

**UNIVERSIDAD MIGUEL HERNÁNDEZ DE ELCHE**

**ESCUELA POLITÉCNICA SUPERIOR DE ELCHE**

**GRADO EN INGENIERÍA ELECTRÓNICA  
Y AUTOMÁTICA INDUSTRIAL**



**“Sistema de Clasificación de textura y color  
mediante Visión Por Computador”**

Trabajo Fin de Grado

Curso 2019/2020

Autor: Edison David Fajardo Sigüencia

Tutor: Luis Miguel Jiménez García



## Agradecimientos

En primer lugar, me gustaría dar las gracias a mi tutor, Luis Miguel Jiménez García, tanto por la oportunidad de poder realizar este proyecto como por la ayuda brindada a lo largo del mismo, en especial por las sugerencias y la rápida resolución de dudas.

También quiero dar las gracias, en particular, mi madre y a mi tía que han sido el aliento que me ha hecho seguir adelante cuando atravesaba algún mal momento donde ni yo mismo creía en mí. Por último, quiero agradecer también al resto de mi familia, amigos y compañeros por formar parte de esta etapa de mi vida.



# Contenido

Agradecimientos .....	III
Lista de ilustraciones.....	VII
Lista de gráficas.....	VIII
Lista de tablas .....	XXIII
1. Introducción.....	1
1.1 Motivación .....	1
1.2 Objetivos .....	2
1.3 Estructura de la memoria.....	2
2. Estado del arte .....	4
2.1 Historia de la visión por computador.....	4
2.2 Componentes .....	6
2.3 Cámaras.....	7
2.4 Usos de la visión por computador.....	9
2.5 Descriptores de imagen .....	12
2.5.1 Textura .....	13
2.5.1.1 Tonos de la textura .....	16
2.5.1.2 Algoritmos estadísticos.....	16
2.5.1.3 Patrones locales binarios .....	17
2.5.1.4 Matriz de coocurrencia.....	18
2.6 Color.....	19
2.6.1 Percepción humana .....	20
2.6.2 Teoría de los colores opuestos.....	20
2.6.3 Representación del color .....	21
2.6.3.1 Modelos lineales.....	21
2.6.3.2 Modelos no lineales.....	23
2.6.3.3 Espacios uniformes de color .....	25
2.7 Clasificadores .....	28
2.7.1 Regresión logística .....	28
2.7.2 SVM (Maquinas de Vector Soporte) .....	31
2.7.3 Vecino más cercano .....	32
2.7.4 Redes neuronales.....	33

2.7.5	Arboles de decisión .....	36
3.	Material y métodos.....	38
3.1	Data sets.....	38
3.1.1	SIPI rotated texture [19] .....	38
3.1.2	ALOT (Amsterdam library of textures [20]).....	38
3.1.3	DTD (Describable Textures Dataset [21]).....	39
2.1.4	Uso general de las bases de datos .....	39
3.2	Espacios de color.....	40
3.3	Descriptores .....	43
3.3.1	Momentos de histograma.....	43
3.3.2	Matriz de coocurrencia .....	43
3.3.3	Patrones locales binarios (LBP) .....	46
3.4	Clasificadores .....	47
3.5	Red neuronal convolucional.....	50
4.	Resultados.....	53
4.1	Comparación de los clasificadores comunes .....	53
4.1.1	Comparación en escala de grises con el primer data set.....	54
4.1.2	Comparación en RGB con el segundo data set .....	81
4.1.3	Comparación en colores opuestos con el segundo data set.....	107
4.1.4	Comparación en HSV con el segundo data set .....	133
4.1.5	Comparación en LAB con el segundo data set.....	160
4.1.6	Comparación en RGB con el tercer data set .....	186
4.1.7	Comparación en colores opuestos con el tercer data set.....	212
4.1.8	Comparación en HSV con el tercer data set .....	239
4.1.9	Comparación en LAB con el tercer data set.....	265
4.2	Resultados de la CNN .....	291
5.	Conclusiones .....	304
5.1	Análisis de los resultados de los espacios de color y clasificadores de imagen.....	304
5.2	Análisis de los resultados de la CNN .....	309
5.3	Trabajos futuros .....	310
	Bibliografía .....	312



# Lista de ilustraciones

Ilustración 1. Componentes de un sistema de visión por computador .....	6
Ilustración 2. Cámara lineal. Marca Racer. ....	8
Ilustración 3. Simulación de la conducción de un coche autónomo.....	11
Ilustración 4. Sintetizar refiltrando las capas y añadiéndolas entonces. ....	15
Ilustración 5. Funcionamiento del LBP original.....	18
Ilustración 6. Representación del color: diagrama cromático xy.....	23
Ilustración 7. A la izquierda el cubo RGB. A la derecha el hexágono obtenido .....	25
Ilustración 8. Representación espacio uniforme $L^*a^*b^*$ .....	26
Ilustración 9. Representación espacio uniforme $L^*u^*v^*$ .....	27
Ilustración 10. La grafica de la derecha corresponde al primer término de la ecuación 1 y la segunda corresponde al segundo término.....	30
Ilustración 11. Ejemplo kernel Gaussiano.....	32
Ilustración 12. Ejemplo del método de reconocimiento del vecino mas cercano.....	33
Ilustración 13. Modelo básico del funcionamiento de una neurona.....	34
Ilustración 14. LeNET CNN .....	36
Ilustración 15. Algoritmo de Greddy.....	37
Ilustración 16. Ejemplo de variación del muestreo espacial.....	40
Ilustración 17. Ejemplo de la variación del número de bits en la digitalización .....	40
Ilustración 18. Ejemplo de la extracción de características con el uso de LBP .....	46
Ilustración 19. Estructura AlexNet .....	51
Ilustración 20. Primera configuración CNN.....	291
Ilustración 21. Segunda configuración CNN.....	293
Ilustración 22. Tercera configuración CNN .....	294
Ilustración 23. Cuarta configuración CNN.....	295
Ilustración 24. Quinta configuración CNN .....	296
Ilustración 25. Sexta configuración CNN.....	297
Ilustración 26. Séptima configuración CNN .....	298
Ilustración 27. Octava configuración CNN .....	299
Ilustración 28. Novena configuración CNN .....	300
Ilustración 29. Decima configuración CNN .....	301
Ilustración 30. Undécima configuración CNN .....	302
Ilustración 31. Progreso del entrenamiento de la CNN .....	310

## Lista de gráficas

Gráfica 1. Comparación clasificadores para ventanas cuadradas para momentos de histograma en escala de grises .....	54
Gráfica 2. Regresión lineal de la red neuronal.....	55
Gráfica 3. Comparación clasificadores para ventanas en filas para momentos de histograma en escala de grises .....	55
Gráfica 4. Validación del modelo de la gráfica 2.....	56
Gráfica 5. Comparación clasificadores para ventanas en columnas para momentos de histograma en escala de grises .....	56
Gráfica 6. Validación del modelo de la gráfica 5.....	57
Gráfica 7. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en escala de grises .....	58
Gráfica 8. Regresión lineal de la red neuronal.....	59
Gráfica 9. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en escala de grises .....	59
Gráfica 10. Validación del modelo de la gráfica 9.....	60
Gráfica 11. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en escala de grises .....	60
Gráfica 12. Validación del modelo de la gráfica 11.....	61
Gráfica 13. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación y con radio 1 en escala de grises .....	62
Gráfica 14. Validación del modelo de la gráfica 13.....	62
Gráfica 15. Comparación clasificadores para ventanas en filas para LBP variante a rotación y con radio 1 en escala de grises .....	63
Gráfica 16. Validación del modelo de la gráfica 15.....	63
Gráfica 17. Comparación clasificadores para ventanas en columnas para LBP variante a rotación y con radio 1 en escala de grises .....	64
Gráfica 18. Validación del modelo de la gráfica 17.....	64
Gráfica 19. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación y con radio 3 en escala de grises .....	65
Gráfica 20. Validación del modelo de la gráfica 19.....	66
Gráfica 21. Comparación clasificadores para ventanas en filas para LBP variante a rotación y con radio 3 en escala de grises .....	66
Gráfica 22. Validación del modelo de la gráfica 21.....	67
Gráfica 23. Comparación clasificadores para ventanas en columnas para LBP variante a rotación y con radio 3 en escala de grises .....	67
Gráfica 24. Validación del modelo de la gráfica 23.....	68
Gráfica 25. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación y con radio 5 en escala de grises .....	68
Gráfica 26. Validación del modelo de la gráfica 25.....	69
Gráfica 27. Comparación clasificadores para ventanas en filas para LBP variante a rotación y con radio 5 en escala de grises .....	69
Gráfica 28. Validación del modelo de la gráfica 27.....	70

Gráfica 29. Comparación clasificadores para ventanas en columnas para LBP variante a rotación y con radio 5 en escala de grises .....	70
Gráfica 30. Validación del modelo de la gráfica 29.....	71
Gráfica 31. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación y con radio 1 en escala de grises .....	71
Gráfica 32. Validación del modelo de la gráfica 31.....	72
Gráfica 33. Comparación clasificadores para ventanas en filas para LBP invariante a rotación y con radio 1 en escala de grises .....	73
Gráfica 34. Validación del modelo de la gráfica 33.....	73
Gráfica 35. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación y con radio 1 en escala de grises .....	74
Gráfica 36. Validación del modelo de la gráfica 35.....	74
Gráfica 37. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación y con radio 3 en escala de grises .....	75
Gráfica 38. Validación del modelo de la gráfica 36.....	75
Gráfica 39. Comparación clasificadores para ventanas en filas para LBP invariante a rotación y con radio 3 en escala de grises .....	76
Gráfica 40. Validación del modelo de la gráfica 39.....	76
Gráfica 41. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación y con radio 3 en escala de grises .....	77
Gráfica 42. Validación del modelo de la gráfica 41.....	77
Gráfica 43. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación y con radio 5 en escala de grises .....	78
Gráfica 44. Validación del modelo de la gráfica 43.....	78
Gráfica 45. Comparación clasificadores para ventanas en filas para LBP invariante a rotación y con radio 5 en escala de grises .....	79
Gráfica 46. Validación del modelo de la gráfica 45.....	79
Gráfica 47. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación y con radio 5 en escala de grises .....	80
Gráfica 48. Validación del modelo de la gráfica 47.....	80
Gráfica 49. Comparación clasificadores para ventanas cuadradas para momentos de histograma en RGB .....	81
Gráfica 50. Regresión lineal de la red neuronal.....	82
Gráfica 51. Comparación clasificadores para ventanas en filas para momentos de histograma en RGB .....	82
Gráfica 52. Validación del modelo de la gráfica 51.....	83
Gráfica 53. Comparación clasificadores para ventanas en columnas para momentos de histograma en RGB .....	83
Gráfica 54. Validación del modelo de la gráfica 53.....	84
Gráfica 55. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en RGB .....	84
Gráfica 56. Validación del modelo de la gráfica 55.....	85
Gráfica 57. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en RGB .....	85

Gráfica 58. Validación del modelo de la gráfica 57.....	86
Gráfica 59. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en RGB .....	86
Gráfica 60. Validación del modelo de la gráfica 59.....	87
Gráfica 61. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en RGB .....	87
Gráfica 62. Validación del modelo de la gráfica 61.....	88
Gráfica 63. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en RGB.....	88
Gráfica 64. Validación del modelo de la gráfica 63.....	89
Gráfica 65. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en RGB .....	89
Gráfica 66. Validación del modelo de la gráfica 65.....	90
Gráfica 67. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en RGB .....	90
Gráfica 68. Validación del modelo de la gráfica 67.....	91
Gráfica 69. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en RGB.....	91
Gráfica 70. Validación del modelo de la gráfica 69.....	92
Gráfica 71. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en RGB .....	92
Gráfica 72. Validación del modelo de la gráfica 71.....	93
Gráfica 73. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en RGB .....	94
Gráfica 74. Validación del modelo de la gráfica 73.....	94
Gráfica 75. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en RGB.....	95
Gráfica 76. Validación del modelo de la gráfica 75.....	95
Gráfica 77. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en RGB .....	96
Gráfica 78. Validación del modelo de la gráfica 77.....	96
Gráfica 79. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en RGB .....	97
Gráfica 80. Validación del modelo de la gráfica 79.....	97
Gráfica 81. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en RGB .....	98
Gráfica 82. Validación del modelo de la gráfica 81.....	98
Gráfica 83. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en RGB.....	99
Gráfica 84. Validación del modelo de la gráfica 83.....	99
Gráfica 85. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en RGB .....	100
Gráfica 86. Validación del modelo de la gráfica 85.....	101

Gráfica 87. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en RGB .....	101
Gráfica 88. Validación del modelo de la gráfica 87.....	102
Gráfica 89. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en RGB.....	102
Gráfica 90. Validación del modelo de la gráfica 89.....	103
Gráfica 91. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en RGB .....	103
Gráfica 92. Validación del modelo de la gráfica 91.....	104
Gráfica 93. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en RGB .....	104
Gráfica 94. Validación del modelo de la gráfica 93.....	105
Gráfica 95. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en RGB.....	105
Gráfica 96. Validación del modelo de la gráfica 95.....	106
Gráfica 97. Comparación clasificadores para ventanas cuadradas para momentos de histograma en colores opuestos.....	107
Gráfica 98. Validación del modelo elegido de la gráfica 97 .....	107
Gráfica 99. Comparación clasificadores para ventanas en filas para momentos de histograma en colores opuestos.....	108
Gráfica 100. Validación del modelo elegido de la gráfica 99 .....	108
Gráfica 101. Comparación clasificadores para ventanas en columnas para momentos de histograma en colores opuestos .....	109
Gráfica 102. Validación del modelo elegido de la gráfica 101.....	109
Gráfica 103. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en colores opuestos.....	110
Gráfica 104. Validación del modelo elegido de la gráfica 103 .....	111
Gráfica 105. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en colores opuestos.....	111
Gráfica 106. Validación del modelo elegido de la gráfica 105 .....	112
Gráfica 107. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en colores opuestos.....	112
Gráfica 108. Validación del modelo elegido de la gráfica 107 .....	113
Gráfica 109. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en colores opuestos.....	113
Gráfica 110. Validación del modelo elegido de la gráfica 109 .....	114
Gráfica 111. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en colores opuestos.....	114
Gráfica 112. Validación del modelo elegido de la gráfica 111.....	115
Gráfica 113. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en colores opuestos .....	115
Gráfica 114. Validación del modelo elegido de la gráfica 113 .....	116
Gráfica 115. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en colores opuestos.....	116

Gráfica 116. Validación del modelo elegido de la gráfica 115 .....	117
Gráfica 117. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en colores opuestos.....	117
Gráfica 118. Validación del modelo elegido de la gráfica 117 .....	118
Gráfica 119. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en colores opuestos .....	118
Gráfica 120. Validación del modelo elegido de la gráfica 119.....	119
Gráfica 121. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en colores opuestos.....	120
Gráfica 122. Validación del modelo elegido de la gráfica 121.....	120
Gráfica 123. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en colores opuestos.....	121
Gráfica 124. Validación del modelo elegido de la gráfica 123 .....	121
Gráfica 125. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en colores opuestos .....	122
Gráfica 126. Validación del modelo elegido de la gráfica 125.....	122
Gráfica 127. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en colores opuestos .....	123
Gráfica 128. Validación del modelo elegido de la gráfica 127.....	124
Gráfica 129. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en colores opuestos.....	124
Gráfica 130. Validación del modelo elegido de la gráfica 129.....	125
Gráfica 131. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en colores opuestos .....	125
Gráfica 132. Validación del modelo elegido de la gráfica 131.....	126
Gráfica 133. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en colores opuestos .....	126
Gráfica 134. Validación del modelo elegido de la gráfica 133.....	127
Gráfica 135. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en colores opuestos.....	127
Gráfica 136. Validación del modelo elegido de la gráfica 135.....	128
Gráfica 137. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en colores opuestos .....	128
Gráfica 138. Validación del modelo elegido de la gráfica 137.....	129
Gráfica 139. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en colores opuestos .....	129
Gráfica 140. Validación del modelo elegido de la gráfica 139.....	130
Gráfica 141. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en colores opuestos.....	130
Gráfica 142. Validación del modelo elegido de la gráfica 141.....	131
Gráfica 143. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en colores opuestos .....	131
Gráfica 144. Validación del modelo elegido de la gráfica 143.....	132

Gráfica 145. Comparación clasificadores para ventanas cuadradas para momentos de histograma en HSV.....	133
Gráfica 146. Regresión lineal de la red neuronal del modelo de la gráfica 145 .....	134
Gráfica 147. Comparación clasificadores para ventanas en filas para momentos de histograma en HSV.....	134
Gráfica 148. Validación del modelo elegido de la gráfica 147.....	135
Gráfica 149. Comparación clasificadores para ventanas en columnas para momentos de histograma en HSV.....	135
Gráfica 150. Validación del modelo elegido de la gráfica 149.....	136
Gráfica 151. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en HSV.....	137
Gráfica 152. Validación del modelo elegido de la gráfica 151.....	137
Gráfica 153. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en HSV .....	138
Gráfica 154. Validación del modelo elegido de la gráfica 153.....	138
Gráfica 155. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en HSV.....	139
Gráfica 156. Validación del modelo elegido de la gráfica 155.....	139
Gráfica 157. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en HSV.....	140
Gráfica 158. Validación del modelo elegido de la gráfica 157.....	140
Gráfica 159. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en HSV.....	141
Gráfica 160. Validación del modelo elegido de la gráfica 159.....	142
Gráfica 161. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en HSV.....	142
Gráfica 162. Validación del modelo elegido de la gráfica 161.....	143
Gráfica 163. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en HSV.....	143
Gráfica 164. Validación del modelo elegido de la gráfica 163.....	144
Gráfica 165. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en HSV.....	144
Gráfica 166. Validación del modelo elegido de la gráfica 165.....	145
Gráfica 167. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en HSV.....	145
Gráfica 168. Validación del modelo elegido de la gráfica 167.....	146
Gráfica 169. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en HSV.....	147
Gráfica 170. Validación del modelo elegido de la gráfica 169.....	147
Gráfica 171. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en HSV.....	148
Gráfica 172. Validación del modelo elegido de la gráfica 171.....	148
Gráfica 173. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en HSV.....	149

Gráfica 174. Validación del modelo elegido de la gráfica 173 .....	149
Gráfica 175. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en HSV .....	150
Gráfica 176. Validación del modelo elegido de la gráfica 175 .....	150
Gráfica 177. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en HSV .....	151
Gráfica 178. Validación del modelo elegido de la gráfica 177 .....	152
Gráfica 179. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en HSV .....	152
Gráfica 180. Validación del modelo elegido de la gráfica 179 .....	153
Gráfica 181. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en HSV .....	153
Gráfica 182. Validación del modelo elegido de la gráfica 181 .....	154
Gráfica 183. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en HSV .....	154
Gráfica 184. Validación del modelo elegido de la gráfica 183 .....	155
Gráfica 185. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en HSV .....	155
Gráfica 186. Validación del modelo elegido de la gráfica 185 .....	156
Gráfica 187. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en HSV .....	156
Gráfica 188. Validación del modelo elegido de la gráfica 187 .....	157
Gráfica 189. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en HSV .....	157
Gráfica 190. Validación del modelo elegido de la gráfica 189 .....	158
Gráfica 191. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en HSV .....	158
Gráfica 192. Validación del modelo elegido de la gráfica 191 .....	159
Gráfica 193. Comparación clasificadores para ventanas cuadradas para momentos de histograma en LAB .....	160
Gráfica 194. Validación del modelo elegido de la gráfica 193 .....	160
Gráfica 195. Comparación clasificadores para ventanas en filas para momentos de histograma en LAB .....	161
Gráfica 196. Validación del modelo elegido de la gráfica 195 .....	161
Gráfica 197. Comparación clasificadores para ventanas en columnas para momentos de histograma en LAB .....	162
Gráfica 198. Validación del modelo elegido de la gráfica 197 .....	162
Gráfica 199. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en LAB .....	163
Gráfica 200. Validación del modelo elegido de la gráfica 199 .....	164
Gráfica 201. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en LAB .....	164
Gráfica 202. Validación del modelo elegido de la gráfica 201 .....	165

Gráfica 203. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en LAB .....	165
Gráfica 204. Validación del modelo elegido de la gráfica 203 .....	166
Gráfica 205. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en LAB .....	166
Gráfica 206. Validación del modelo elegido de la gráfica 205 .....	167
Gráfica 207. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en LAB .....	167
Gráfica 208. Validación del modelo elegido de la gráfica 207 .....	168
Gráfica 209. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en LAB .....	168
Gráfica 210. Validación del modelo elegido de la gráfica 209 .....	169
Gráfica 211. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en LAB .....	170
Gráfica 212. Validación del modelo elegido de la gráfica 211 .....	170
Gráfica 213. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en LAB .....	171
Gráfica 214. Validación del modelo elegido de la gráfica 213 .....	171
Gráfica 215. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en LAB .....	172
Gráfica 216. Validación del modelo elegido de la gráfica 215 .....	172
Gráfica 217. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en LAB .....	173
Gráfica 218. Validación del modelo elegido de la gráfica 217 .....	174
Gráfica 219. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en LAB .....	174
Gráfica 220. Validación del modelo elegido de la gráfica 219 .....	175
Gráfica 221. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en LAB .....	175
Gráfica 222. Validación del modelo elegido de la gráfica 221 .....	176
Gráfica 223. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en LAB .....	176
Gráfica 224. Validación del modelo elegido de la gráfica 223 .....	177
Gráfica 225. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en LAB .....	177
Gráfica 226. Validación del modelo elegido de la gráfica 225 .....	178
Gráfica 227. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en LAB .....	178
Gráfica 228. Validación del modelo elegido de la gráfica 227 .....	179
Gráfica 229. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en LAB .....	180
Gráfica 230. Validación del modelo elegido de la gráfica 229 .....	180
Gráfica 231. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en LAB .....	181

Gráfica 232. Validación del modelo elegido de la gráfica 231 .....	181
Gráfica 233. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en LAB .....	182
Gráfica 234. Validación del modelo elegido de la gráfica 233 .....	182
Gráfica 235. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en LAB .....	183
Gráfica 236. Validación del modelo elegido de la gráfica 235 .....	183
Gráfica 237. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en LAB .....	184
Gráfica 238. Validación del modelo elegido de la gráfica 237 .....	184
Gráfica 239. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en LAB .....	185
Gráfica 240. Validación del modelo elegido de la gráfica 239 .....	185
Gráfica 241. Comparación clasificadores para ventanas cuadradas para momentos de histograma en RGB .....	186
Gráfica 242. Validación del modelo elegido de la gráfica 241 .....	187
Gráfica 243. Comparación clasificadores para ventanas en filas para momentos de histograma en RGB .....	187
Gráfica 244. Validación del modelo elegido de la gráfica 243 .....	188
Gráfica 245. Comparación clasificadores para ventanas en columnas para momentos de histograma en RGB .....	188
Gráfica 246. Validación del modelo elegido de la gráfica 245 .....	189
Gráfica 247. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en RGB .....	189
Gráfica 248. Validación del modelo elegido de la gráfica 247 .....	190
Gráfica 249. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en RGB .....	190
Gráfica 250. Validación del modelo elegido de la gráfica 249 .....	191
Gráfica 251. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en RGB .....	191
Gráfica 252. Validación del modelo elegido de la gráfica 251 .....	192
Gráfica 253. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en RGB .....	193
Gráfica 254. Validación del modelo elegido de la gráfica 253 .....	193
Gráfica 255. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en RGB .....	194
Gráfica 256. Validación del modelo elegido de la gráfica 255 .....	194
Gráfica 257. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en RGB.....	195
Gráfica 258. Validación del modelo elegido de la gráfica 257 .....	195
Gráfica 259. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en RGB .....	196
Gráfica 260. Validación del modelo elegido de la gráfica 259 .....	196

Gráfica 261. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en RGB .....	197
Gráfica 262. Validación del modelo elegido de la gráfica 261 .....	197
Gráfica 263. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en RGB.....	198
Gráfica 264. Validación del modelo elegido de la gráfica 263 .....	198
Gráfica 265. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en RGB .....	199
Gráfica 266. Validación del modelo elegido de la gráfica 265 .....	200
Gráfica 267. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en RGB .....	200
Gráfica 268. Validación del modelo elegido de la gráfica 267 .....	201
Gráfica 269. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en RGB.....	201
Gráfica 270. Validación del modelo elegido de la gráfica 269 .....	202
Gráfica 271. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en RGB.....	202
Gráfica 272. Validación del modelo elegido de la gráfica 271 .....	203
Gráfica 273. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en RGB .....	203
Gráfica 274. Validación del modelo elegido de la gráfica 273 .....	204
Gráfica 275. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en RGB.....	204
Gráfica 276. Validación del modelo elegido de la gráfica 275 .....	205
Gráfica 277. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en RGB.....	206
Gráfica 278. Validación del modelo elegido de la gráfica 277 .....	206
Gráfica 279. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en RGB .....	207
Gráfica 280. Validación del modelo elegido de la gráfica 279 .....	207
Gráfica 281. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en RGB.....	208
Gráfica 282. Validación del modelo elegido de la gráfica 281 .....	208
Gráfica 283. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en RGB.....	209
Gráfica 284. Validación del modelo elegido de la gráfica 283 .....	209
Gráfica 285. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en RGB .....	210
Gráfica 286. Validación del modelo elegido de la gráfica 285 .....	210
Gráfica 287. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en RGB.....	211
Gráfica 288. Validación del modelo elegido de la gráfica 287 .....	211
Gráfica 289. Comparación clasificadores para ventanas cuadradas para momentos de histograma en colores opuestos .....	212

Gráfica 290. Validación del modelo elegido de la gráfica 289 .....	213
Gráfica 291. Comparación clasificadores para ventanas en filas para momentos de histograma en colores opuestos .....	213
Gráfica 292. Validación del modelo elegido de la gráfica 291 .....	214
Gráfica 293. Comparación clasificadores para ventanas en columnas para momentos de histograma en colores opuestos .....	214
Gráfica 294. Validación del modelo elegido de la gráfica 293 .....	215
Gráfica 295. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en colores opuestos .....	215
Gráfica 296. Validación del modelo elegido de la gráfica 295 .....	216
Gráfica 297. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en colores opuestos .....	216
Gráfica 298. Validación del modelo elegido de la gráfica 297 .....	217
Gráfica 299. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en colores opuestos .....	217
Gráfica 300. Validación del modelo elegido de la gráfica 299 .....	218
Gráfica 301. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en colores opuestos .....	218
Gráfica 302. Validación del modelo elegido de la gráfica 301 .....	219
Gráfica 303. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en colores opuestos .....	219
Gráfica 304. Validación del modelo elegido de la gráfica 303 .....	220
Gráfica 305. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en colores opuestos .....	220
Gráfica 306. Validación del modelo elegido de la gráfica 305 .....	221
Gráfica 307. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en colores opuestos .....	222
Gráfica 308. Validación del modelo elegido de la gráfica 307 .....	222
Gráfica 309. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en colores opuestos .....	223
Gráfica 310. Validación del modelo elegido de la gráfica 309 .....	223
Gráfica 311. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en colores opuestos .....	224
Gráfica 312. Validación del modelo elegido de la gráfica 311 .....	224
Gráfica 313. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en colores opuestos .....	225
Gráfica 314. Validación del modelo elegido de la gráfica 313 .....	226
Gráfica 315. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en colores opuestos .....	226
Gráfica 316. Validación del modelo elegido de la gráfica 315 .....	227
Gráfica 317. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en colores opuestos .....	227
Gráfica 318. Validación del modelo elegido de la gráfica 317 .....	228

Gráfica 319. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en colores opuestos .....	228
Gráfica 320. Validación del modelo elegido de la gráfica 319 .....	229
Gráfica 321. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en colores opuestos.....	229
Gráfica 322. Validación del modelo elegido de la gráfica 321.....	230
Gráfica 323. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en colores opuestos .....	231
Gráfica 324. Validación del modelo elegido de la gráfica 323.....	231
Gráfica 325. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en colores opuestos .....	232
Gráfica 326. Validación del modelo elegido de la gráfica 325 .....	233
Gráfica 327. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en colores opuestos.....	233
Gráfica 328. Validación del modelo elegido de la gráfica 327 .....	234
Gráfica 329. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en colores opuestos .....	234
Gráfica 330. Validación del modelo elegido de la gráfica 329.....	235
Gráfica 331. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en colores opuestos .....	235
Gráfica 332. Validación del modelo elegido de la gráfica 331.....	236
Gráfica 333. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en colores opuestos.....	236
Gráfica 334. Validación del modelo elegido de la gráfica 333.....	237
Gráfica 335. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en colores opuestos .....	238
Gráfica 336. Validación del modelo elegido de la gráfica 335.....	238
Gráfica 337. Comparación clasificadores para ventanas cuadradas para momentos de histograma en HSV.....	239
Gráfica 338. Validación del modelo elegido de la gráfica 337.....	240
Gráfica 339. Comparación clasificadores para ventanas en filas para momentos de histograma en HSV.....	240
Gráfica 340. Validación del modelo elegido de la gráfica 339.....	241
Gráfica 341. Comparación clasificadores para ventanas en columnas para momentos de histograma en HSV.....	241
Gráfica 342. Validación del modelo elegido de la gráfica 341.....	242
Gráfica 343. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en HSV.....	242
Gráfica 344. Validación del modelo elegido de la gráfica 343.....	243
Gráfica 345. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en HSV .....	243
Gráfica 346. Validación del modelo elegido de la gráfica 345.....	244
Gráfica 347. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en HSV.....	244

Gráfica 348. Validación del modelo elegido de la gráfica 347 .....	245
Gráfica 349. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en HSV.....	246
Gráfica 350. Validación del modelo elegido de la gráfica 349.....	246
Gráfica 351. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en HSV.....	247
Gráfica 352. Validación del modelo elegido de la gráfica 351.....	247
Gráfica 353. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en HSV.....	248
Gráfica 354. Validación del modelo elegido de la gráfica 353.....	248
Gráfica 355. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en HSV.....	249
Gráfica 356. Validación del modelo elegido de la gráfica 355.....	249
Gráfica 357. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en HSV.....	250
Gráfica 358. Validación del modelo elegido de la gráfica 357.....	250
Gráfica 359. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en HSV.....	251
Gráfica 360. Validación del modelo elegido de la gráfica 359.....	251
Gráfica 361. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en HSV.....	252
Gráfica 362. Validación del modelo elegido de la gráfica 361.....	253
Gráfica 363. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en HSV.....	253
Gráfica 364. Validación del modelo elegido de la gráfica 363.....	254
Gráfica 365. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en HSV.....	254
Gráfica 366. Validación del modelo elegido de la gráfica 365.....	255
Gráfica 367. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en HSV.....	255
Gráfica 368. Validación del modelo elegido de la gráfica 367.....	256
Gráfica 369. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en HSV.....	256
Gráfica 370. Validación del modelo elegido de la gráfica 369.....	257
Gráfica 371. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en HSV.....	257
Gráfica 372. Validación del modelo elegido de la gráfica 371.....	258
Gráfica 373. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en HSV.....	259
Gráfica 374. Validación del modelo elegido de la gráfica 373.....	259
Gráfica 375. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en HSV.....	260
Gráfica 376. Validación del modelo elegido de la gráfica 375.....	260

Gráfica 377. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en HSV.....	261
Gráfica 378. Validación del modelo elegido de la gráfica 377.....	261
Gráfica 379. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en HSV.....	262
Gráfica 380. Validación del modelo elegido de la gráfica 379.....	262
Gráfica 381. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en HSV.....	263
Gráfica 382. Validación del modelo elegido de la gráfica 381.....	263
Gráfica 383. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en HSV.....	264
Gráfica 384. Validación del modelo elegido de la gráfica 383.....	264
Gráfica 385. Comparación clasificadores para ventanas cuadradas para momentos de histograma en LAB.....	265
Gráfica 386. Validación del modelo elegido de la gráfica 385.....	266
Gráfica 387. Comparación clasificadores para ventanas en filas para momentos de histograma en LAB.....	266
Gráfica 388. Validación del modelo elegido de la gráfica 387.....	267
Gráfica 389. Comparación clasificadores para ventanas en columnas para momentos de histograma en LAB.....	267
Gráfica 390. Validación del modelo elegido de la gráfica 389.....	268
Gráfica 391. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en LAB.....	268
Gráfica 392. Validación del modelo elegido de la gráfica 391.....	269
Gráfica 393. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en LAB.....	269
Gráfica 394. Validación del modelo elegido de la gráfica 393.....	270
Gráfica 395. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en LAB.....	270
Gráfica 396. Validación del modelo elegido de la gráfica 395.....	271
Gráfica 397. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en LAB.....	271
Gráfica 398. Validación del modelo elegido de la gráfica 397.....	272
Gráfica 399. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en LAB.....	272
Gráfica 400. Validación del modelo elegido de la gráfica 399.....	273
Gráfica 401. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en LAB.....	273
Gráfica 402. Validación del modelo elegido de la gráfica 401.....	274
Gráfica 403. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en LAB.....	274
Gráfica 404. Validación del modelo elegido de la gráfica 403.....	275
Gráfica 405. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en LAB.....	275

Gráfica 406. Validación del modelo elegido de la gráfica 405 .....	276
Gráfica 407. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en LAB .....	276
Gráfica 408. Validación del modelo elegido de la gráfica 407 .....	277
Gráfica 409. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en LAB .....	278
Gráfica 410. Validación del modelo elegido de la gráfica 409 .....	278
Gráfica 411. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en LAB .....	279
Gráfica 412. Validación del modelo elegido de la gráfica 411 .....	279
Gráfica 413. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en LAB .....	280
Gráfica 414. Validación del modelo elegido de la gráfica 413 .....	280
Gráfica 415. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en LAB .....	281
Gráfica 416. Validación del modelo elegido de la gráfica 415 .....	281
Gráfica 417. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en LAB .....	282
Gráfica 418. Validación del modelo elegido de la gráfica 417 .....	283
Gráfica 419. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en LAB .....	283
Gráfica 420. Validación del modelo elegido de la gráfica 419 .....	284
Gráfica 421. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en LAB .....	284
Gráfica 422. Validación del modelo elegido de la gráfica 421 .....	285
Gráfica 423. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en LAB .....	285
Gráfica 424. Validación del modelo elegido de la gráfica 423 .....	286
Gráfica 425. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en LAB .....	286
Gráfica 426. Validación del modelo elegido de la gráfica 425 .....	287
Gráfica 427. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en LAB .....	288
Gráfica 428. Validación del modelo elegido de la gráfica 427 .....	288
Gráfica 429. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en LAB .....	289
Gráfica 430. Validación del modelo elegido de la gráfica 429 .....	289
Gráfica 431. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en LAB .....	290
Gráfica 432. Validación del modelo elegido de la gráfica 431 .....	290

## Lista de tablas

Tabla 1. Tabla del entrenamiento de la CNN primera configuración .....	292
Tabla 2. Tabla del entrenamiento de la CNN segunda configuración.....	293
Tabla 3. Tabla del entrenamiento de la CNN tercera configuración.....	294
Tabla 4. Tabla del entrenamiento de la CNN cuarta configuración.....	295
Tabla 5. Tabla del entrenamiento de la CNN quinta configuración.....	296
Tabla 6. Tabla del entrenamiento de la CNN sexta configuración.....	297
Tabla 7. Tabla del entrenamiento de la CNN séptima configuración .....	298
Tabla 8. Tabla del entrenamiento de la CNN octava configuración .....	299
Tabla 9. Tabla del entrenamiento de la CNN novena configuración .....	300
Tabla 10. Tabla del entrenamiento de la CNN decima configuración .....	301
Tabla 11. Tabla del entrenamiento de la CNN undécima configuración .....	302
Tabla 12. Tabla del entrenamiento de la CNN última configuración.....	310



# 1. Introducción

La visión por computador, también llamada visión artificial, es una disciplina basada en la adquisición de imágenes mediante el uso de métodos con los que podamos adquirir, procesar y analizar imágenes del mundo real. La adquisición la obtendremos mediante el uso de una o varias cámaras, los distintos tipos de uso serán explicados más adelante. Y para poder llevar a cabo el procesamiento y el análisis es necesaria la transformación de la información del mundo real en una representación que los ordenadores puedan manejar.

Los objetivos de este campo son, a nivel ingenieril, la construcción de sistemas autónomos que sean capaces de realizar tareas que solo podrían ser realizadas correctamente con un sistema de visión humano. También podríamos hablar desde el punto de vista de la biología, ya que podríamos conseguir modelos computacionales del sistema de visión humano. Es cierto que son objetivos muy ligados, ya que el conocimiento actual del sistema de visión humano es amplio [1]. Este conocimiento sirve de inspiración a los ingenieros que diseñan los sistemas de visión por computador.

## 1.1 Motivación

En el mundo actual existen multitud de tareas, procesos, trabajos, etcétera... que conllevan un gran peligro para la persona que debe hacerlos, ya sea por las condiciones en las que se tiene que hacer como en lo azaroso del mismo trabajo.

Por ello, la motivación principal de este trabajo es hacer que la visión por computador de un paso hacia delante y mediante el uso de lo ya conocido y de lo que se puede llegar a conocer, conseguir sistemas de visión por computador que sean capaces de realizar tareas cada vez más complejas. Además, vivimos en un mundo en constante crecimiento donde la optimización de recursos ha adquirido un gran papel, y gracias a sistemas como el que se pretende

implementar los distintos procesos pueden ser más óptimos, generando menos recursos desperdiciados.

## **1.2 Objetivos**

Anteriormente ya se ha puesto de manifiesto que el objetivo principal del presente proyecto es el de implementar un sistema de clasificación mediante visión por computador utilizando descriptores de color y textura, y también clasificadores basados en imagen y redes neuronales convolucionales.

Para conseguirlo estudiaremos diferentes descriptores, espacios de color, tamaño de ventanas y algoritmos de clasificación utilizando bases de datos de imágenes de dominio público.

## **1.3 Estructura de la memoria**

A continuación, se muestra una lista de los distintos capítulos que conforman el presente proyecto y, una leve y breve, descripción de sus contenidos:

- En el capítulo 1 (actual) se da una pequeña introducción al proyecto, también se expone su motivación y su principal objetivo.
- En el capítulo 2 se redacta el estado del arte en la visión por computador, haciendo hincapié en la textura y color en imágenes digitales. También se habla sobre los distintos clasificadores que se usan hoy en día. Además, se exponen las bases científicas y los puntos más relevantes de investigaciones relacionadas.
- En el capítulo 3 se detalla en profundidad tanto los descriptores, como los clasificadores, como los espacios de color que vamos a utilizar. También se exponen los distintos data sets de los que vamos a hacer uso y la manera en que lo haremos.

- En el capítulo 4 se expondrán y discutirán los resultados que hemos obtenido con las distintas configuraciones entre espacio de color, descriptor, clasificador y tamaño de ventana. además, de los resultados obtenido con la red neuronal convolucional AlexNet.
- En el capítulo 5 mostraremos las conclusiones del proyecto y se planteara un posible trabajo futuro.



## **2. Estado del arte**

En este capítulo pretendemos hacer una introducción que sea capaz de ilustrar con propiedad el ámbito de estudio en el que se encuentra ubicado el presente proyecto. Se describirán los conceptos más relacionados e importantes con la visión por computador, descriptores, espacios de color y métodos de clasificación.

La estructura mantenida es la siguiente: en el apartado 2.1 se expondrá brevemente la historia de la visión por computador, ya que es relevante conocer los pasos que nos han llevado hasta la situación actual. En el apartado 2.2 hablaremos de los componentes más importantes que componen la visión por computador generalmente. En el apartado 2.3 hablaremos de algo fundamental para la visión por computador, las cámaras, el principal instrumento de este campo. En el siguiente apartado, 2.4, se mencionarán los distintos usos que tienen la visión por computador en el mundo actual. En el apartado 2.5 nos centraremos en la textura y en las distintas maneras (descriptores) que existen para analizarla. En el apartado 2.6 hablaremos del concepto de color y de las distintas maneras que existen para representarlo. Por último, nos centraremos en los clasificadores, explicaremos los distintos tipos que existen y sus principales características.

### **2.1 Historia de la visión por computador**

Dentro de la comunidad esta comúnmente aceptado que el padre de la visión por computador es Larry Roberts, ya que, en su realización del doctorado, en el MIT (Massachusetts Institute of Technology), analizo la posibilidad de la extracción de información geométrica 3D desde la vista en perspectiva de bloques 2D [2]. Esto estableció una ruta para el estudio de la visión por computador. Tiempo después se empezó a afrontar las imágenes del mundo real. Esta nueva manera de estudiar la visión por computador fue, básicamente, realizar las tareas de "nivel bajo" como la detección de bordes y segmentación.

Conforme fueron pasando los años se desarrollaron algoritmos más significativos como el detector de bordes de Sobel (1970), que se sigue usando hoy en día. Otro algoritmo importante fue el de la detección de texturas de Haralik y Shanmugam (1973). Años después se produjo otro gran paso, el borrador que presentó David Marr en 1978 en el MIT, el cual supuso un gran acercamiento para lograr entender los distintos objetos que componen una escena [3].

Los algoritmos de detección de bordes y segmentación fueron aplicados a las imágenes 2D para conseguir un boceto, desde el cual con el uso de estéreo binocular se pudo obtener un boceto en 2.5D, que son técnicas que hacen que una serie de imágenes o escenas parezcan ser de tres dimensiones cuando no lo son. Después de todo esto, llegaron las técnicas de alto nivel, análisis de estructuras, que buscaban conseguir modelos representativos en 3D de los objetos en una escena, que hizo afrontar los problemas de la visión por computador de otra manera.

Más tarde fueron apareciendo aplicaciones muy avanzadas, como la detección de rostros en tiempo real (2001) o el testeo de coches autónomos capaces de ir por carretera.

Haciendo un repaso a la historia de este campo, hay que recalcar que a medida que las posibles aplicaciones iban surgiendo tanto la visión por computador como campos relacionados se iban desarrollando más rápido. Esta relación queda reflejada con el procesamiento de imágenes y con su captación, conforme esta tecnología iba avanzando también lo hacía la visión por computador.

## 2.2 Componentes

Para poder desarrollar de manera adecuada un sistema de procesamiento de imágenes digitales necesitamos los siguientes elementos:



ILUSTRACIÓN 1. COMPONENTES DE UN SISTEMA DE VISIÓN POR COMPUTADOR

- Fuente de luz: es uno de los aspectos más relevantes, debemos tener una iluminación uniforme e independiente del entorno. Si no se ilumina adecuadamente podemos perder información y productividad.
- Lentes: capturan la imagen y la llevan al sensor de imagen en la cámara. Es el componente más importante, con la ayuda del resto de características de la cámara, ya que determina la calidad y resolución de la imagen tomada.
- Tarjeta de adquisición o captura de imágenes: actúa como la interfaz entre nuestra cámara y el computador, su función es transformar la imagen obtenida en datos que el computador pueda leer y analizar.
- Computador: es donde se realizará el procesamiento de la imagen a través del software oportuno. El software ubica las características específicas, realiza mediciones y las compara con la especificación. Finalmente, se toma una decisión y se comunican los resultados.

Existen otros elementos a tener en cuenta, como los cables o accesorios de la cámara, cuya combinación o uso por separado nos ayudará a obtener con más calidad la imagen que buscamos.

## 2.3 Cámaras

Si la estudiamos como un conjunto, la cámara tiene la función de capturar la imagen proyectada en el sensor, mediante la lente, para poder transferirla a un sistema electrónico.

Es evidente que para la visión por computador no podemos usar una cámara cualquiera. Las cámaras requieren ciertas características que la hagan útil para la aplicación que se va a llevar a cabo, por ejemplo, un control del disparo para capturar piezas que pasan por delante de ella en la posición requerida. Las podemos clasificar en función de:

- La tecnología del elemento sensor:
  - Cámaras de tubo: se basan en la utilización de un material fotosensible que capta la imagen, siendo leída por un haz de electrones. Obsoletas.
  - Cámaras de estado sólido: tenemos las CCD (Charge Coupled Device), las CMOS (Complementary Metal-Oxide Semiconductor) y CCD color. Los dispositivos CCD usan registros de desplazamiento para transportar la carga de cada píxel y formar la señal analógica, mientras los dispositivos CMOS, cada pixel tiene una electrónica asociada para transferir su información.
- La disposición física:
  - Cámaras lineales: se basan en un sensor CCD lineal, trabajan haciendo la imagen línea a línea ejecutando un barrido del objeto justo con un desplazamiento longitudinal del mismo. Proporciona gran calidad de la imagen, esto exige una precisión de cirujano para formar la imagen a partir de líneas individuales. Su utilización está muy extendida para la inspección de objetos de longitud indeterminada, vidrio, papel, telas, etc. Hay que tener en cuenta las siguientes características técnicas: número de elementos del sensor, a mayor número de elementos (píxeles) mayor tamaño de

la óptica. Velocidad, es decir, el número de píxeles capaces de ser leídos por unidad de tiempo. Y si se trata de una cámara lineal a color, estas cámaras tienen tres sensores lineales, uno por color (azul, rojo y verde). Pueden ser del tipo trisensor donde los sensores CCD están posicionados justo a otros separados por un pequeño espacio y tipo prisma donde los sensores están ubicados en las tres caras de un prisma.



Ilustración 2. Cámara lineal. Marca Racer.

- Cámaras matriciales: el sensor abarca un área que está formada por una matriz de píxeles. Casi todas las cámaras de este tipo llevan tecnología CCD teniendo una matriz formada por miles de diodos fotosensibles posicionados con mucha precisión. Las características más relevantes son: el factor de relleno, porcentaje del área de píxel que es sensible a la luz y que nunca podrá ser ideal (100%). El tipo de transferencia de la información, tenemos la transferencia interlínea (ITL) que funcionan mediante registros de desplazamiento entre las líneas de píxel para almacenar y transferir los datos de la imagen. La transferencia de cuadro tiene un área dedicada al almacenamiento de la luz, separada del área activa. Y transferencia de cuadro entero, esta es la arquitectura más simple, funcionan con registros en paralelo para exposición de los fotones, integración de la carga y transformación de la misma.

Los tipos anteriores son las más comúnmente usadas, a continuación, mencionaremos otro tipos con usos muy particulares:

- Cámaras 3D: Permiten hacer medidas de formas en 3D a diferentes velocidades.
- Cámaras Infrarrojas / Cámaras Térmicas: capturan radiación infrarroja con la que podemos determinar la temperatura de objetos o cuerpos.
- Cámaras Alta Velocidad: Se utilizan cuando los procesos son muy rápidos.

## **2.4 Usos de la visión por computador**

Como hemos podido comprobar, la visión por computador o visión artificial ha avanzado mucho en los últimos años tanto por el número de estudios realizados como por el avance de la tecnología que permitía nuevos métodos. Este avance se ha traducido en que muchos campos han decidido utilizar esta herramienta. Los campos genéricos más destacables son los siguientes:

### **Medicina**

En lo que respecta a la medicina se han abierto muchas ramas de investigación que usan la visión por computador, en muchas de ellas la visión por computador se usa, básicamente, para analizar miles y miles de radiografías, ecografías, mamografías, etcétera... y conseguir identificar los factores de riesgo de forma anticipada y automática, es decir, detección sin ayuda de intervención humana. Por ejemplo, en las enfermedades cardiovasculares, usando fotografías de fondo de retina [4].

### **Agricultura**

Como sabemos en la agricultura cuanto más óptimo sea el uso de los recursos mejor será la calidad obtenida y, obviamente, habrá un ahorro económico. Por ejemplo, podemos optimizar la cantidad y el tipo de herbicida que aplicamos a una hoja u otra dependiendo del tipo de hoja que se trate, ahí es donde toma relevancia la visión por computador [5].

## Industria

Al hablar a nivel general, podemos decir que este campo es el que más usos le da a la visión por computador actualmente. Hay muchas actividades que se realizaban por personas ya que se necesitaba su criterio para la correcta realización de la actividad. Ahora tenemos los medios necesarios para conseguir un entorno de trabajo perfecto para el uso de la visión artificial. Por ejemplo, a la hora de verificar frutas o productos manufacturados podemos comprobar si cumplen con los criterios de calidad establecidos, evitando los posibles gastos si el producto llega al cliente con defectos y demás [6].

Queda claro que los resultados son muy buenos, el único pero que se le puede poner es que el entorno está muy controlado, porque la cámara o método de captación usado depende mucho de la iluminación exterior. Pueden cambiar totalmente los resultados en función de una variación en la iluminación que dificulte leer una característica determinada.

## Seguridad

Partiendo de que el número de cámaras de seguridad ha aumentado exponencialmente en los últimos años, ya sea para seguridad en empresas, zonas públicas o edificios, y que no es posible tener a un operario controlando todas esas cámaras, la visión por computador adquiere un protagonismo enorme en este campo.

A través de secuencias de imágenes se puede realizar vigilancia para detectar la presencia y movimiento de cuerpos extraños, el seguimiento de personas o coches o su identificación. [7]

## Automoción

En los últimos años, la conducción autónoma ha adquirido una importancia muy relevante, los avances en tecnología, como sensores, y en visión por computador han hecho que esto pase.

El uso de la visión artificial se centra en la detección de carriles, detección de seres humanos y detección de objetos. Lo que se busca conseguir es que sea capaz de analizar todo el entorno a todos los niveles y actuar en consecuencia [8].



Ilustración 3. Simulación de la conducción de un coche autónomo.

## Robótica

Los primeros usos de los robots eran para manipular, es decir, realizar acciones precisas, rápidas y repetitivas en un entorno cerrado. No eran capaces de tomar una decisión como tal, eran sistemas completamente planificados con antelación. Pero hay acciones que aparte de tener esas cualidades deben tener un cierto criterio para funcionar bien de forma autónoma, esto se consigue

obteniendo información del entorno y uno de los mecanismos para ello es la visión por computador. [9]

Una vez provistos los robots con las herramientas necesarias para captura y procesamiento de imágenes, se ha hecho notar otra vez la iluminación como condicionante más importante. En este campo los entornos reales no son muy controlados, desde que la cantidad de luz de la escena depende de la hora del día o por donde se mueva el robot. Ya hemos visto este problema en los coches autónomos.

### Reconocimiento de objetos

Podemos hablar de la capacidad humana, aunque no somos la única especie capaz, para poder distinguir un objeto no solo por su forma sino también por su textura y color. Somos capaces de hacerlo sin importar la colocación, la distancia o tamaño. Mas adelante profundizaremos más en la textura y el color, ya que son los instrumentos que usaremos para la aplicación que se va a desarrollar en esta investigación.

## **2.5 Descriptores de imagen**

Uno de los pasos fundamentales en la visión por computador es la descripción de objetos. Su objetivo es extraer una descripción matemática para cada objeto detectado en la imagen que nos permita más adelante clasificar esos objetos, básicamente generamos un vector de características que defina de forma única cada uno de los objetos. La descripción debe ser única, completa, invariante frente a transformaciones geométricas y sensible, con esto último nos referimos a la capacidad de mostrar la diferencia entre objetos similares.

Existen numerosas técnicas de descripción que podemos clasificar en cuatro grandes grupos: descripción de contorno, descripción de región, descripción global y descripción de puntos característicos. Centrándonos en los descriptores de región, que se basan en la parte interior de los objetos, tenemos tres tipos

de descriptores de región: momentos geométricos, descriptores topológicos y textura. Vamos a profundizar más en este último debido a su relevancia en el proyecto.

### **2.5.1 Textura**

La textura es un fenómeno muy amplio, de ahí que su definición sea complicada a pesar de que parece tan fácil de reconocer. Por ejemplo, es tan relativo que una foto de una hoja sola sería un objeto, pero una foto de una copa de un árbol, que son miles de hojas, sería una textura. Es común que una gran cantidad de objetos pequeños sean considerados como textura. También es común que muchas superficies que tienen patrones ordenados parezcan muchos objetos pequeños.

Los problemas más comunes relacionados con la textura son:

- La segmentación de textura: es el problema de dividir una imagen en componentes que dentro de ella tienen textura constante.
- Síntesis de la textura: busca la formación de grandes regiones de textura partiendo de pequeñas imágenes de ejemplo.
- Forma a partir de la textura: involucra la recuperación de la orientación de la superficie o la forma de la superficie desde la textura de una imagen.

Generalmente, las texturas de las imágenes consisten en patrones organizados de subelementos regulares, a veces llamados textones. Una de las maneras más comunes de intentar representar la textura es encontrar los textones, y entonces describir la manera en la que están dispuestos. Al no existir una regla clara no resulta fácil saber que debemos buscar. Así que utilizaremos elementos de patrones más simples, puntos y barras. La ventaja de esto es la facilidad para detectar estos elementos mediante el filtrado de la imagen. Así pues, si aplicamos filtros de puntos obtendremos una respuesta más fuerte en las pequeñas áreas que difieren de sus vecinos. Otro punto a

favor es que detectan las estructuras no orientadas. Por otro lado, los filtros de barras son orientados y tienden a responder a estructuras orientadas, esta propiedad es descrita como análisis de la orientación o representación de la orientación. Los más usados son los filtros de puntos y barras por suma ponderada de gaussianos y puntos y barras por filtros de Gabor.

Este tipo de filtros presenta un problema computacional, el tener que practicar convoluciones a una imagen con un gran número de filtros en un rango de escalas, necesita demasiados recursos. La pirámide gaussiana reduce esta necesidad tratando sistemáticamente la escala submuestreando la imagen una vez ha sido suavizada, así no se procesa demasiada información redundante. Tiene un problema y es que almacena toda la siguiente capa de escala más fina. Para solucionar esto y buscar lo que realmente necesitamos, mantener almacenados los errores en la predicción, se originó la pirámide Laplaciana. Estas pirámides usan el hecho que una capa gruesa de la pirámide Gaussiana predice la aparición de una siguiente capa más fina. Entonces, si tenemos un operador de sobremuestreo que produzca una versión de una capa gruesa de la misma medida que la siguiente más fina, solo tendríamos que almacenar la diferencia entre la predicción y la propia capa.

$$P_{LAPLACIANO}(I)_m = P_{GAUSSIANO}(I)_m \quad (2.7.1)$$

$$P_{LAPLACIANO}(I)_k = P_{GAUSSIANO}(I)_k - S \uparrow (P_{GAUSSIANO}(I)_{k+1}) \quad (2.7.2)$$

$$P_{LAPLACIANO}(I)_m = (Id - S \uparrow S \downarrow G_\sigma)P_{GAUSSIANO}(I)_k \quad (2.7.3)$$

El problema con las pirámides Laplacianas está en que no contienen suficiente información para concluir algo sobre la textura de la imagen, ya que no es una representación explícita de la orientación de las líneas. Si cogemos cada capa y la descomponemos más, obteniendo una colección de componentes donde cada una representa una energía para cada orientación distinta. Cada componente puede ser considerado como la respuesta de un filtro orientado en una escala y orientación característica. Esto da lugar a la pirámide orientada. La estrategia

ideal es tener una colección de filtros que tengan respuesta orientada y donde la síntesis sea fácil. Podemos producir una colección de filtros para reconstruir una capa desde sus componentes involucrando filtrar una imagen una segunda vez con el mismo filtro.

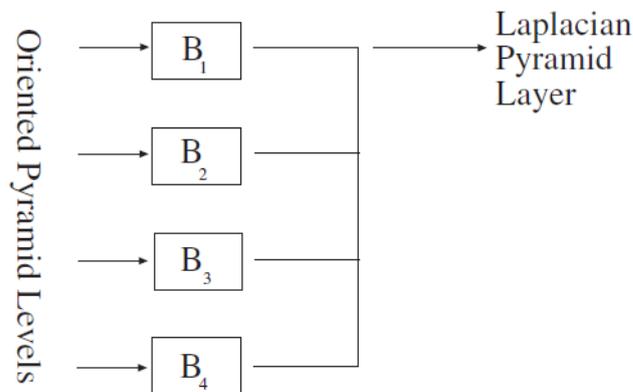


Ilustración 4. Sintetizar refiltrando las capas y añadiéndolas entonces.

La estrategia general para sintetizar texturas es pensar en ella como si fuera una muestra de alguna distribución probabilística, para después intentar obtener otras muestras desde la misma distribución. Asumiendo que la textura es homogénea. La distribución de probabilidad en valores de un píxel es determinada por las propiedades de algunos de sus vecinos, más que por la posición del propio píxel. Con esto, podemos construir un modelo para la textura fuera de los límites de la región de ejemplo, basadas en las propiedades de esta.

Hay diferentes maneras de sintetizar la textura, las más importantes son las siguientes:

- Síntesis por emparejamiento de los histogramas de las respuestas de que proporciona un filtro
- Síntesis por muestro de las densidades condicionales de las respuestas que proporciona un filtro
- Síntesis por muestreo de modelos locales

### **2.5.1.1 Tonos de la textura**

Ya sabemos que en el mundo real los objetos de una escena pueden cambiar de posición y/o orientación, si vemos un área de la imagen desde el frente o de lado, la textura no parece la misma. Este suceso sabemos que pasa porque al hacer una visión frontal la textura de los elementos se empequeñece y las acerca. Por ejemplo, teniendo una superficie con la misma textura, deberíamos tener la capacidad suficiente como para saber qué elementos están en una posición frontal y cuáles de lado, así podríamos recuperar el tono de la superficie.

Recuperando el tema de la homogeneidad, antes explicado, añadimos el concepto de textura isotrópica. En este nuevo concepto la probabilidad de encontrar un elemento de textura no depende de la orientación del elemento, es decir, el modelo probabilístico de la textura isotrópica no dependerá de la orientación del sistema de coordenadas del plano de la textura.

No todas las superficies que nos vamos a encontrar van a ser planas, pueden estar curvadas. Para poder recuperar información sobre la geometría diferencial de la superficie tenemos que asumir ciertas cosas. La primera, asumimos que la textura es homogénea, así si logramos conocer la configuración de uno de los planos tangentes a la superficie, seremos capaces de saber cómo es la textura frontalmente. Lo segundo que tenemos que asumir es que sabemos la configuración de uno de esos planos tangentes. Ahora vienen los inconvenientes. No sabemos la configuración de ninguno de los planos tangentes, así que necesitamos deducir las configuraciones relativas.

Para codificar numéricamente el concepto de textura existen diferentes algoritmos que explicaremos a continuación.

### **2.5.1.2 Algoritmos estadísticos**

En este tipo de algoritmo codificaremos la textura a partir del histograma,

recordamos que el histograma es una función de distribución de las intensidades de la imagen, es decir, cuantas veces se repite un nivel de intensidad en toda la imagen. A partir de los momentos del histograma podemos estimar un descriptor de textura. Se usan habitualmente el momento de primer orden (media), momento de segundo grado (varianza) que mide el contraste, momento de orden tres (sesgo) que mide la asimetría del histograma y momento de grado cuatro (curtosis) que mide la uniformidad del histograma. Por último, también debemos nombrar la entropía.

### **2.5.1.3 Patrones locales binarios**

Hoy en día la técnica más importante para clasificar texturas es el uso de los patrones binarios locales (LBP) [10]. Esta técnica ha ido evolucionando desde su propuesta original que la hace muy útil para los problemas modernos [11].

Centrándonos en el operador LBP original, podemos explicarlo como resultado de un análisis estadístico y estructural de la textura. El objetivo es codificar variaciones de intensidad (claro-oscuro) de forma binaria, la codificación viene en función de si el valor relativo dentro de un píxel en sus vecinos es más claro u oscuro. Por ejemplo, si a los ocho vecinos de un píxel les damos un número de 0 a 7 y si el píxel central es más claro u oscuro que el píxel vecino se pondrá un 0 en la posición que marque la etiqueta puesta previamente a ese píxel vecino dentro de un vector de tamaño 8, si sucede al revés en lugar de un 0 se pondrá un 1. Una vez tengamos las 8 posiciones, calculamos el valor en decimal. Como descriptor se utiliza el histograma del LBP de la imagen resultante. Este tipo de codificaciones son invariantes a la traslación y a los cambios monotónicos del nivel de gris, ya que siempre calculamos valores relativos de un píxel a sus vecinos.

Una de las mejoras aplicadas a esta primera idea es una combinación ortogonal de LBPs. Para reducir las dimensiones del histograma LBP podemos considerar una menor cantidad de píxeles vecinos. Esta disminución en los píxeles también supone una disminución de la capacidad discriminante de la

característica LBP. En conclusión, necesitamos llegar a un compromiso entre la reducción de las dimensiones del histograma LBP y su capacidad discriminante [12].

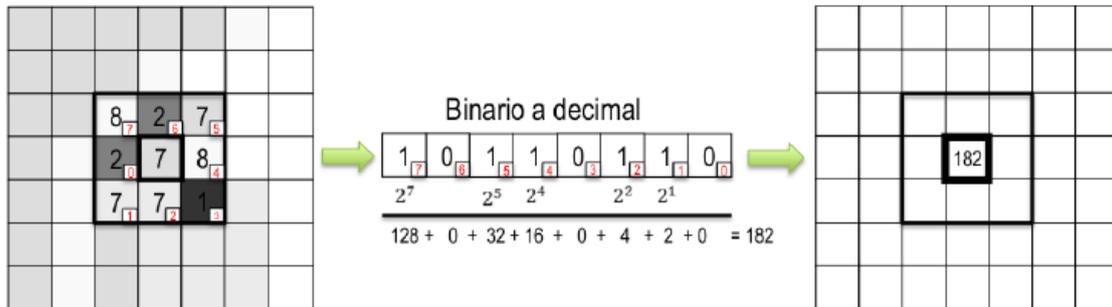


Ilustración 5. Funcionamiento del LBP original

### 2.5.1.4 Matriz de coocurrencia

Usamos la matriz de concurrencia para extraer información de la textura sobre la transición del nivel de gris entre dos píxeles. Dada una relación espacial definida entre los píxeles en una textura, la matriz representa la distribución conjunta de pares de nivel de gris de los píxeles vecinos. Si modificamos la relación espacial, como la orientación o la distancia entre píxeles, las matrices darán información diferente a cada cambio. Los descriptores se extraen de esas matrices.

El número de filas y columnas de la matriz de coocurrencia solo depende de los niveles de gris en la textura y no en el tamaño de la imagen. La matriz de coocurrencia tiene un elemento,  $P(m, n)$ , que indica el número de transiciones entre el nivel de gris de  $m$  y el de  $n$  que tiene lugar en la textura según la relación espacial dada. Es habitual cuantificar el valor de intensidad del nivel de gris para reducir el tamaño de la matriz de coocurrencia.

## 2.6 Color

Como bien sabemos ya, las imágenes poseen unas características que nos sirven a nosotros para su análisis. Para lograr entender con profundidad esta característica tenemos que empezar por su naturaleza.

Empecemos hablando de la luz, la luz tiene un comportamiento un tanto extraño llamado dualidad onda corpúsculo. Esto quiere decir que muchas partículas pueden exhibir comportamientos característicos de ondas en unos experimentos mientras en otros experimentos aparecen como partículas compactas y localizadas. Cuando se comporta como corpúsculo está compuesta por fotones que emiten y absorben energía y, cuando se comporta como onda los campos magnéticos y eléctricos interactúan en ángulos rectos. Estos campos se intercalan transversalmente y le imprimen movimiento a la onda.

El color de las superficies es resultado de una gran variedad de mecanismos, incluyendo la absorción diferencial a diferentes longitudes de onda, refracción, difracción y dispersión del grosor. El color de la luz que regresa a nuestros ojos está afectado por la radiancia espectral del iluminante y por la reflectancia espectral de la superficie. Existen cuerpos que no reflejan la luz, es decir, absorbe toda la luz y toda la energía radiante que incide sobre él, estos cuerpos son llamados comúnmente como cuerpos negros.

La fuente de luz más importante es el sol, el color de la luz del sol varía con el tiempo y con la época del año, es por ello que es un factor muy importante a tener en cuenta. Otro factor es el cielo, otra fuente de luz natural. La luz del sol que es dispersada por el aire hace que el cielo sea luminoso, esto hace también que sea más luminoso en el horizonte que en el cenit. Ya se ha hablado de la relevancia de la iluminación anteriormente, en este caso pasaría lo mismo, podríamos llegar a ver el mismo objeto de diferente color cuando lo observemos bajo distintas fuentes de luz.

### **2.6.1 Percepción humana**

También es importante conocer como el ser humano es capaz de observar el color, somos capaces de distinguir miles de objetos de distintos colores mientras que solo somos capaces de distinguir cien distintos tonos de gris. El ojo humano es sensible a las radiaciones electromagnéticas de entre 380 nm y 780 nm, este rango conforma el espectro visible de colores. Ya sabemos que las fuentes de luz emiten radiación con diferentes longitudes de onda, a su vez el objeto refleja otra distribución de longitudes de onda. Nuestros fotorreceptores son sensibles a determinadas longitudes de onda y esos estímulos se envían al cerebro y se genera una sensación de color. Para poder entender esto mejor, debemos hablar de la tricromatismo, cuando se realizaron pruebas de luz se notó que la mayoría solo necesitaba tres primarios para su realización. Los colores primarios deben ser independientes, es decir, ninguna posible mezcla entre dos de ellos puede generar el tercero.

Investigaciones anatómicas de la retina han concluido que existen dos tipos de células sensibles a la luz, solo son diferenciadas por su forma. Tenemos los conos que tienen forma aproximadamente cónica y los bastones que son aproximadamente cilíndricos. Los conos dominan prácticamente la visión de color y totalmente la fóvea. Hay tres tipos de conos con sensibilidades diferentes, tenemos los conos S, los conos M y los conos L.

### **2.6.2 Teoría de los colores opuestos**

Esta teoría fue propuesta por Ewald Hering, el cual defendía fielmente la idea de que el blanco y el amarillo no son sensaciones compuestas del color, sino que eran tan puras y primarias como la del resto de colores primarios. Entonces, propuso que la visión del color se producía por el emparejamiento de sensaciones de color, que operarían mediante procesos oponentes, es decir, cada uno de los receptores produciría dos tipos de respuestas antagónicas entre si. Por ejemplo, si cogemos uno de estos colores resulta más estimulado que su opuesto, entonces se verá el matiz correspondiente al superior. En

cambio, si son estimulados por igual se anulan por ser complementarios y aparece la sensación de gris. Los pares de colores son: azul-amarillo; rojo-verde; blanco-negro.

### **2.6.3 Representación del color**

Describir los colores de una manera precisa resulta vital, por ello resulta necesario un sistema estandarizado para hablar sobre el color. El tener que representar los colores de alguna forma estándar es el propósito de los modelos de color. La amplia mayoría de los modelos se han desarrollado para aplicaciones específicas.

#### **2.6.3.1 Modelos lineales**

Para representar el color existen mecanismos naturales: primero, debemos elegir un conjunto estandarizado de colores primarios, y entonces describir cualquier color usando los colores primarios cada uno con una ponderación relativa sobre el total. Hacer un experimento de combinación cada vez que queramos describir un color puede llegar a ser práctico. Cuando mezclamos colores linealmente, podemos construir un sencillo algoritmo para determinar los pesos que deberían ser usados para combinar una fuente de alguna radiancia espectral conocida, dando un conjunto arreglado de primarios.

La radiancia espectral de la fuente puede ser considerada como una suma ponderada de unas fuentes de longitud de onda única, ya que la combinación de colores es lineal, la combinación de primarios que coincide con una suma ponderada de fuentes de longitud de onda única es obtenida por la combinación de primarios de cada una de las fuentes de longitud de onda única, y entonces añadir las ponderaciones. Si guardamos un registro de los pesos necesarios de colores primarios para emparejar una fuente de longitud de onda única, un conjunto de funciones de emparejamiento de color, podremos obtener los pesos usados para emparejar una radiancia espectral arbitraria.

Los problemas vienen precisamente por ahí, si los colores primarios son luces reales, al menos una de las funciones de emparejamiento de color será negativo para alguna longitud de onda. Esto implica que la combinación substractiva es necesaria para emparejar algunos colores, da igual el conjunto de primarios usados. Para solventarlo podríamos obligar a que las funciones fuesen positivas siempre, lo que garantiza que los primarios serán imaginarios, ya que para algunas longitudes de onda su radiancia espectral será negativa. Lo que vamos a hacer es comparar los pesos y decir si el color es similar o no, y esto es suficiente para conseguir las funciones de emparejamiento de colores. Muchos sistemas han sido estandarizados por la CIE (Comission international d'éclairage).

- Espacio de color CIE RGB: es un espacio de color tricromático cuyos colores primitivos tienen una única longitud de onda (rojo:700 nm; verde:543.1 nm; azul:438.5 nm). Es un modelo aditivo, es decir, especifica directamente la cantidad de primario que debe ser emitida para generar el color. Las imágenes RGB se dividirán en tres imágenes en niveles de gris independientes, cada una de ellas representa una componente de color: rojo (R), verde (G), azul (B). Para un uso más claro tenemos los coeficientes tricromáticos que comprimen toda la información de color en dos canales.

$$r = \frac{R}{R+G+B}; g = \frac{G}{R+G+B}; b = \frac{B}{R+G+B}; r + g + b = 1$$

Existe una variante de este modelo, el sRGB. Esta variante también es llamada corrección gamma y se trata de una corrección de los tres canales de la imagen sin modificar la información de color. Generan imágenes con más brillo que mejoran notablemente la visualización de las mismas.

- CIE espacio XYZ: las funciones de emparejamiento de colores son elegidas para ser siempre positivas, así que las coordenadas de

cualquier luz real son siempre positivas. Resulta imposible obtener las coordenadas X, Y y Z de los primarios ya que para algunas longitudes de onda el valor de su radiancia espectral es negativa. Dadas las funciones de coincidencia de color solo, una puede especificar las coordenadas XYZ de un color y por lo tanto describirlo. Como ya se ha visto con el espacio anterior, los espacios lineales permiten varias construcciones graficas de utilidad que son más difíciles de dibujar en 3D que en 2D, por eso lo más común es intersectar el espacio XYZ con el plano  $X+Y+Z=1$  y dibujar el resultado usando las coordenadas:

$$(x, y) = \left( \frac{X}{X+Y+Z}, \frac{Y}{X+Y+Z} \right)$$

El espacio XYZ es útil si nos interesa medir un color.

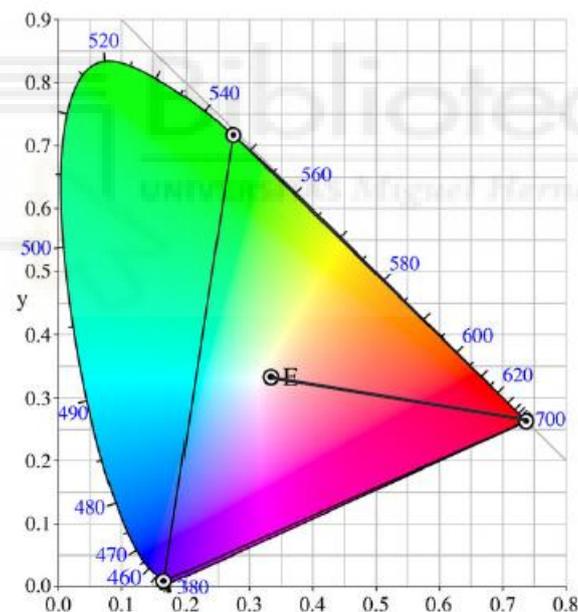


Ilustración 6. Representación del color: diagrama cromático xy

### 2.6.3.2 Modelos no lineales

Las coordenadas de un color en un espacio lineal pueden no necesariamente codificar propiedades que son comunes en el lenguaje o que son importantes

en las aplicaciones. Términos de color útiles incluyen: hue representa una característica asociada con la longitud de onda dominante en el color; saturación representa la pureza relativa entre el blanco y la longitud de onda dominante (hue). El blanco puro posee una saturación nula; luminosidad que es la propiedad que varía a su paso de blanco a negro.

Otra dificultad con los espacios lineales es que las coordenadas individuales no capturan las intuiciones humanas sobre la topología de los colores. Sabemos las relaciones locales de Hue o tinte, que existen, por ejemplo, el rojo cerca del violeta y naranja, el naranja cerca del rojo y amarillo, etcétera... Y cada una de estas relaciones locales funciona y pueden ser modeladas globalmente disponiéndolas en un círculo. Una vez explicado esto es obvio que no ninguna coordenada individual de un espacio de color lineal puede modelar hue, ya que la coordenada tiene un valor máximo el cual está muy lejos del valor mínimo.

Al explicar los modelos no lineales se ha explicado también el modelo HSI ya que este modelo fue el primero. Otro modelo que también se usa es el modelo HSV (Hue – Saturation - Value). Un método estándar para afrontar el problema que supone construir un espacio de color que refleje esas relaciones aplicando una transformación no lineal a espacio RGB. Un espacio capaz de eso es el HSV, el cual se obtiene mirando hacia abajo del centro de los ejes del cubo RGB. Lo logramos porque RGB es un espacio lineal, la luminosidad, el termino value en el espacio HSV, varía con la escala hacia fuera del origen y podemos

aplanar el cubo RGB para obtener un espacio 2D con un valor constante y, entonces para un mejor entendimiento lo transformamos en un hexágono.

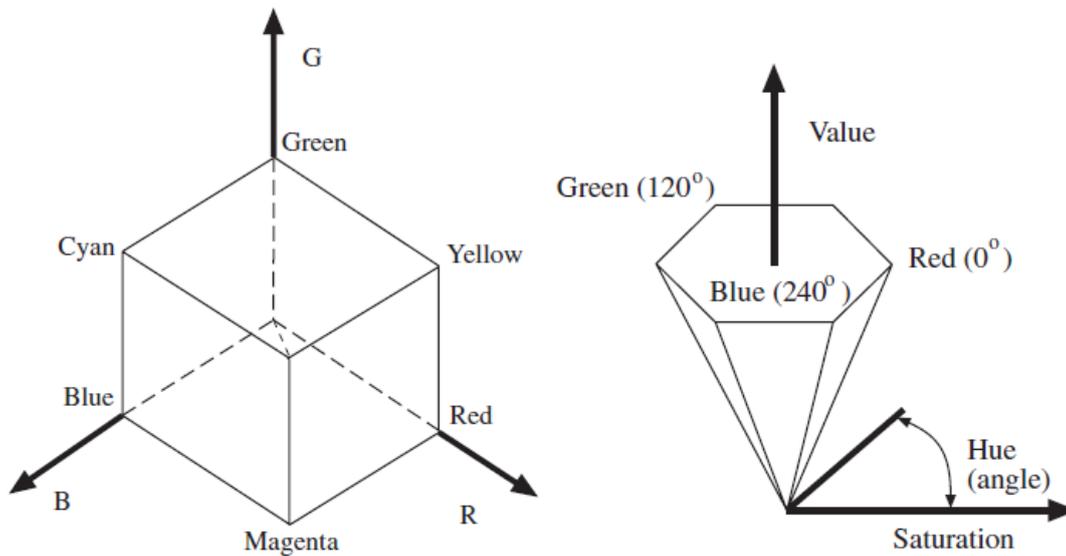


Ilustración 7. A la izquierda el cubo RGB. A la derecha el hexágono obtenido

### 2.6.3.3 Espacios uniformes de color

La mayoría de las veces no somos capaces de reproducir exactamente los colores. Con esto pongo en relevancia la importancia de conocer si la diferencia en un color sería notable para un ser humano que observa. Esto es útil para ser capaces de comparar la importancia de las pequeñas diferencias de color. Solo las diferencias realmente notables pueden ser detectadas modificando el color mostrado a un observador hasta que pueda decir que ha cambiado en comparación con el color original. Cuando esas diferencias son ilustradas en un espacio de color, forman el límite de una región de colores que son indistinguibles de los colores originales. Por ejemplo, en el espacio XY las elipses dependían bastante de donde en el espacio se producía la diferencia. Esto significa que la medida de diferencia en xy es un pésimo indicador de la importancia en la diferencia de color. Un espacio de color uniforme es uno donde la distancia en coordenadas espaciales es una justa guía de la importancia de la diferencia entre dos colores.

CIE LAB es prácticamente el espacio uniforme de color más universal. Las coordenadas de un color en LAB son obtenidas como un mapeo no lineal de las coordenadas XYZ. La principal razón para tener en consideración este espacio es que es sustancialmente uniforme y esto en algunos problemas es relevante, ya que en algunos resulta importante entender como de diferentes serán dos colores para un observador y las diferencias en coordenadas LAB proporcionan una buena guía.



Respecto al espacio CIE LUV, expresa la misma función de transformación que en LAB, pero con unos datos distintos. Primero calculamos la referencia al blanco y a partir de ahí calculamos LUV, el valor de L será calculado igual que

antes pero ahora usaremos u y v que expresan una relación diferente. Tiene una mayor relación entre la distancia real y la distancia perceptual de un color.

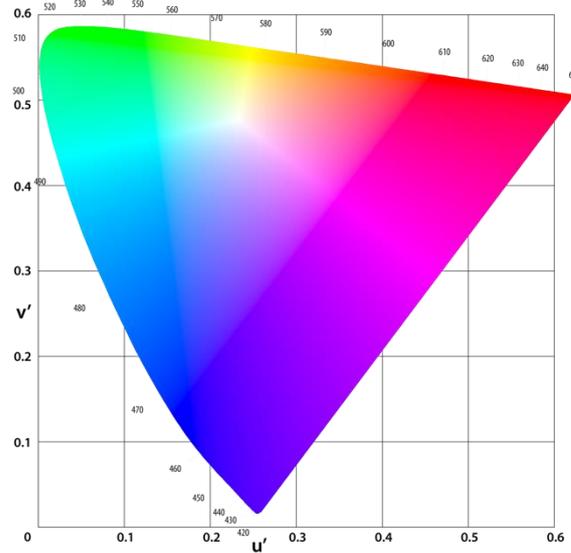


Ilustración 9. Representación espacio uniforme L\*u\*v\*

Función de transformación (para ambos modelos):

$$f(x) = \begin{cases} x^{1/3} & x > 0.0088 \\ 7.787x + \frac{16}{116} & x \leq 0.0088 \end{cases}$$

Siendo  $X_n$ ,  $Y_n$  y  $Z_n$  las coordenadas de referencia al blanco tenemos las siguientes funciones para obtener las coordenadas LAB y LUV:

$$L^* = 116f\left(\frac{Y}{Y_n}\right) - 16; \quad L \in [0 - 100]$$

$$a^* = 500 \left( f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right)$$

$$b^* = 200 \left( f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right)$$

$$u^* = 13L^*(u' - u'_n)$$

$$v^* = 13L^*(v' - v'_n)$$

$$u' = \frac{4X}{X+15Y+3Z}$$

$$v' = \frac{9Y}{X+15Y+3Z}$$

$$u'_n = \frac{4X_n}{X_n+15Y_n+3Z_n}$$

$$v'_n = \frac{9Y_n}{X_n + 15Y_n + 3Z_n}$$

## 2.7 Clasificadores

Otro de los pasos fundamentales en la visión por computador es el reconocimiento o clasificación de objetos. A partir del vector de características, obtenido en la parte de descripción de objetos, intentaremos clasificarlo asignándolo a un patrón previamente conocido que luego se agrupe en un grupo representativo (clases). Las características que forman el vector deben ser invariantes ante parámetros que pueden dar lugar a variaciones en la captura de la información de la imagen, tales como rotación, traslación, escala, cambios en la iluminación, oclusión y punto de vista. Las clases de objetos vienen dadas por una serie de muestras que las describen.

Las técnicas usadas se pueden dividir en dos: técnicas supervisada o técnicas no supervisadas. En la primera, asumimos que a cada muestra le hemos asignado una etiqueta manualmente que indica su clase. En los sistemas no supervisados no tienen esa información adicional. A continuación, hablaremos de los clasificadores más relevantes para nuestro proyecto.

### 2.7.1 Regresión logística

Debemos distinguir la regresión logística simple de la múltiple. La primera es un método de regresión que permite estimar la probabilidad de una variable cualitativa binaria en función de una variable cuantitativa [13]. Tiene diferentes usos, pero uno de los más importantes es la clasificación binaria, en esta aplicación las observaciones se clasifican en un grupo u otro dependiendo del valor que tome la variable empleada como predictor.

Para empezar, debemos definir la función sigmoide (logística):  $g(z) = \frac{1}{1+e^{-z}}$ .

Nuestra función de decisión será resultado de aplicar la función logística [14] al producto escalar del modelo (teta) transpuesto por el vector descripción (x). Al vector características le hemos añadido un 1 en su primera posición, este será el valor de sesgo. Recordando que el vector teta conforma el modelo, su primera posición, teta 0, servirá para tener modelos que no pasen por el origen.

Clasificaremos como clase 1 ( $y=1$ ) cuando el valor de probabilidad sea mayor que 0.5 y será de clase 0 ( $y=0$ ) cuando valga menos que 0.5. El valor de la clasificación final vendrá dado por  $y = (\theta^T \cdot x > 0)$ , esto conforma la regla de decisión lineal.

El problema de la regresión logística consiste en estimar el modelo teta a partir de los datos obtenidos anteriormente con medidas del vector de descripción y con un etiquetado previo a esas medidas. Creamos dos vectores por filas, uno en el que almacenaremos cada vector de descripción obtenido de la imagen extendido, con extendido me refiero a la adición del 1. El otro vector contendrá el etiquetado, bien 0 o bien 1. Aparte de estos dos vectores, tendremos el vector teta, que contendrá los parámetros del modelo que nos permitirá estimar el modelo de regresión logística. Para generar el vector del modelo necesitamos una función de coste que nos diga si un valor de teta es correcto o no. La función de coste trata de ir acumulando los errores que cometemos en cada predicción, tanto para  $y=1$  e  $y=0$ . También hay un término de regularización, afecta a todos los valores de teta salvo al primero, que es el sesgo. Este termino busca simplificar el modelo, que los valores de teta sean pequeños.

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m [y^{(i)} \log(h_{\theta}(x^{(i)})) + (1 - y^{(i)}) \log(1 - h_{\theta}(x^{(i)}))] + \lambda \sum_{j=1}^n \theta_j^2$$

El primer termino corresponde a los errores que cometemos en las muestras etiquetadas como 1, es decir, los errores que cometemos cuando predecimos una muestra que esta etiquetada como 1. El segundo termino expresa lo mismo que la anterior, pero para las muestras etiquetadas como 0. El ultimo termino

es el de regularización, afecta a todos los valores del modelo salvo al primero, el sesgo. Con la regularización controlaremos el sobreajuste del sistema.

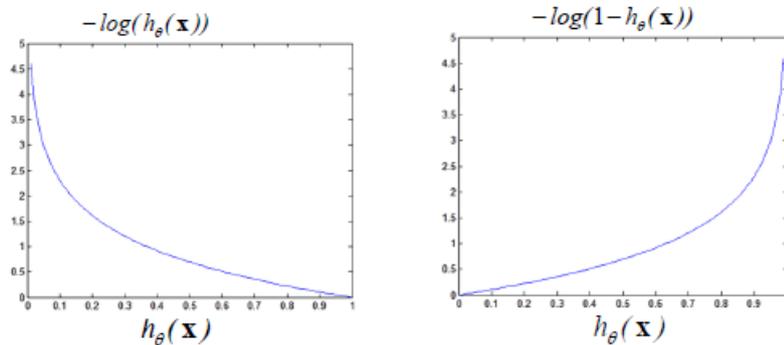


Ilustración 10. La grafica de la derecha corresponde al primer término de la ecuación 1 y la segunda corresponde al segundo término.

Con la función de coste estimaremos diferentes valores de teta. Usaremos el método del gradiente, que es un método iterativo, que busca es ir ajustando el valor de teta buscando el valor mínimo. Lo que calcula es el valor de la derivada del valor de J para cada una de las variables tetas y nos moveremos a partir de un punto inicial en la dirección contraria al gradiente. Usaremos un factor alfa, factor de aprendizaje, que nos hará ir más rápido o más lento. La función en si es:  $\theta^{t+1} = \theta^t - \alpha \nabla_{\theta} J(\theta)$ .

Si queremos implementar reglas más complejas a las lineales, tendremos que añadir nuevas variables con componentes polinómicas con otra descripción. Por ejemplo,  $x = [1 \ x_1 \ x_2]^T \rightarrow x' = [1 \ x_1 \ x_2 \ (x_1)^2 \ (x_2)^2 \ x_1 * x_2]^T = [x_1 \ x_2 \ x_3 \ x_4 \ x_5]^T$ . Esto puede generar problemas de sobreajuste. En cualquier caso, con este tipo de mecanismos implementaremos reglas de separación que en vez de ser rectas serán curvas polinómicas, para separar mejor los datos.

Cuando tenemos más de un objeto, clasificación multiclase, usamos la técnica de 'Uno contra todos', la idea es que el vector de etiquetas puede tener valores hasta d. Se divide en d problemas de clasificación binaria, agrupamos los valores de las diferentes etiquetas. Calcularemos la función de predicción para cada objeto y escogeremos como predicción la de máxima probabilidad.

Usamos la matriz de confusión que es una matriz de datos que va contando valores de aciertos y fallos. En las columnas tendremos las clases predichas, y en filas las clases reales.

### **2.7.2 SVM (Maquinas de Vector Soporte)**

La base es similar a la regresión logística, pero plantea algunas diferencias. Por ejemplo, la función de coste se simplifica, mejora el proceso de separación entre las clases y, la aportación más importante, el concepto de kernel que es la transformación de los datos del conjunto en un nuevo espacio de características donde las clases sean separables y luego se deshace ese cambio. Se proyecta cada vector de datos  $x$  sobre un conjunto de puntos en el espacio de características (vectores soporte) a través del kernel. Permite reglas de decisión no lineales sin necesidad incrementar el tamaño del espacio de características [15]. Un requisito fundamental es que los datos deben estar escalados y normalizados. La regla de decisión determina que será 1 una cuando  $\theta^T \cdot x \geq 0$  y será 0 cuando  $\theta^T \cdot x < 0$ .

También tenemos una función de coste, pero esta vez el coeficiente de regularización es  $C$  que es la inversa de  $\alpha$ . Por lo demás seguimos teniendo un termino de coste para cuándo  $y=1$  y cuando  $y=0$ . Este clasificador maximiza el margen de separación entre clases.

Como ya hemos mencionado antes, detenemos una transformación mediante kernels y vectores soporte. Tenemos el kernel lineal, el kernel Gaussiano y kernel polinómico. Profundizando el kernel Gaussiano transforma los datos  $x$  y lo transforma en un vector  $f$  que está formado por un conjunto que son la proyección sobre los vectores soporte. Obtenemos una nueva función de decisión  $h_{\theta}(x) = \theta^T \cdot f > 0$ , y también tenemos una nueva función de coste.

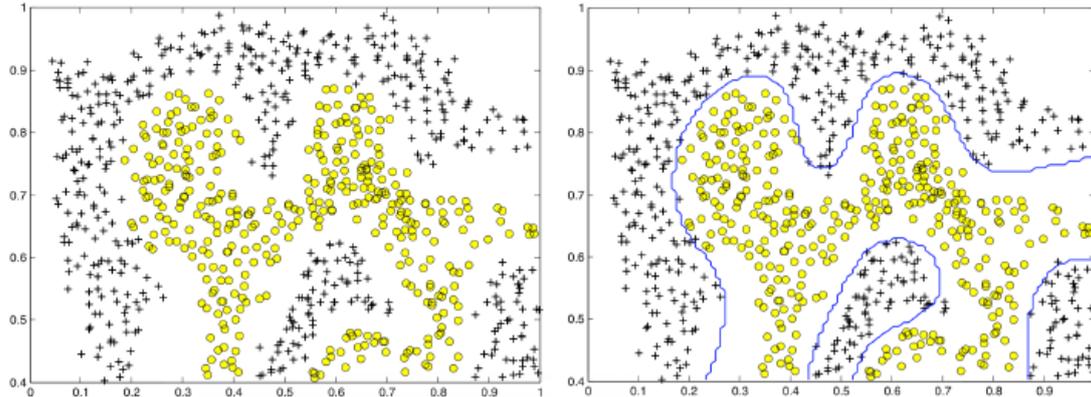


Ilustración 11. Ejemplo kernel Gaussiano.

### 2.7.3 Vecino más cercano

Este tipo de clasificador no requiere modelo, utilizan directamente las muestras como modelo del propio clasificador, es decir, cuando tenemos que clasificar una nueva muestra debemos tener todos los datos que hemos utilizado para generar etiquetados con anterioridad para crear el modelo. Para poder clasificar un nuevo dato buscaremos los vecinos más cercanos, para ello usaremos el algoritmo K-NN. Tenemos que generar una esfera alrededor de la nueva muestra y contar el número de muestras de los vecinos más cercanos que estén dentro. El valor de K especifica el número mínimo que debemos tener dentro de la esfera, la esfera crecerá hasta que haya ese número. Para medir las distancias a todos los vecinos, nos apoyamos en la distancia euclídea, que es la distancia "ordinaria" entre dos puntos de un espacio euclídeo, la cual se deduce a partir del teorema de Pitágoras. Esta distancia solo se puede usar si los valores están normalizados, sino usamos la distancia de Mahalanobis. Su

utilidad radica en que es una forma de determinar la similitud entre variables aleatorias multidimensionales. Se diferencia de la distancia euclídea en que tiene en cuenta la correlación entre las variables aleatorias, esta distancia está normalizada según varianza.

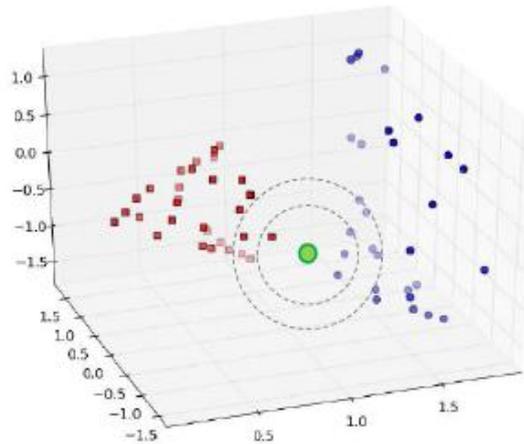


Ilustración 12. Ejemplo del método de reconocimiento del vecino más cercano.

## 2.7.4 Redes neuronales

Es una técnica que en la actualidad está siendo muy utilizada. Una red neuronal es una estructura de procesamiento de información paralela y distribuida, que intenta emular, dentro de las limitaciones propias de la tecnología, las funciones computacionales elementales de la red nerviosa del cerebro humano, en base a la interconexión de multitud de elementos de procesamiento, cada uno de los cuales presenta un comportamiento completamente local. Fundamentalmente es un Mecanismo o procedimiento matemático que transforma un conjunto de variables numéricas (entradas) en un conjunto de variables numéricas (salidas). Hay interconexiones entre diferentes objetos que llamaremos neuronas. De forma general, tenemos un conjunto de entradas de la red neuronal que están sometidas a un peso ajustable ( $w_i$ ) diferente. Todos esos datos ya escalados se acumulan mediante un sumador que también se le añade un valor de sesgo ( $\theta$ ). El valor resultante se pasa a través de una transformación mediante una función de transferencia que tiende a saturar la salida y generar la salida de la red neuronal.  $SALIDA(a) = f(\sum_{i=1}^n w_i x_i - \theta)$ .

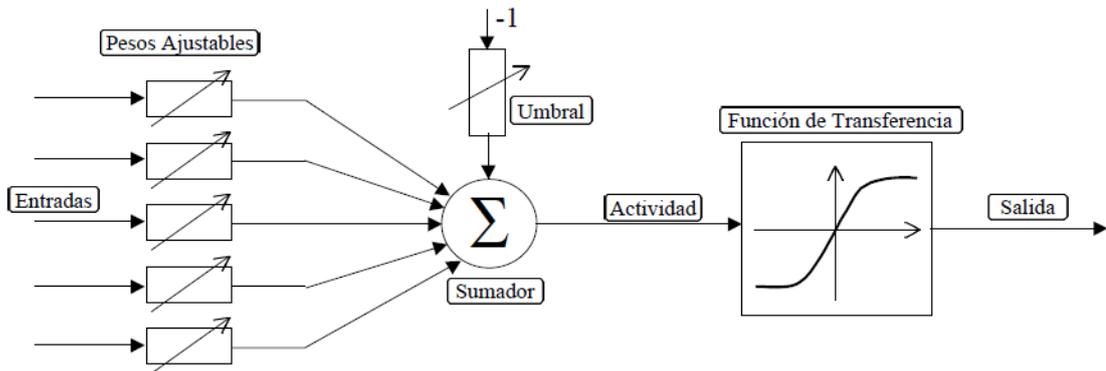


Ilustración 13. Modelo básico del funcionamiento de una neurona.

La clave de este modelo está en combinar múltiples neuronas conectadas entre sí, esta cooperación es la que produce las respuestas complejas. Por lo tanto, vamos a agrupar en capas las neuronas de la red, y conectar las capas entre sí formando un sistema masivamente paralelo. Intentando emular el comportamiento neuronal humano, tenemos la memoria a corto plazo viene dada por el nivel de actividad de cada neurona y la memoria a largo plazo está determinada por los valores de los pesos sinápticos que hemos asignado a cada una de las entradas de la red neuronal.

Una red neuronal no se programa, se entrena. Al entrenar buscamos calcular los pesos de cada una de las entradas para ajustar el comportamiento de las neuronas y determinar el grado de conexión entre las neuronas de la red. Tenemos dos tipos de aprendizaje: el aprendizaje supervisado donde dando muestras a la entrada y a la salida le damos la etiqueta correcta que debería tener el resultado. Por otro lado, tenemos el aprendizaje no supervisado donde los datos suministrados son vectores de descripción donde obtendremos clases con los datos agrupados.

Existen distintos tipos de redes neuronales:

- Redes unidireccionales (Feedforward Networks): básicamente transformamos de un conjunto de datos especificado en otro especificado que es el que realmente queremos. Tiene una

arquitectura típica de una red multicapa. El aprendizaje es supervisado y tiene lugar a través de un proceso de ajuste de los pesos sinápticos de las neuronas de la red.

- Redes recurrentes (Feedback Networks): genera memoria asociativa, es decir, asocia a memorias previas la clasificación de una muestra futura. La red funciona como un sistema dinámico, es decir, la salida de unas neuronas son las entradas a otra, de ahí también se desprende que su arquitectura típica sea de una red monocapa con realimentación.
- Redes autoorganizadas (self-organizing networks): se utilizan en técnicas no supervisadas cuando buscamos hacer clustering, es decir, buscamos los grupos más representativos dentro de un conjunto de datos. Cada neurona tiene un cierto grado de conexión con neuronas colaterales, es decir, neuronas que estén en la misma capa.

Una de las variantes más usadas de este tipo de clasificador son **las redes neuronales convolucionales (CNN)** [16]. La idea es que, en lugar de usar una compresión previa de las imágenes en un vector de descripción, se use la imagen completa para realizar la clasificación. Por lo tanto, la capa de entrada será la propia imagen. Si usásemos una red neuronal tradicional todas las neuronas utilizarían toda la imagen (explosión de parámetros) y esto sería muy costoso a nivel de cómputo. Con una CNN cada neurona actúa sobre una ventana (entorno de vecindad de cada píxel de la imagen). Las neuronas dentro del mismo nivel utilizan los mismos pesos para producir el mismo filtrado, mientras diferentes niveles de una capa realizan filtrados diferentes, es decir, cada nivel actúa como un filtro convolucional extrayendo características (la red aprende sus propias características). La red neuronal va aprendiendo el filtrado que debe realizar sobre la imagen para extraer los descriptores que se usaran en la etapa final de clasificación, esto requiere de un conjunto de

entrenamiento muy grande, por lo tanto, la clave de este algoritmo es la capacidad de procesamiento para entrenar mejor la red.

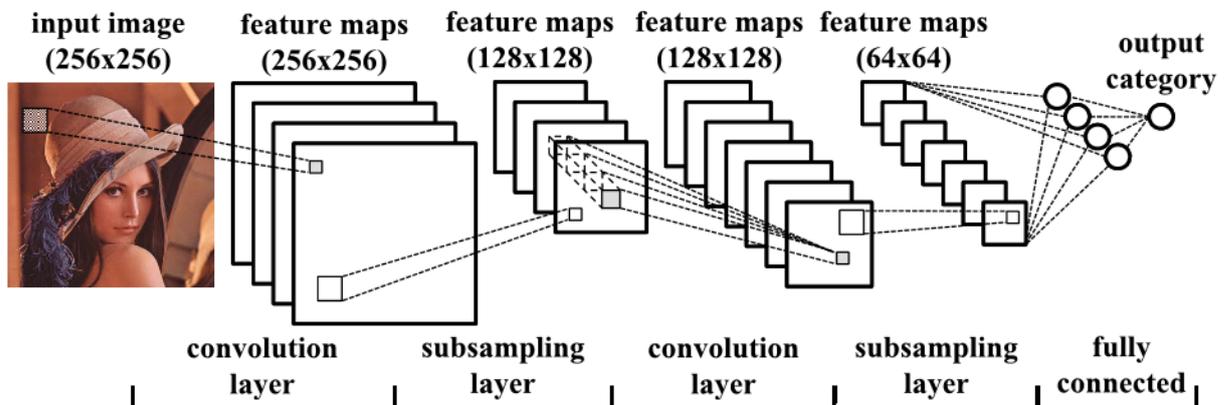


Ilustración 14. LeNET CNN

### 2.7.5 Árboles de decisión

Son métodos bastante sencillos que son muy útiles a la hora de trabajar con pocas muestras para hacer el entrenamiento. Representa funciones lógicas sencillas de decisión binaria, decidimos si en función de un umbral si una variable será clasificada en una dirección u otra. Está compuesto por una serie de nodos y ramas, donde los nodos representan las variables del vector de características y las ramas representan las reglas de decisión sobre esas variables. Los nodos finales o nodos hojas serán las clases con las que se hará la clasificación. Existen múltiples formas de inferir el árbol, tenemos la trivial que crea una ruta del árbol por cada instancia de entrenamiento, pero esto da arboles demasiado grandes y no funcionan bien con instancias nuevas. También tenemos la forma óptima que obtiene el árbol más pequeño posible compatible con todas las instancias, pero en términos de cómputo esto no es viable. Por último, la forma pseudo-óptima, en esta la selección de atributo en cada nivel del árbol es en función de la calidad de la división que se produce. El algoritmo de este tipo más común es el algoritmo Greedy que clasifica por votación. Básicamente, partimos de los datos originales etiquetados y se hace una primera clasificación con una de las características, calculando el umbral que mejor separa esa característica. Si el error de clasificación es pequeño

finalizar la rama con una predicción y si es grande se selecciona una nueva característica.

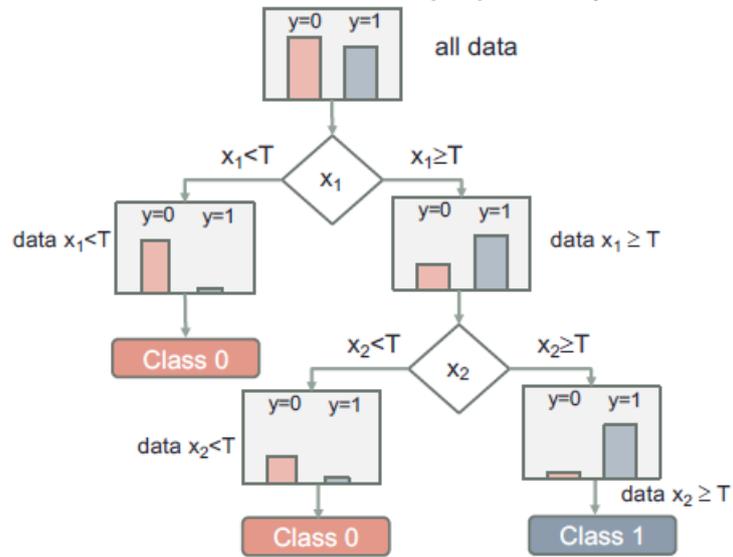


Ilustración 15. Algoritmo de Greddy



## 3. Material y métodos

En esta sección se explicarán los distintos pasos que he seguido a lo largo del trabajo hasta la obtención de los resultados que serán expuesto en el capítulo 4. En primer lugar, hablaremos de las bases de datos y en la manera en que han sido utilizadas para la realización de las pruebas. Después, ahondaremos en los distintos espacios de color que utilizaremos, centrándonos en cómo son y como los usaremos. A continuación, especificaremos las configuraciones de los distintos descriptores que he empleado. Y, por último, hablaré de los clasificadores usados y sus distintas configuraciones.

### 3.1 Data sets

Usaremos distintos data sets con el objetivo de que los resultados no se vean sesgados por la manera en que estos data sets han sido obtenidos. Además, hablaremos de como los hemos usado para un análisis más completo.

#### 3.1.1 SIPI rotated texture [19]

Este data set está constituido por trece clases de textura de Brodatz, que a su vez son siete de cada tipo, pero rotados con diferentes ángulos: 0, 30, 60, 90, 120, 150, y 200 grados. Todas las imágenes tienen las mismas dimensiones: 512x512 píxeles con 8 bits/píxel.

Las clases son: *bark, brick, bubbles, grass, leather, pigskin, raffia, sand, straw, water, weave, wood y wool.*

Este data set será usado para evaluar la escala de grises a la hora de clasificar texturas.

#### 3.1.2 ALOT (Amsterdam library of textures [20])

Uno de los data sets más completos a los que se puede acceder. Consta de imágenes a diferentes escalas y rotaciones. Tiene doscientas cincuenta clases

de texturas y cada clase tienes 28 imágenes cuyas dimensiones son: 768x512, 768x47 o 768x330.

Usaremos este data set para la evaluación de los distintos espacios de color cuando se necesita de hacer un análisis textural.

### **3.1.3 DTD (Describable Textures Dataset [21])**

Esta base de datos de texturas contiene 5640 imágenes, organizadas en 47 clases inspiradas en la percepción humana. Por cada clase hay 120 imágenes. El tamaño de las imágenes varía entre 300x300 y 640x640 y se garantiza que como mínimo un 90% de la superficie representa el atributo de la clase.

Esta base de datos será la segunda con la que probemos el análisis textural en diferentes espacios de color.

### **2.1.4 Uso general de las bases de datos**

Vamos a usar las imágenes de diferentes maneras, para conseguir concluir cual puede ser el mejor a la hora de coger muestras. Empezaremos usando la imagen en sí, es decir, si la imagen es 512x512 usamos todos los píxeles. Otra manera será la de dividir la imagen en ventanas, cada imagen se dividirá en los distintos tamaños de la ventana. Tenemos ventanas cuadradas, empezaremos con una ventana, luego cuatro ventanas, después dieciséis ventanas y, por último, en sesenta y cuatro ventanas. Otra disposición de las ventanas será dividir en columnas o filas, por ejemplo, si la imagen es de 512x512 y dividimos por filas, tendremos una ventana de  $(512/n^{\circ} \text{ de divisiones}) \times 512$ . Tendremos ventanas, ya sean divididas por filas o columnas, divididas en ocho, dieciséis y treinta y dos.

Cada ventana será considerada como una muestra, es decir, sacaremos las características propias de cada ventana para su posterior uso.

## 3.2 Espacios de color

Debemos tener presente que se realizara el proceso para diferentes espacios de color, por ello debemos incidir más ampliamente en estos también. Usaremos los siguientes espacios:

- Escala de grises: en la adquisición de imágenes debemos convertir a digital la señal analógica transmitida por la cámara, por ellos se realiza un muestreo de las coordenadas espaciales y una digitalización en niveles de gris. La resolución final de la imagen depende del muestreo espacial que apliquemos. Respecto a la digitalización, hablaremos de la cuantificación, daremos un valor número a la luminosidad en el píxel. Trabajaremos en ocho bits, ya que nos dan 256 niveles de intensidad.



Ilustración 16. Ejemplo de variación del muestreo espacial

Ilustración 17. Ejemplo de la variación del número de bits en la digitalización

- RGB: es el espacio de color usado normalmente. Otros espacios de color son calculados a partir del espacio RGB mediante transformaciones tanto no lineales como lineales. Para reducir la sensibilidad de las imágenes RGB a la orientación de la superficie, la luminosidad y otras condiciones fotográficas, se define un espacio rgb que es el resultado de normalizar los componentes R, G y B:

$$r = \frac{R}{R + G + B}$$
$$g = \frac{G}{R + G + B}$$

$$b = \frac{B}{R + G + B}$$

A causa de la normalización, g y r son invariantes a escala y, por lo tanto, invariantes a la luz, cambios de intensidad, sombras y tono [17].

- Colores opuestos: este espacio de color [18] tiene tres canales: L, C1 y C2. Los colores primarios de este modelo están basados en los tres ejes opuestos psicológicos fundamentales: blanco-negro, rojo-verde, y amarillo- azul. La información del color queda almacenada en C1 y C2. El rango de valores de C1 es [-1,1] y el de C2 es [-0.8660,0.8660]. Por último, el canal L contiene información sobre la luminosidad y su rango de valores es [0,1]. Las fórmulas de cambio de espacio de color de RGB a colores opuesto son:

$$O1 = \frac{(R - G)}{\sqrt{2}}$$

$$O2 = \frac{R + G - 2B}{\sqrt{6}}$$

$$L = \frac{R + G + B}{\sqrt{3}}$$

- HSV: este espacio de color viene motivado por el sistema de visión humano, ya que los seres humanos describimos el color mediante el tono (H), saturación (S) y brillo (V). La crominancia queda definida en los canales de tono y saturación, mientras la intensidad o valor especifica la luminosidad. Para cambiar del espacio de color RGB al HSV tenemos que las siguientes formulas:

$$LET \begin{cases} MAX = \max(R, G, B) \\ MIN = \min(R, G, B) \\ \delta \end{cases}$$

$$v = MAX$$

$$S = \begin{cases} \frac{\delta}{MAX} & \text{if } MAX \neq 0 \\ 0 & \text{if } MAX = 0 \end{cases}$$

$$H = \begin{cases} 60\left(\frac{G - B}{\delta}\right) & \text{if } MAX = R \\ 60\left(\frac{B - R}{\delta} + 2\right) & \text{if } MAX = G \\ 60\left(\frac{R - G}{\delta} + 4\right) & \text{if } MAX = B \\ \text{not defined} & \text{if } MAX = 0 \end{cases}$$

- Lab: es un espacio uniforme de color, en el que la información cromática queda almacenada en dos canales (a y b), y la información a cerca de la luminosidad está en otro canal (L). Este espacio es relativo al espacio XYZ, por lo tanto, para poder calcularlo debemos primero pasar de RGB a XYZ y, entonces, de XYZ a Lab.

Primero debemos normalizar los valores RGB:

$$\begin{aligned} var\_R &= (R/255) \\ var\_G &= (G/255) \\ var\_B &= (B/255) \end{aligned}$$

$$\begin{aligned} var\_R &= \begin{cases} (((var\_R + 0.055)/1.055)/1.055)^{2.4} & var\_R > 0.04045 \\ var\_R / 12.92 & var\_R \leq 0.04045 \end{cases} \\ var\_G &= \begin{cases} (((var\_G + 0.055)/1.055)/1.055)^{2.4} & var\_G > 0.04045 \\ var\_G / 12.92 & var\_G \leq 0.04045 \end{cases} \\ var\_B &= \begin{cases} (((var\_B + 0.055)/1.055)/1.055)^{2.4} & var\_B > 0.04045 \\ var\_B / 12.92 & var\_B \leq 0.04045 \end{cases} \end{aligned}$$

Escalamos lo valores =

$$\begin{aligned} var\_R &= var\_R * 100 \\ var\_G &= var\_G * 100 \\ var\_B &= var\_B * 100 \end{aligned}$$

$$X = var\_R * 0.4124 + var\_G * 0.3576 + var\_B * 0.1805$$

$$Y = var\_R * 0.2126 + var\_G * 0.7152 + var\_B * 0.0722$$

$$Z = var\_R * 0.0193 + var\_G * 0.1192 + var\_B * 0.9505$$

Una vez hecha esta transformación procedemos a hacer la propia para el espacio Lab ((Xn, Yn,Zn) son la referencia al blanco):

$$L = 116f\left(\frac{Y}{Yn}\right) - 16$$

$$a = 500\left(f\left(\frac{X}{Xn}\right) - f\left(\frac{Y}{Yn}\right)\right)$$

$$b = 200 \left( f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right)$$

$$f(x) = \begin{cases} x^{1/3} & x > 0.0088 \\ 7.787x + \frac{16}{116} & x \leq 0.0088 \end{cases}$$

### 3.3 Descriptores

Los distintos descriptores que voy a usar ya han sido mencionados anteriormente en el capítulo 2. Aquí explicaremos como los he usado con ayuda del programa de cálculo MATLAB.

#### 3.3.1 Momentos de histograma

Debo empezar recordando que los momentos de histograma que van desde primer orden hasta cuarto orden son: media, varianza, sesgo y curtosis. También usaremos la entropía para un análisis más completo.

Empezaremos calculando el histograma de la ventana gracias a las facilidades que ofrece 'Machine Vision Toolbox for MATLAB by Peter Corke' y el programa MATLAB en sí mismo. En el espacio de color de escala de gris cada muestra contiene cinco descriptores. Y en el resto de los espacios de color, como es lógico, tendremos quince descriptores.

#### 3.3.2 Matriz de coocurrencia

A la hora de usar este descriptor hay que tener presente que la información extraída se calcula por la transición del nivel de gris entre dos pixeles. Esta transición del nivel de gris puede darse de distintas combinaciones de la relación espacial, la orientación y la distancia entre pixeles. Para la obtención de la matriz de coocurrencia usare la función 'graycomatrix' de MATLAB con la siguiente configuración: el número de niveles de gris considerado será de 256

niveles, siendo en consecuencia el rango utilizado escalando la imagen de entrada en niveles de grises es de 0 a 255. La distancia entre el píxel de interés y su vecino será de un píxel con un ángulo de 0°. Y, por último, teniendo en cuenta que necesitaremos después la matriz simétrica podemos activar la opción de simetría que tiene la función, y eso hemos hecho.

Una vez tenemos la matriz de coocurrencia simétrica, debemos expresar esta matriz como probabilidad. Para ello usaremos la siguiente función:

$$C_{i,j} = \frac{P_{i,j}}{\sum_{i,j=0}^{N-1} P_{i,j}}$$

Donde:

- $i$  es el número de filas y  $j$  el número de columnas
- $P$  es el valor de la celda  $(i, j)$  en la ventana
- $C_{i,j}$  es la probabilidad en la celda  $i, j$
- $N$  es el número de filas o columnas

Ahora con la matriz de coocurrencia simétrica y normalizada podemos concluir ciertas propiedades:

- Los valores de la diagonal representan los pares de píxeles cuyos valores no tienen diferencias en su nivel de gris. Esto conlleva que, si estos valores son grandes, la imagen no muestra mucho contraste.
- Sumando los valores de la diagonal podemos obtener la probabilidad de que un píxel y su vecino tengan el mismo nivel de gris.
- Las líneas que son paralelas a la diagonal separadas una celda, representan los pares de píxeles con una diferencia de un nivel de gris. Entonces, conforme nos alejamos de la diagonal la diferencia entre niveles de grises es mayor.

De la matriz obtenida podemos derivar diferentes medidas, siendo estas los descriptores texturales. Las utilizadas son las siguientes:

- Inercia (o contraste): adquiere un valor elevado cuando la imagen tiene mucho contraste y tiene un valor bajo cuando los valores más altos de la matriz están cerca de la diagonal principal, básicamente es una medida de la variación local en la imagen.

$$C_1 = \sum_{i,j} (i - j)^2 * C_{i,j}$$

- Energía (o momento angular de segundo orden): es una medida de la homogeneidad local, da valores elevados cuando la matriz tiene pocas entradas de gran magnitud, y es baja cuando todas las entradas son similares, por ejemplo, si todos los pixeles son iguales la energía es mínima.

$$C_2 = \sum_{i,j} C_{i,j}^2$$

- Entropía: medimos la aleatoriedad de la imagen, el valor máximo es alcanzado cuando todos los elementos de la matriz de coocurrencia son idénticos.

$$C_3 = \sum_{i,j} -C_{i,j} * \log_2[C_{i,j}]$$

Se considera que  $0 * \log(0) = 0$ .

- Homogeneidad: el valor será alto cuando la matriz de coocurrencia se concentra a lo largo de la diagonal, esto sucederá cuando la imagen sea localmente homogénea.

$$C_4 = \sum_{i,j} \frac{C_{i,j}}{1 + (i - j)^2}$$

- Probabilidad máxima: el valor más elevado de que una transición ocurra.

$$C_5 = \max\{C_{i,j}\}$$

### 3.3.3 Patrones locales binarios (LBP)

Desde un punto de vista general, el funcionamiento de este descriptor se basa en que examina la ventana correspondiente dividiéndola en células. Después cada píxel de la célula es comparado con sus vecinos a una distancia determinada formando un círculo. Cuando el píxel central es mayor que el vecino ponemos un 0, cuando ocurra lo contrario pondremos un 1. Esto último nos dará un número binario que será transformado a decimal. Y así iremos obteniendo los descriptores.

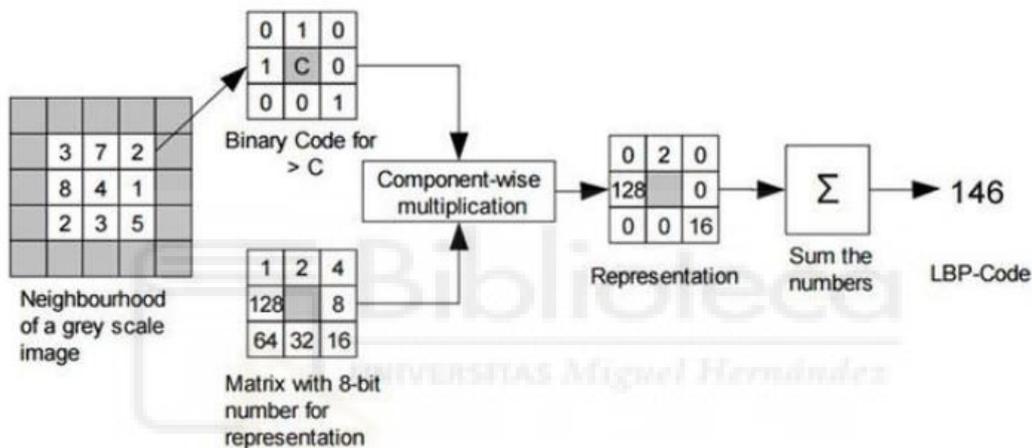
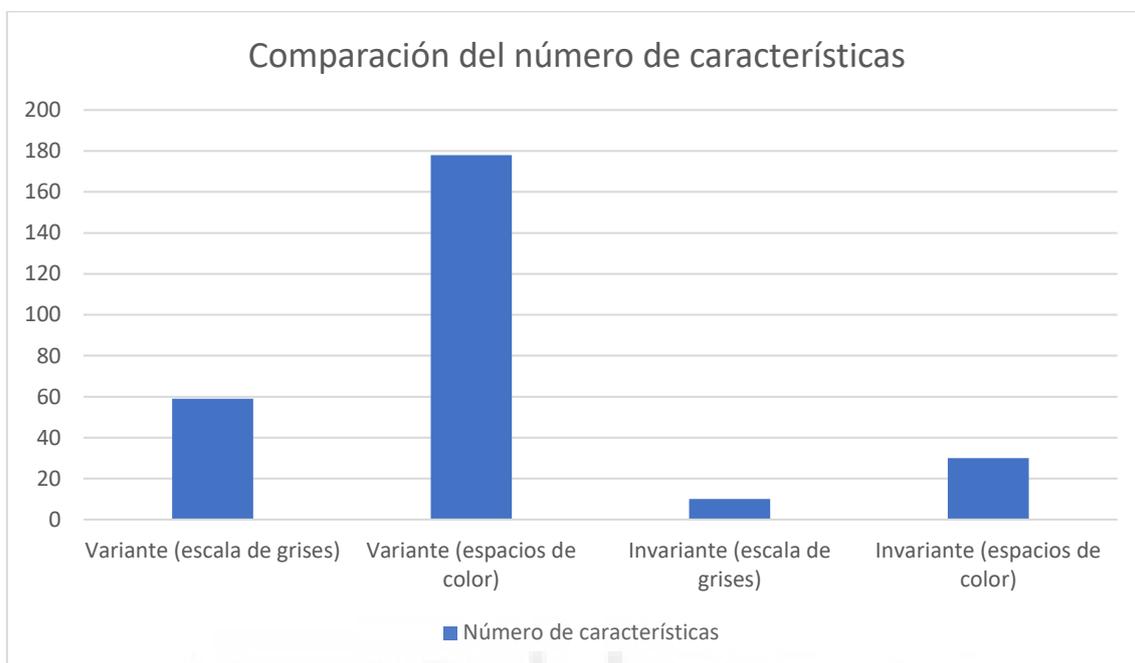


Ilustración 18. Ejemplo de la extracción de características con el uso de LBP

En nuestro caso, nos valemos de la función 'extractLBPFeatures' implementada en MATLAB. Se han hecho distintas pruebas cambiando la configuración de esta función. Para todas esas pruebas se ha mantenido el número de vecinos, que es de 8. El radio del patrón circular para seleccionar vecinos ha adquirido tres valores: 1,3 y 5. Y se han hecho pruebas tanto haciéndola invariante como variante ante rotación.

El número de descriptores solo se ha visto modificado al cambiar la característica de variante o invariante ante rotación, si era variante a rotación obteníamos 59 descriptores y si era invariante ante rotación obteníamos 10

descriptores, este número de descriptores son para el espacio de color de escala de grises.



### 3.4 Clasificadores

Como ya se vio en el capítulo 2, existen distintos tipos de clasificadores y unos resultan más eficientes para una serie de datos que para otros. Se han realizado pruebas con todos los clasificadores de la Tabla 1 en busca de cuál podría ser el idóneo para este proyecto. Todos ellos comparten la técnica de evaluación, he elegido la validación cruzada. La validación cruzada nos garantiza la independencia de la partición entre datos de entrenamiento y datos de prueba y al dividir los datos en pliegues y estimando la precisión de cada pliegue protegemos al modelo del sobreajuste. Utilizaremos una validación cruzada de diez pliegues, es decir, los datos de muestra se dividen en 10 subconjuntos donde uno de ellos se utiliza como datos de test y el resto como datos de entrenamiento. El proceso de validación cruzada se realizará diez veces, y en cada una de ellas se usará un subconjunto diferente como datos de test. Finalmente, realizamos la media aritmética de los resultados obtenidos en

cada iteración y, así, obtener un resultado final único. El hecho de que evaluemos a partir de 10 combinaciones de datos de entrenamiento y test hace que la validación cruzada sea un método muy preciso, su única desventaja es el tiempo de cómputo, que es elevado.

Los clasificadores tienen una configuración determinada que se detalla en la tabla 1.

Clasificador	Kernel	Escala del kernel	Método multiclase
SVM lineal	Lineal	auto	One-vs-one
SVM cuadrático	Cuadrático	auto	One-vs-one
SVM cúbico	Cúbico	Auto	One-vs-one
SVM Gaussiano fino	Gaussian	Depende del tamaño del vector de descripción, pero mantendrá un valor pequeño. Por ejemplo, 0.5.	One-vs-one
SVM Gaussiano medio	Gaussian	Depende del tamaño del vector de descripción, pero mantendrá un valor entre el del pequeño y el del grande. Por ejemplo, 3.	One-vs-one
SVM Gaussiano grueso	Gaussian	Depende del tamaño del	One-vs-one

vector de descripción, pero mantendrá un valor elevado respecto a los otros dos. Por ejemplo, 9.

Clasificador	Nº máximo de divisiones	Criterio de las divisiones	Sustituir división de decisiones
Árbol de decisión fino	100	Gini's diversity index	off
Árbol de decisión medio	20	Gini's diversity index	off
Árbol de decisión grueso	4	Gini's diversity index	off

Clasificador	Nº de vecinos	Distancia métrica	Distancia ponderada
KNN fino	1	Euclídeo	equivalente
KNN medio	10	Euclídeo	equivalente
KNN grueso	100	Euclídeo	equivalente
KNN coseno	1	Coseno	equivalente
KNN cúbico	1	Minkowski (cúbico)	equivalente
KNN ponderado	1	Euclídeo	Inversa al cuadrado

Clasificador	%entrenamiento/ %validación / %test	Neuronas internas	Algoritmo de entrenamiento
Red neuronal	70/15/15	20/30/40/50* *cambiante ante el tamaño de la ventana	Levenberg-Marquardt

Estas características han sido las que mejores resultados nos proporcionaban, se probaron diferentes configuraciones, manteniendo dos parámetros y modificando el tercero, o manteniendo uno y modificando el resto y demás posibles combinaciones.

### **3.5 Red neuronal convolucional**

Ya hemos hablado de esta variante de las redes neuronales, recordaremos sus características principales. Para empezar, la entrada será la imagen en si, es decir, no habrá que extraer nada con anterioridad. Esta red neural lo que hace es obtener mediante el uso de un gran número de capas las características propias de la imagen de entrada. Cada capa tiene una función determinada para lograr el objetivo.

Se usará la red neuronal convolucional AlexNet para realizar pruebas y ser capaces de analizar su funcionamiento y precisión. Me he decantado por esta porque AlexNet supuso un avance notable en cuanto a la precisión de las redes neuronales, consiguió reducir el porcentaje de error más de un 10% respecto a la mejor red de esa época.

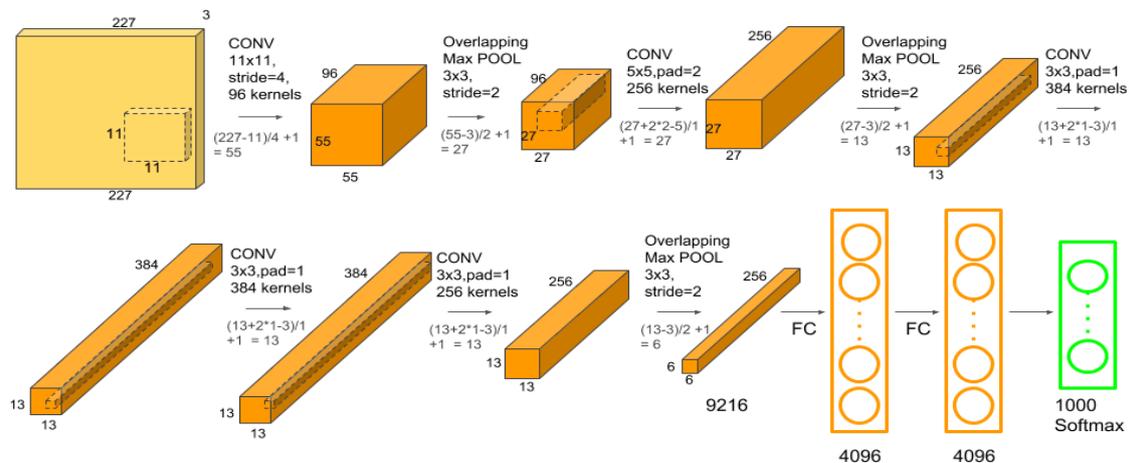


Ilustración 19. Estructura AlexNet

Como ya hemos dicho anteriormente, las imágenes son las entradas, estas imágenes deben tener unas dimensiones predeterminadas, 227x227 para escala de grises y 227x227x3 para otro espacio de color. Centrándonos en la arquitectura, Alexnet consiste en cinco capas convolucionales y tres capas completamente conectadas. El hecho de tener múltiples kernels convolucionales provoca la extracción de características interesantes en una imagen. Las dos primeras capas convolucionales están seguidas por unas capas de 'Overlapping Max Pooling', se explicará que son más adelante. Las últimas tres capas convolucionales están conectadas directamente y, la última capa convolucional va seguida de una capa 'Overlapping Max Pooling', la salida de esta va a una serie de dos capas completamente conectadas. Y la segunda capa completamente conectada acaba en un clasificador 'softmax' con 1000 clases.

'ReLU (Rectified Linear Unit) nonlinearity' es aplicado después de todas las convoluciones y capas completamente conectadas. Y las dos primeras ReLUs van seguidas por una normalización local antes de la agrupación.

Volviendo a las capas de 'Overlapping Max Pooling', se usan para disminuir la anchura y altura de los tensores, manteniendo la profundidad.

Y respecto a 'ReLU (Rectified Linear Unit) nonlinearity', usamos este método para el entrenamiento ya que es más rápido que la manera convencional de entrenamiento que había antes, las funciones de activación de Tanh o sigmoid.

Bien, centrándonos en su uso, lo que debemos hacer, primeramente, es tener las imágenes con las dimensiones que exige el modelo, ya que como sabemos, en total tenemos 25 capas, de las cuales modificaremos las tres últimas para ajustarlas a nuestro caso. La capa 23 es una capa completamente conectada en la que debemos especificar el número de clases que tenemos, que es trece. La capa 24 vamos a dejarla como esta, 'softmaxLayer'. Y la última capa será la capa de clasificación.

Ahora, centrándonos en el reentrenamiento de la red neuronal, hay varias características que vamos a modificar para lograr un mejor funcionamiento. Aquí solo se detallan las características, en el capítulo de resultados expondremos los valores probados, así como, la configuración idónea.

Primero, debemos elegir el algoritmo a utilizar para minimizar la función de coste. Tenemos tres algoritmos donde elegir, el primero es el 'Stochastic Gradient Descent with Momentum' (SGDM), cuya mayor virtud es que reduce en gran medida la oscilación [22]. Después, tenemos el 'RMSProp' que mantiene una media móvil de los cuadrados de los distintos elementos que hay en los gradientes de los parámetros. Por último, tenemos 'Adam' que es similar al anterior, la única diferencia es que añadimos un término del momento.

Otro parámetro relevante, es el tamaño del 'minibatch', que es un subconjunto de los datos de entrenamiento que se usa para evaluar el gradiente de la función de coste y actualizar los pesos.

También podemos elegir si desordenar los datos para hacer el entrenamiento más real y complejo, es aconsejable hacer al menos una vez.

Además, podemos elegir el ritmo de aprendizaje inicial, si esté es muy bajo el entrenamiento tardará mucho más tiempo y si, por el contrario, es muy alto el entrenamiento quizás un resultado no tan optimo o, incluso, diverja.

Existen más parámetros, pero son configuraciones para la visualización del entrenamiento y no afectan al entrenamiento en sí.

## **4. Resultados**

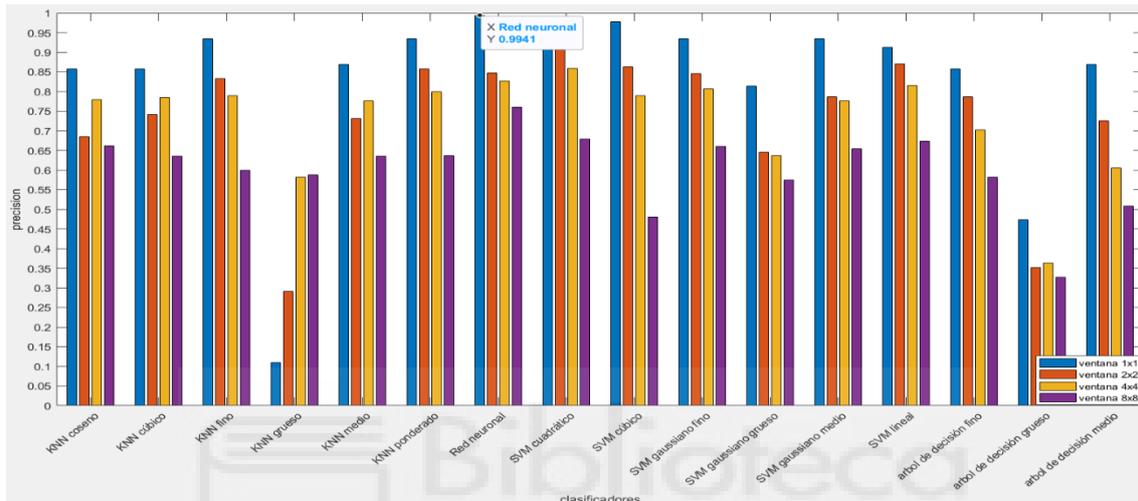
Este capítulo queda claramente dividido en dos apartados, en el primero expondremos los diferentes resultados que hemos obtenido al clasificar los datos tras realizar diferentes pruebas con diferentes tamaños de ventana y distintos descriptores. Estos resultados muestran el porcentaje de acierto de cada clasificación con respecto a la clasificación esperada, y la manera en que representaremos esta información será mediante el uso de diferentes gráficos donde compararemos los espacios de color, los clasificadores y los descriptores entre si. También añadiremos la matriz de confusión y las tasas de éxito y de error del mejor clasificador para cada caso. Como ya se ha mencionado anteriormente, se hará uso de la validación cruzada. En el segundo apartado mostraremos los resultados obtenidos con la red neuronal convolucional Alexnet.

### **4.1 Comparación de los clasificadores comunes**

En el apartado se presentan los resultados, de los distintos clasificadores ya mencionados en el apartado 3.4., para poder observar cuál de ellos es el más idóneo para cada una de las combinaciones determinadas. Se representa tres graficas por espacio y descriptor, la primera será de los resultados en las ventanas cuadradas (2x2, 4x4 y 8x8), la segunda será de los resultados de las ventanas en fila (8x1, 16x1 y 32x1) y por ultimo los resultados de las ventanas en columna (1x8, 1x16 y 1x32). Respecto al eje de ordenadas, marcará el valor de la precisión de los clasificadores en tanto por uno.

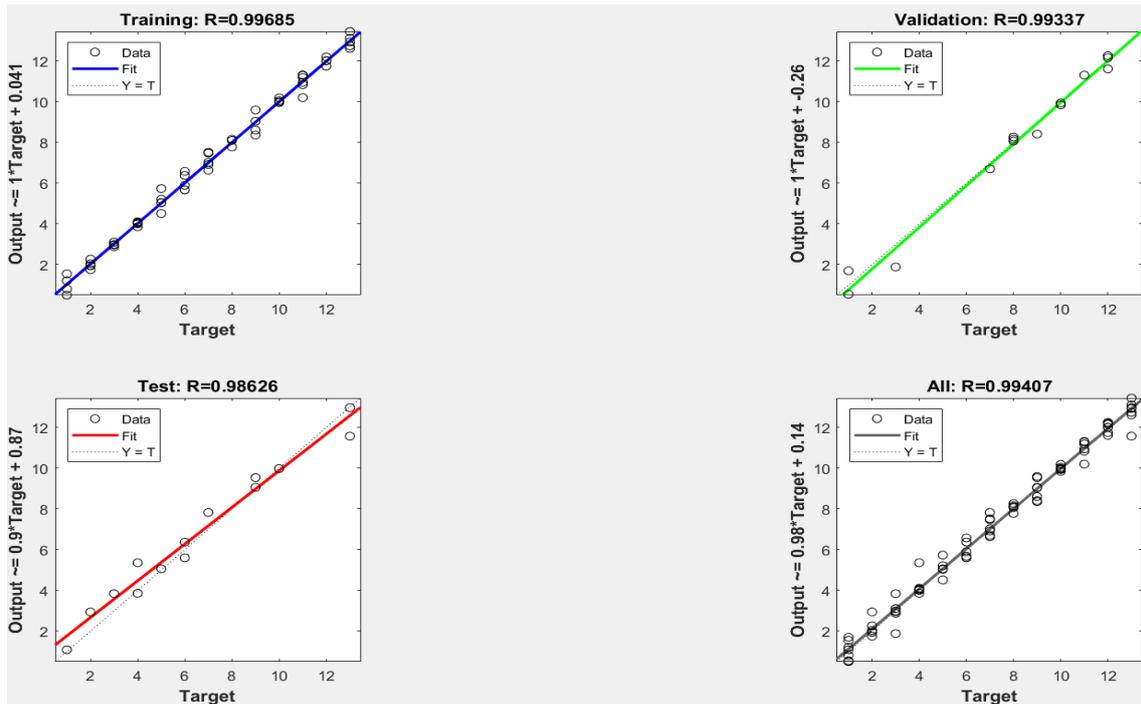
Además, mostraremos la matriz de confusión del clasificador con mayor precisión de cada caso estudiado y, también, las tasas de éxito y error de los mismos.

### 4.1.1 Comparación en escala de grises con el primer data set



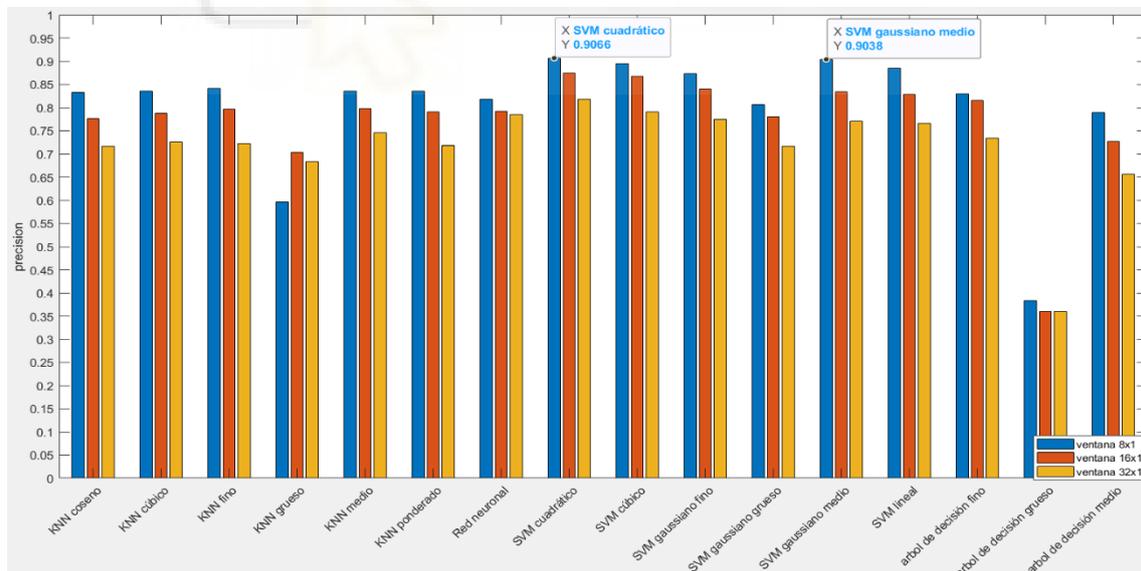
Gráfica 1. Comparación clasificadores para ventanas cuadradas para momentos de histograma en escala de grises

En la gráfica 1 vemos los diferentes clasificadores que hemos usado con datos procedentes del momento de histograma en escala de grises para ventanas cuadradas. La mayoría dan más precisión en ventana de 1x1, siendo la red neuronal la que más se ajusta para esta ventana y, por el contrario, el K-NN grueso el que peor resultado da. A cada reducción de ventana obtenemos peores resultados en muchos de los clasificadores.



Gráfica 2. Regresión lineal de la red neuronal

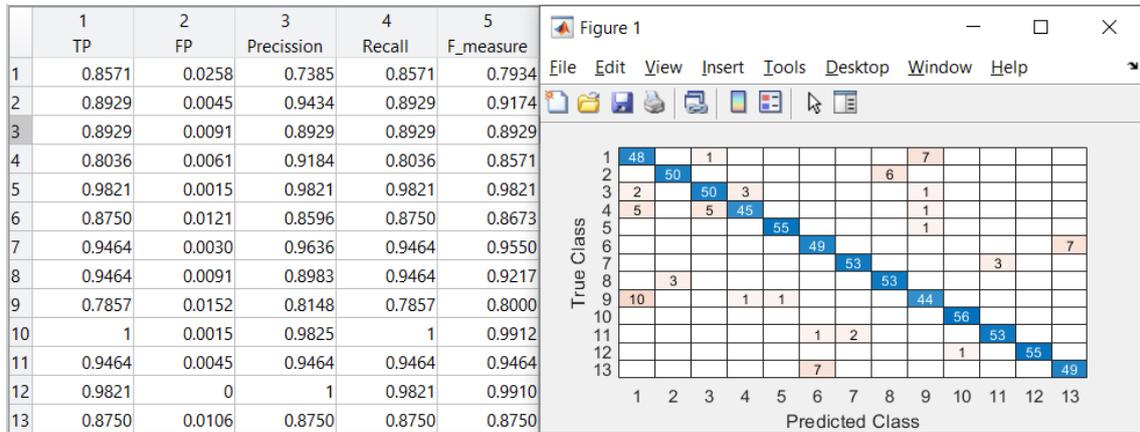
En la gráfica 2 vemos como la red neuronal se adaptó a los datos usando momentos de histograma en escala de grises.



Gráfica 3. Comparación clasificadores para ventanas en filas para momentos de histograma en escala de grises

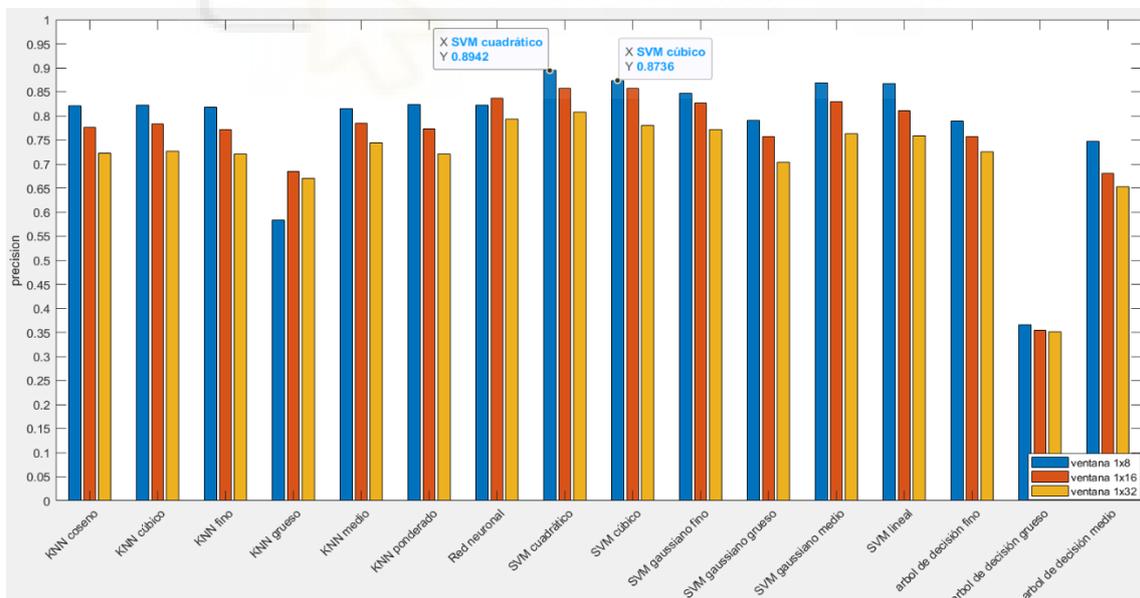
Al comparar los clasificadores con ventanas en fila, en la leyenda se puede ver el tamaño de las mismas, gráfica 3. El SVM cúbico es el que más precisión

tiene, seguido muy de cerca por el de gaussiano medio. Vemos que, en general, los mejores resultados son para ventana 8x1 y pasando a otra ventana más pequeña empeoran los resultados.



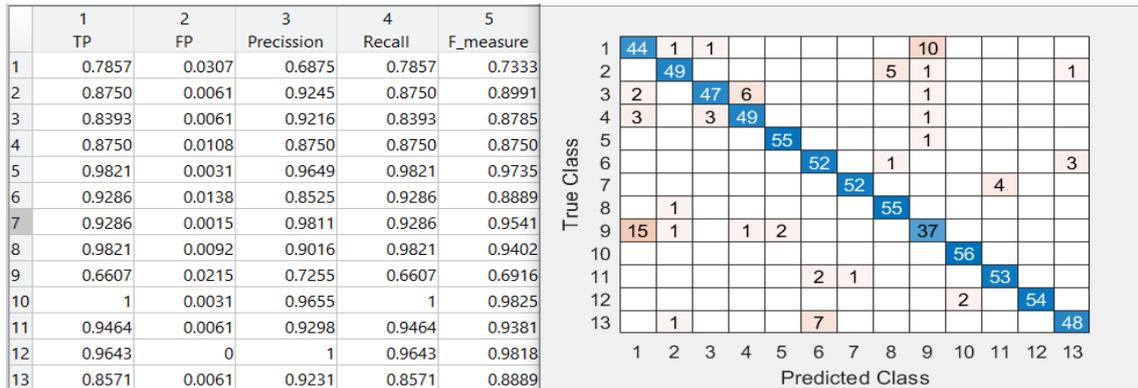
Gráfica 4. Validación del modelo de la gráfica 2

Aquí, en la gráfica 4, podemos ver la matriz de confusión del clasificador SVM cuadrático para ventanas en filas usando momentos de histograma en escala de grises y las tasas de éxito y error en la clasificación.



Gráfica 5. Comparación clasificadores para ventanas en columnas para momentos de histograma en escala de grises

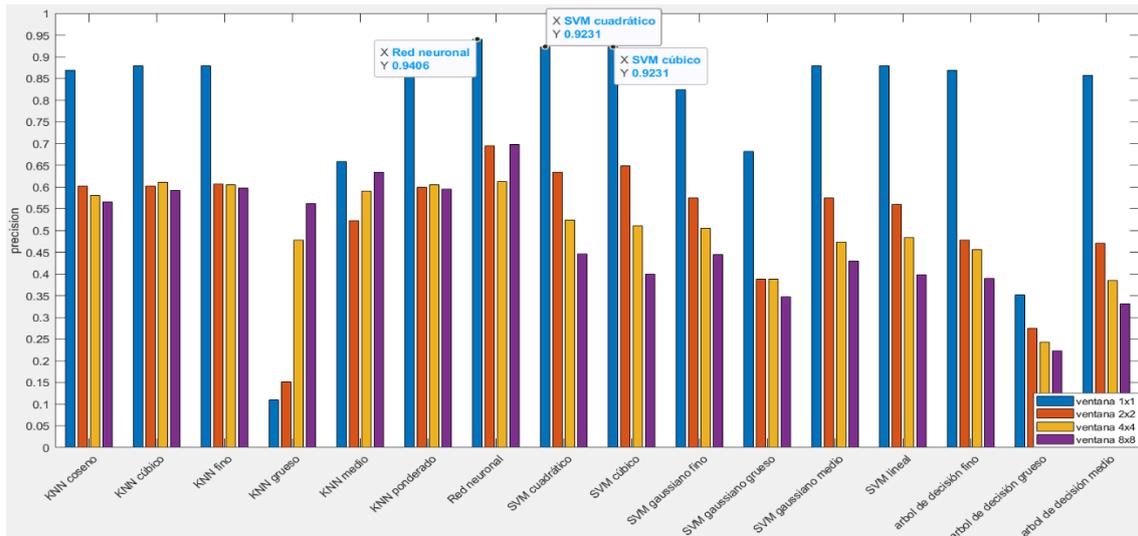
Con ventanas en columnas usando los momentos de histograma para imágenes en escala de grises, gráfica 5 los mejores resultados son para ventana 1x8, y a menor tamaño de las ventanas menor precisión obtenemos. El SVM cuadrático es el de mayor precisión con una diferencia más que notable respecto del siguiente, que es el SVM cúbico.



Gráfica 6. Validación del modelo de la gráfica 5

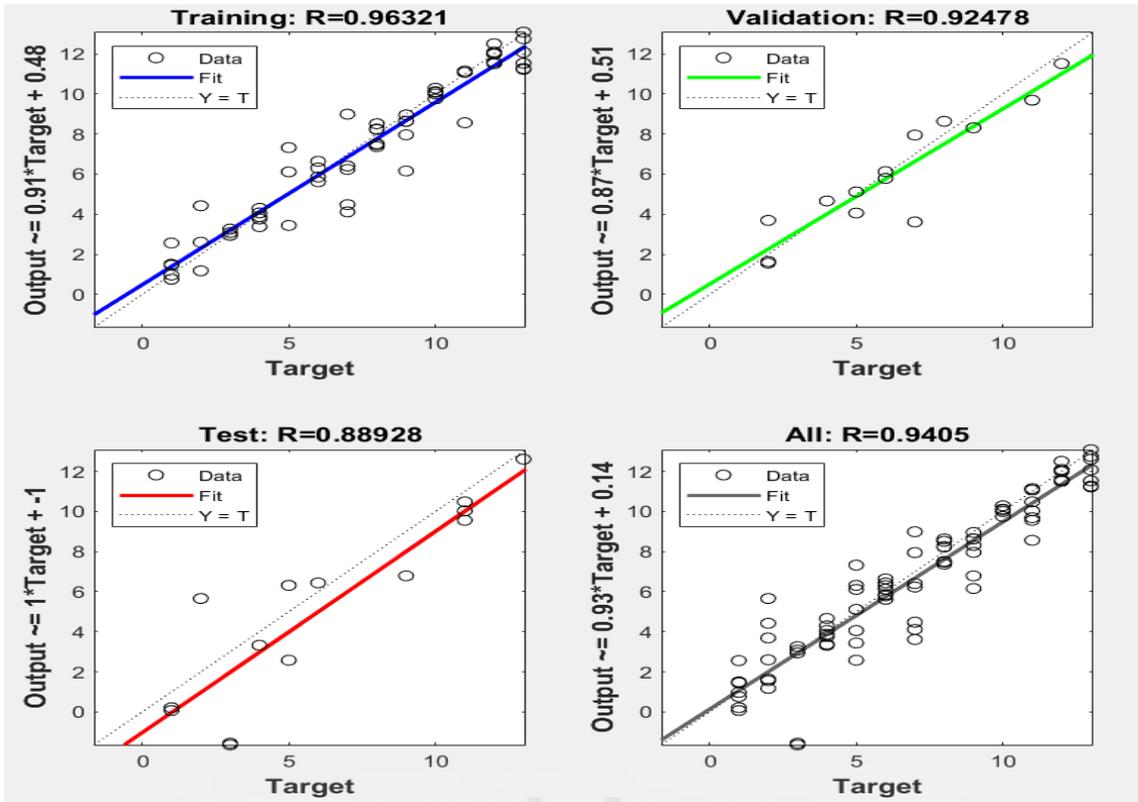
Aquí, en la gráfica 6, podemos ver la matriz de confusión del clasificador SVM cuadrático para ventanas en columnas usando momentos de histograma en escala de grises y las tasas de éxito y error en la clasificación.

Para escala de grises con el uso de momentos de histograma, hemos visto que la red neuronal para ventana de 1x1 es la que mayor porcentaje nos ofrece, además hay que tener en cuenta que en el resto de las ventanas los resultados han sido muy pobre en comparación.



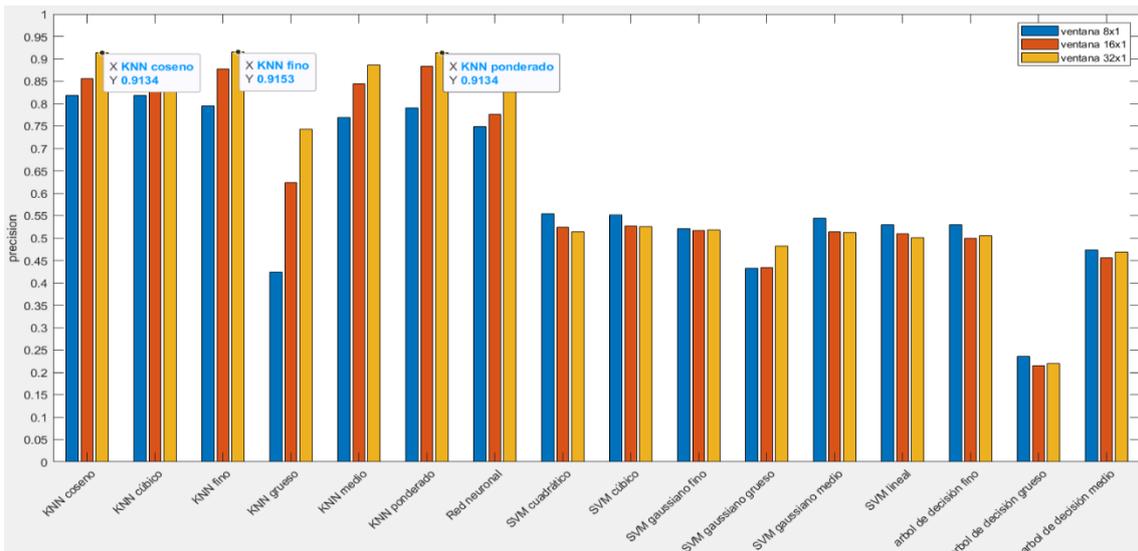
Gráfica 7. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en escala de grises

A la hora de usar la matriz de coocurrencia en escala de grises para ventanas cuadradas, en la gráfica 7 la red neuronal para una ventana de 1x1 es la que más logra ajustarse. En general para esta ventana es la que da el mejor resultado y casi todos los valores están próximos entre sí, pero en este caso cabe destacar que la diferencia de resultado con la siguiente ventana es muy notoria.



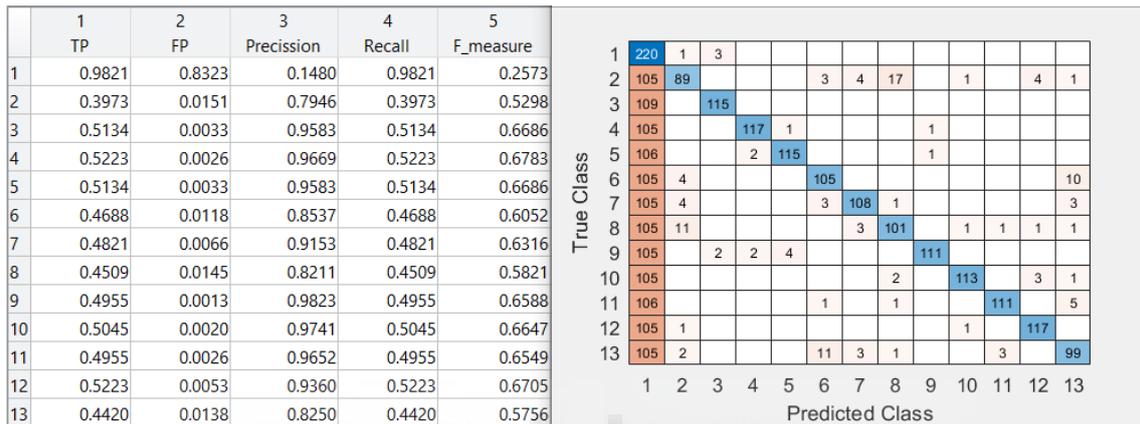
Gráfica 8. Regresión lineal de la red neuronal

En la gráfica 8 vemos como la red neuronal se adaptó a los datos usando momentos de histograma en escala de grises.



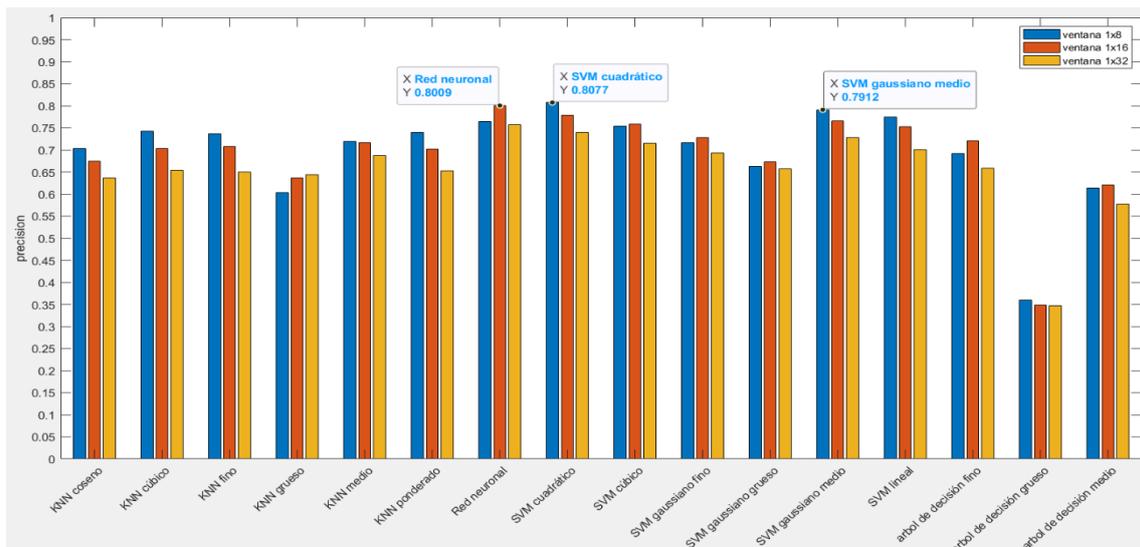
Gráfica 9. Comparación clasificadores para ventanas en filas para matriz de cocurrencia en escala de grises

Continuando con la matriz de coocurrencia en escala de grises, pero para ventanas en filas, en la gráfica 9 vemos que los clasificadores K-NN para ventana 32x1 son los que destacan entre todos. A medida que agrandamos la ventana obtenemos peores resultados. Los clasificadores SVM tienen, todos, un resultado muy parecido tanto entre ellos como para ventanas diferentes tamaños.



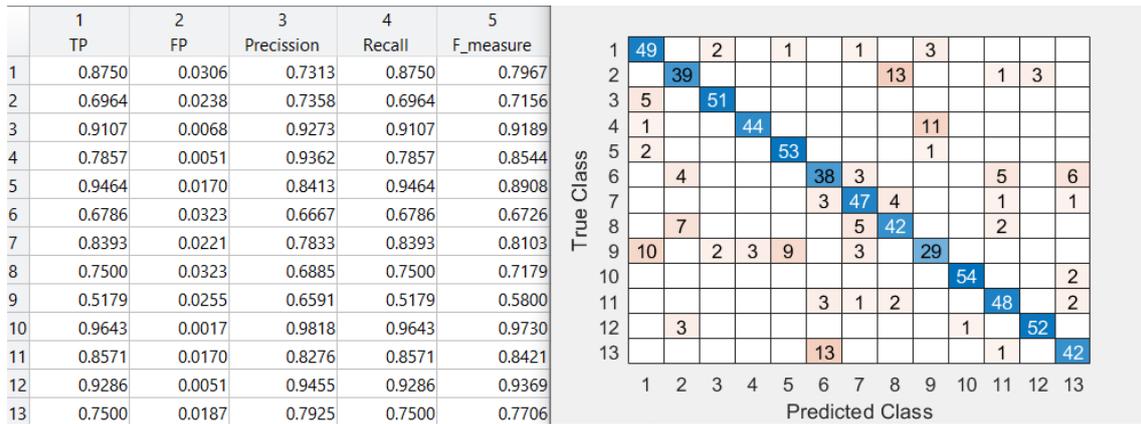
Gráfica 10. Validación del modelo de la gráfica 9

Aquí, en la gráfica 10, podemos ver la matriz de confusión del clasificador K-NN fino para ventanas en filas usando matriz de coocurrencia en escala de grises y las tasas de éxito y error en la clasificación.



Gráfica 11. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en escala de grises

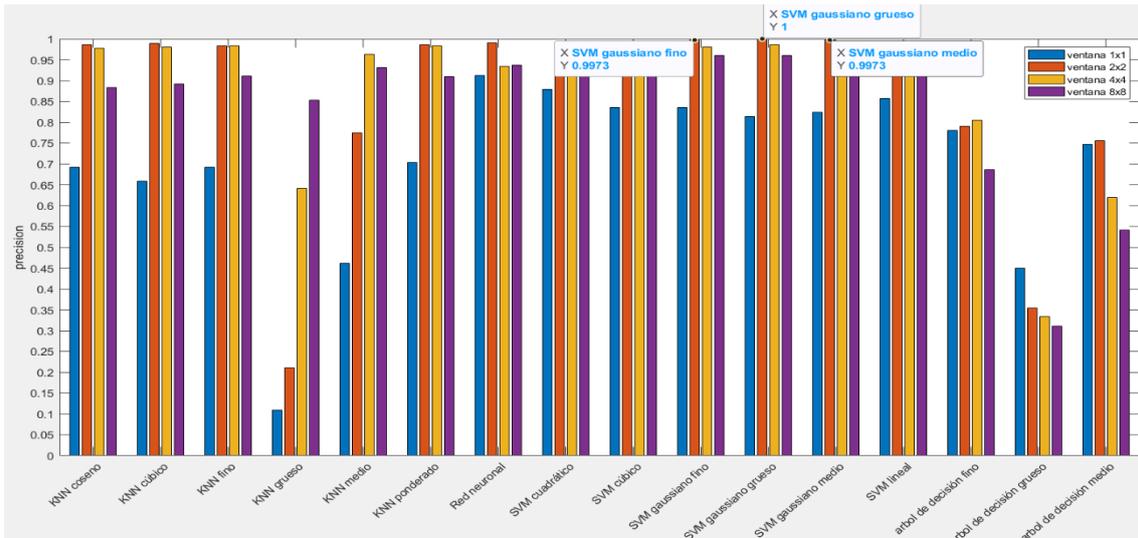
Aquí, en la gráfica 11, podemos ver como para ventanas en columnas, salvo en algunas excepciones, a mayor tamaño de las ventanas mejores resultados tenemos. Una de las excepciones es la red neuronal, que para una ventana de 1x16 nos da la mayor precisión para este caso después del SVM cuadrático para una ventana de 1x8.



Gráfica 12. Validación del modelo de la gráfica 11

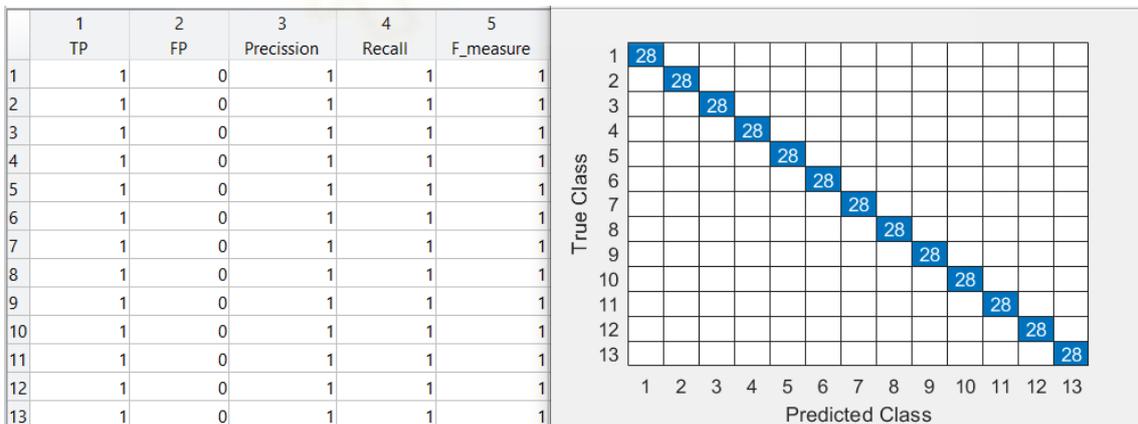
Aquí, en la gráfica 12, podemos ver la matriz de confusión del clasificador SVM cuadrático para ventanas en columnas usando la matriz de coocurrencia en escala de grises y las tasas de éxito y error en la clasificación.

Después de ver las gráficas de las tres ventanas posibles, la red neuronal usando la matriz de coocurrencia en escala de grises para una ventana de 1x1 es la que mejor precisión nos da. En general para una ventana de 1x1 los clasificadores dan los resultados más altos.



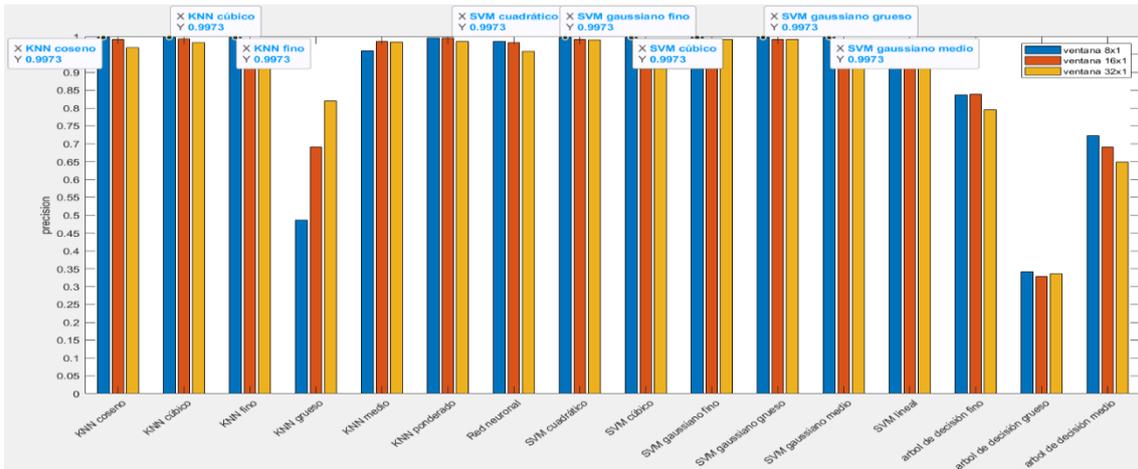
Gráfica 13. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación y con radio 1 en escala de grises

Podemos observar en la gráfica 13 que en al usar un descriptor LBP variante a rotación con radio 1 en escala de grises, en las ventanas de 2x2 es donde los clasificadores arrojan mayor precisión. Alcanzamos la precisión máxima con el SVM gaussiano grueso para la ventana antes mencionada, pero el resto de SVM gaussianos también arrojan un muy buen resultado.



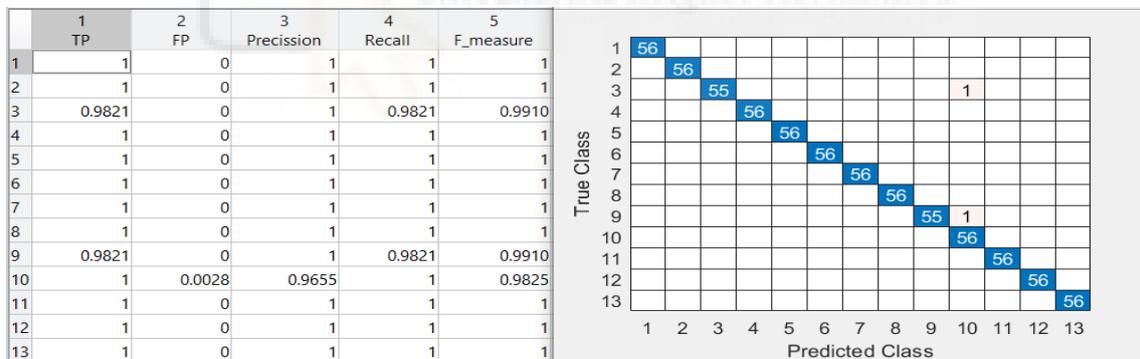
Gráfica 14. Validación del modelo de la gráfica 13

Aquí, en la gráfica 14, podemos ver la matriz de confusión del clasificador SVM gaussiano grueso para ventanas cuadradas usando LBP variante a rotación con radio 1 en escala de grises y las tasas de éxito y error en la clasificación.



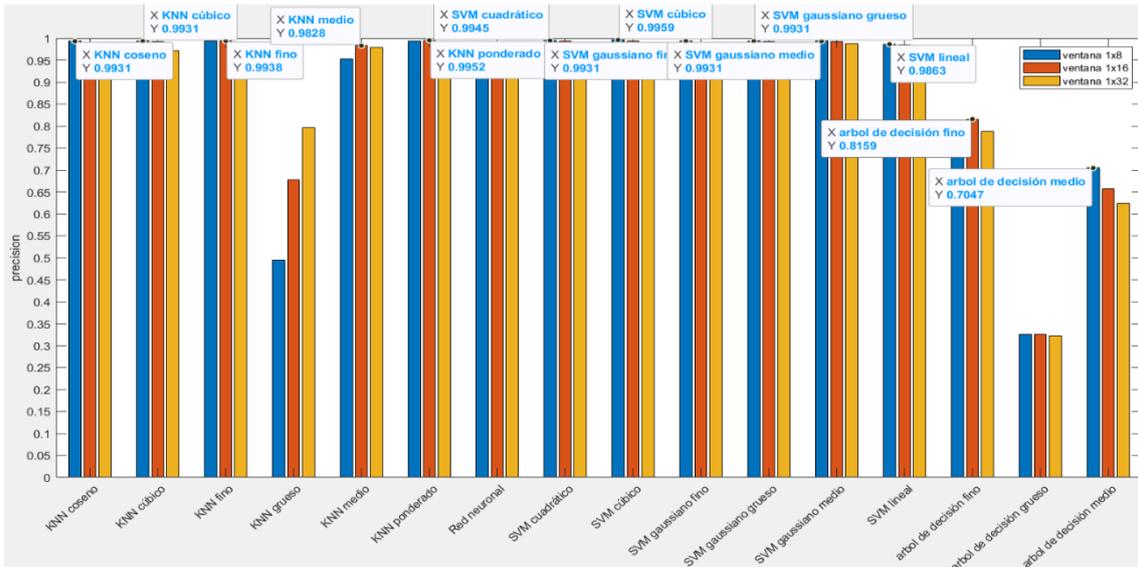
Gráfica 15. Comparación clasificadores para ventanas en filas para LBP variante a rotación y con radio 1 en escala de grises

En la gráfica 15 alcanzamos el mismo resultado con varios clasificadores para una ventana de 8x1 usando un LBP variante ante rotación con radio 1 en escala de grises. Sin tener en cuenta los árboles de decisión y el K-NN grueso, los resultados del resto de clasificadores para los distintos tipos de ventanas en fila es similar.



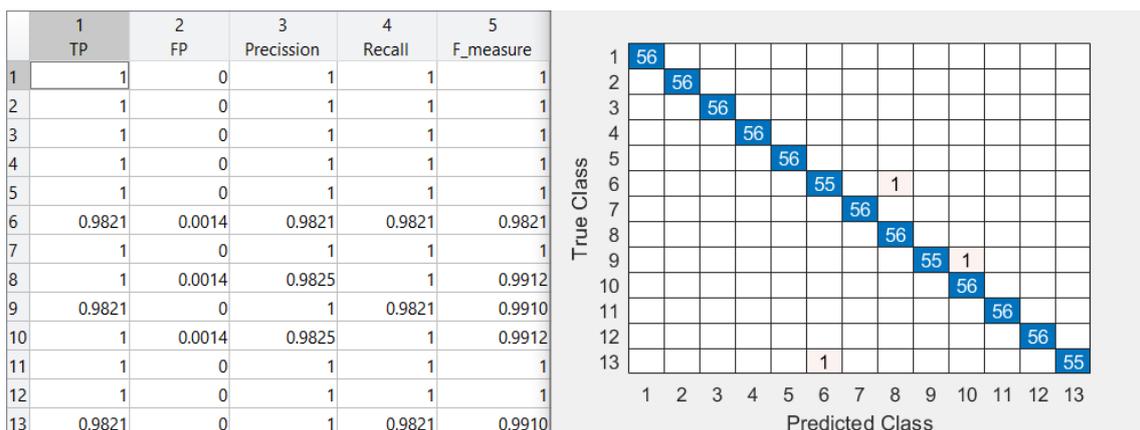
Gráfica 16. Validación del modelo de la gráfica 15

Aquí, en la gráfica 16, podemos ver la matriz de confusión de uno de los clasificadores que alcanzaron la mayor precisión para ventanas en fila usando LBP variante a rotación con radio 1 en escala de grises y las tasas de éxito y error en la clasificación.



Gráfica 17. Comparación clasificadores para ventanas en columnas para LBP variante a rotación y con radio 1 en escala de grises

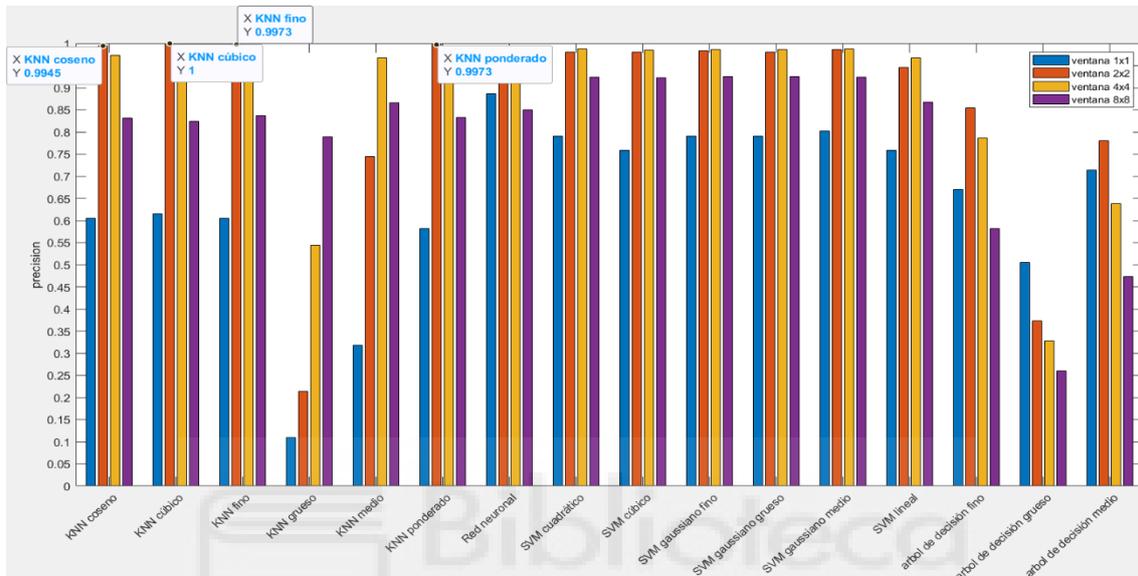
Antes de nada, hay que mencionar que para ventanas en columnas usando LBP variante a rotación y con radio 1, en la gráfica 17 el mejor clasificador es el SVM cúbico. Ahora, profundizando más vemos que para ningún clasificador la ventana de 1x32 nos ofrece el mejor resultado, siempre varían entre las otras ventanas, y en la mayoría el valor se aproxima mucho a la precisión máxima obtenida.



Gráfica 18. Validación del modelo de la gráfica 17

Aquí, en la gráfica 18, podemos ver la matriz de confusión del clasificador SVM cúbico para ventanas en columnas usando LBP variante a rotación con radio 1 en escala de grises y las tasas de éxito y error en la clasificación.

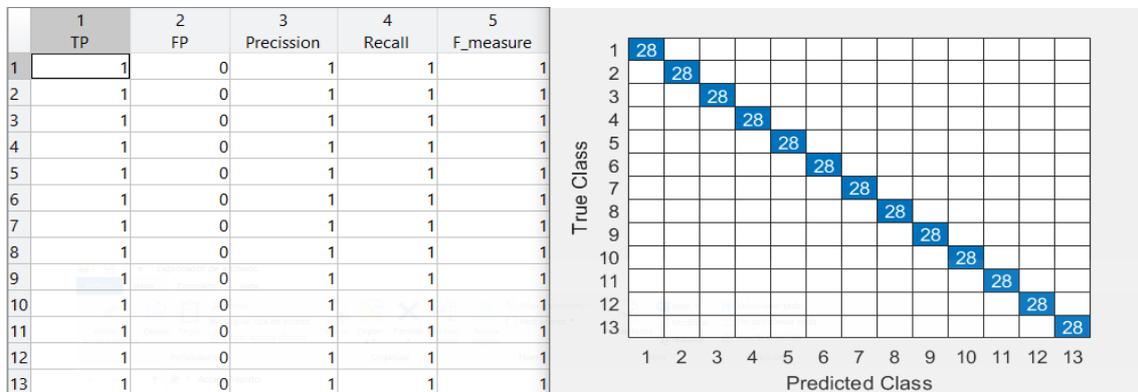
Después de observar con detenimiento las gráficas anteriores, vemos que el clasificador SVM Gaussiano grueso con una ventana de 2x2 es el idóneo cuando usamos el LBP variante a rotación con radio 1 y, cabe recalcar, que su comportamiento general, es decir, en el resto de las ventanas también ha sido notable.



Gráfica 19. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación y con radio 3 en escala de grises

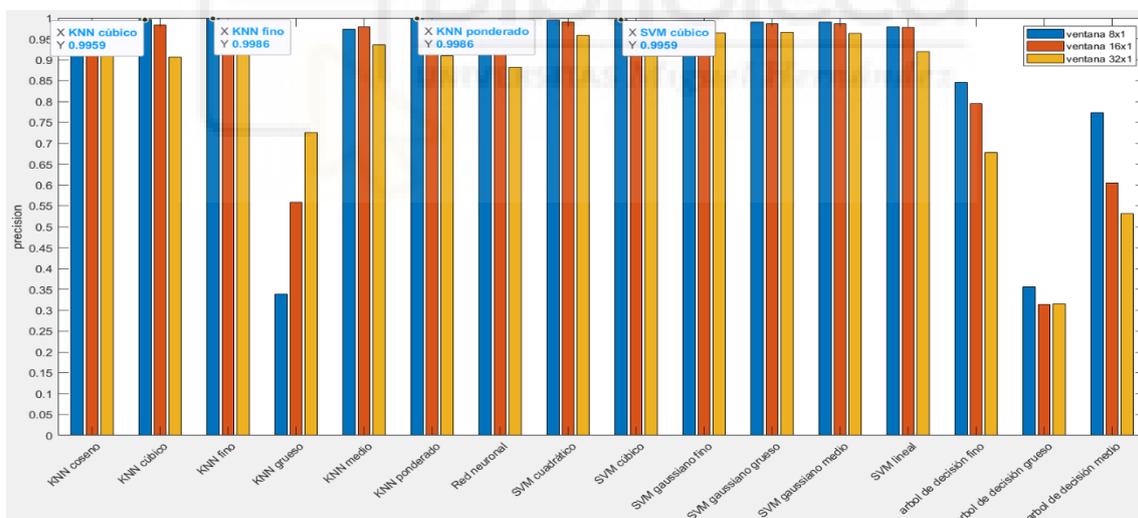
Podemos ver que usando LBP variante a rotación y con radio 3 en escala de grises, en la gráfica 19 en las ventanas 4x4 los clasificadores SVM alcanzan el valor más alto respecto al resto de ventanas, aun así, no es suficiente para

alcanzar la precisión de algunos de los clasificadores K-NN. Con el clasificador K-NN cúbico en ventanas de 2x2 alcanzamos la máxima precisión posible.



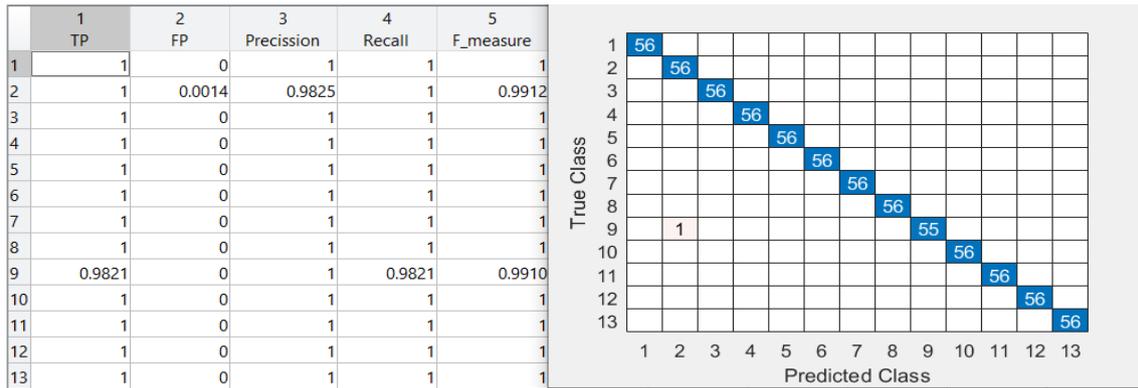
Gráfica 20. Validación del modelo de la gráfica 19

Aquí, en la gráfica 20, podemos ver la matriz de confusión del clasificador K-NN cúbico para ventanas cuadradas usando LBP variante a rotación con radio 3 en escala de grises y las tasas de éxito y error en la clasificación.



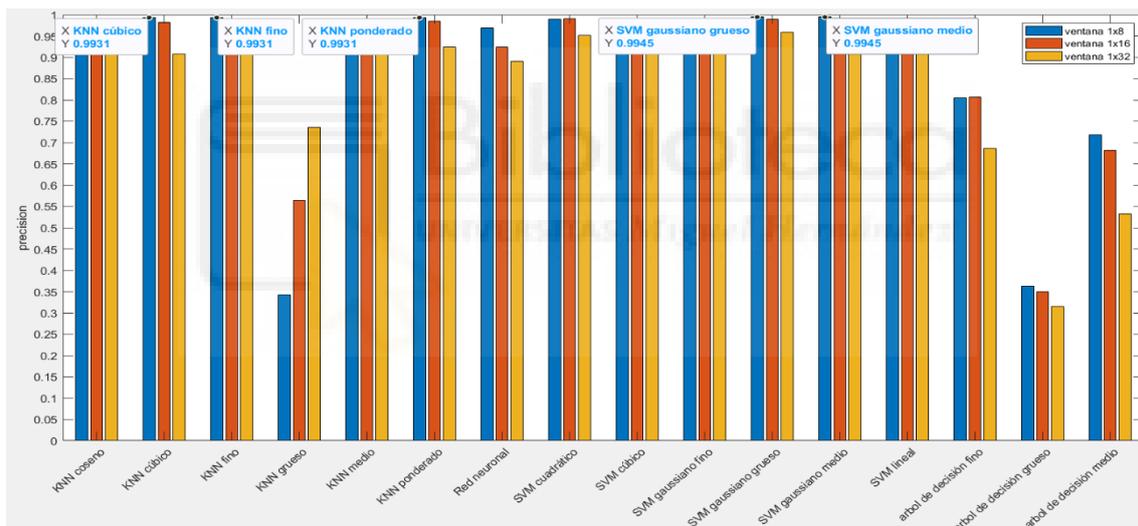
Gráfica 21. Comparación clasificadores para ventanas en filas para LBP variante a rotación y con radio 3 en escala de grises

Por lo general en la gráfica 21, los mejores resultados para cada clasificador se dan en la ventana de 8x1, siendo el K-NN fino y el K-NN ponderado los que comparten la máxima precisión para la ventana antes mencionada, cabe destacar que a medida que la ventana se hace mas pequeña los resultados son peores, salvo para el K-NN grueso.



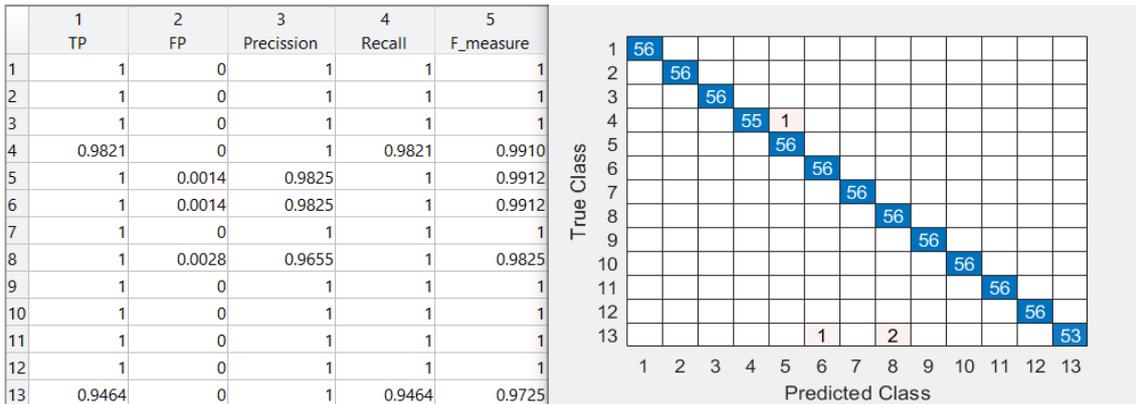
Gráfica 22. Validación del modelo de la gráfica 21

Aquí, en la gráfica 22, podemos ver la matriz de confusión del clasificador K-NN cúbico para ventanas en filas usando LBP variante a rotación con radio 3 en escala de grises y las tasas de éxito y error en la clasificación.



Gráfica 23. Comparación clasificadores para ventanas en columnas para LBP variante a rotación y con radio 3 en escala de grises

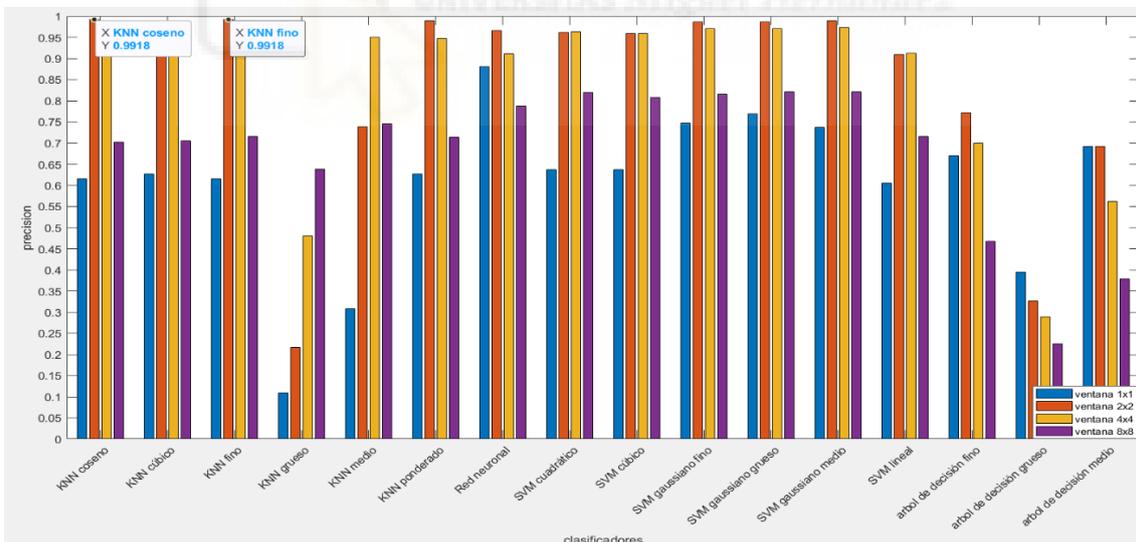
Vemos que en la gráfica 23 el comportamiento es parecido a cuando analizamos las ventanas en filas, siendo esta vez los clasificadores SVM gaussiano grueso y SVM gaussiano medio los que mayor precisión nos proporcionan para una ventana de 1x8. De manera general, es para la ventana de 1x8 para la que los clasificadores alcanzan mayor precisión, y está decrece conforme la ventana disminuye su tamaño.



Gráfica 24. Validación del modelo de la gráfica 23

Aquí, en la gráfica 24, podemos ver la matriz de confusión del clasificador SVM gaussiano grueso para ventanas en filas usando LBP variante a rotación con radio 3 en escala de grises y las tasas de éxito y error en la clasificación.

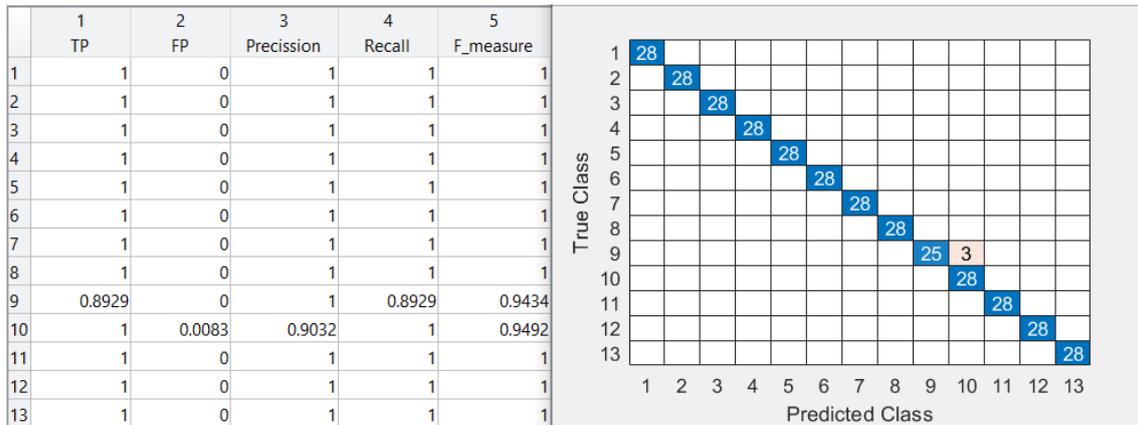
Después de los datos visto, queda claro que para LBP variante a rotación y con radio 3 en escala de grises, el K-NN cúbico para una ventana de 2x2 es el que mejor resultado nos ofrece.



Gráfica 25. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación y con radio 5 en escala de grises

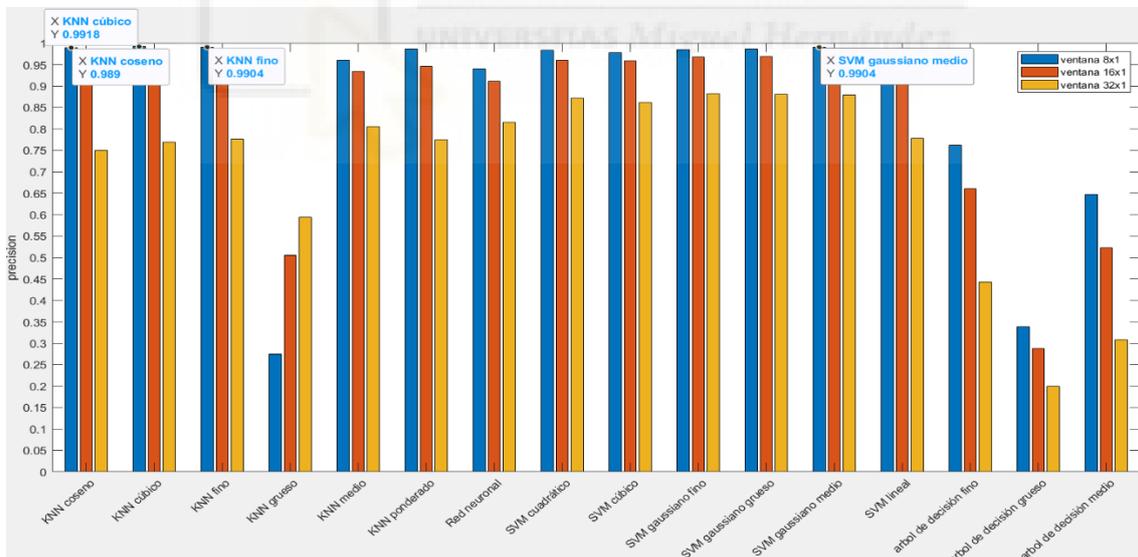
A la hora de analizar el LBP variante a rotación con radio 5 para escala de grises, en la gráfica 25 comprobamos que los mejores resultados,

generalmente, se dan en ventanas de 2x2. Tanto el clasificador K-NN coseno como el K-NN fino son los que mayor precisión tienen con una ventana de 2x2.



Gráfica 26. Validación del modelo de la gráfica 25

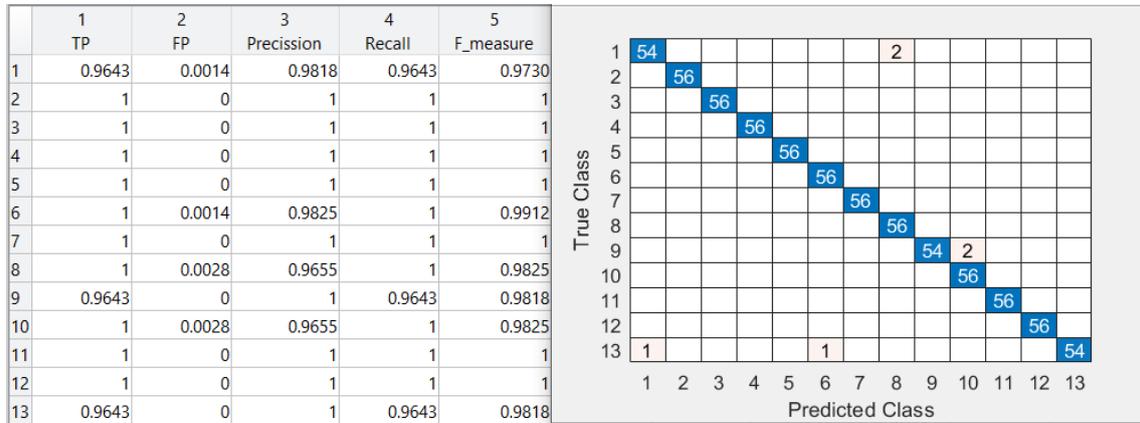
Hemos elegido el K-NN fino para representar la matriz de confusión y las tasas de acierto y error para LBP variante a rotación con radio 5 para ventanas cuadradas de la gráfica 26.



Gráfica 27. Comparación clasificadores para ventanas en filas para LBP variante a rotación y con radio 5 en escala de grises

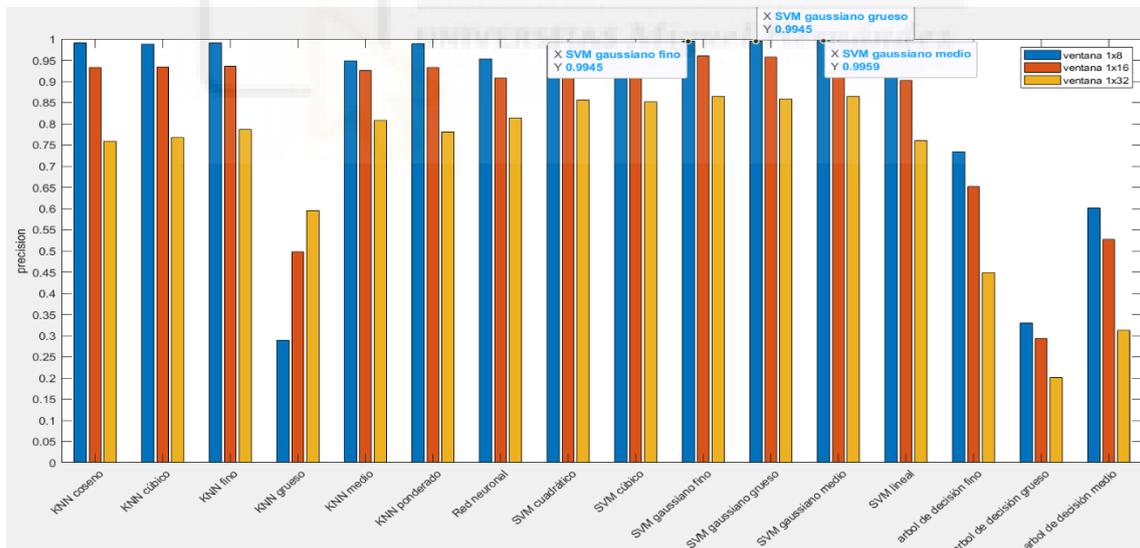
Podemos ver que los mejores resultados se producen, de forma generalizada en la gráfica 27, en la ventana de 8x1 y a medida que el tamaño de la ventana

decrece también lo hace el resultado. El clasificador con la mayor precisión para LBP variante a rotación y con radio 5 es el K-NN cúbico para ventanas de 8x1.



Gráfica 28. Validación del modelo de la gráfica 27

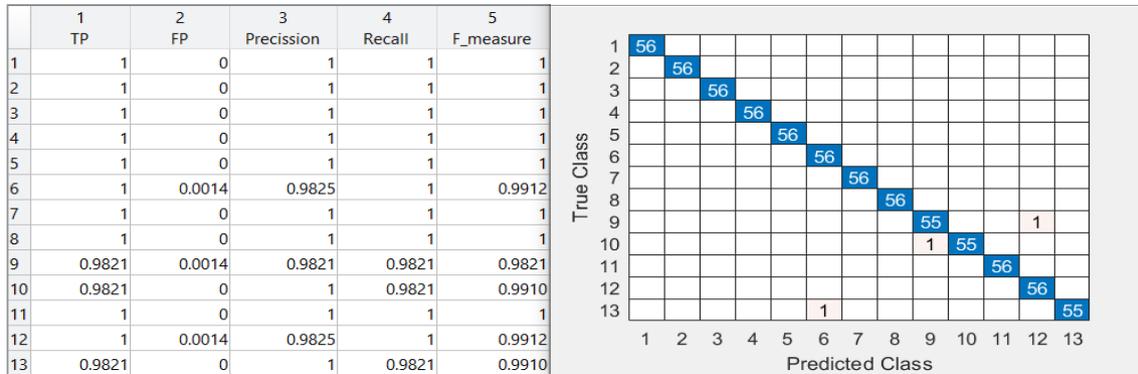
Usaremos el clasificador con más precisión, el K-NN cúbico, para representar la matriz de confusión y las tasas de acierto y error para LBP variante a rotación con radio 5 para ventanas en fila de la gráfica 28.



Gráfica 29. Comparación clasificadores para ventanas en columnas para LBP variante a rotación y con radio 5 en escala de grises

Vemos que en la gráfica 29 los mejores resultados suceden cuando las ventanas son de 1x8 y, que estos mismos, decrecen conforme disminuye el tamaño de la ventana. El mejor resultado usando LBP variante a rotación y con

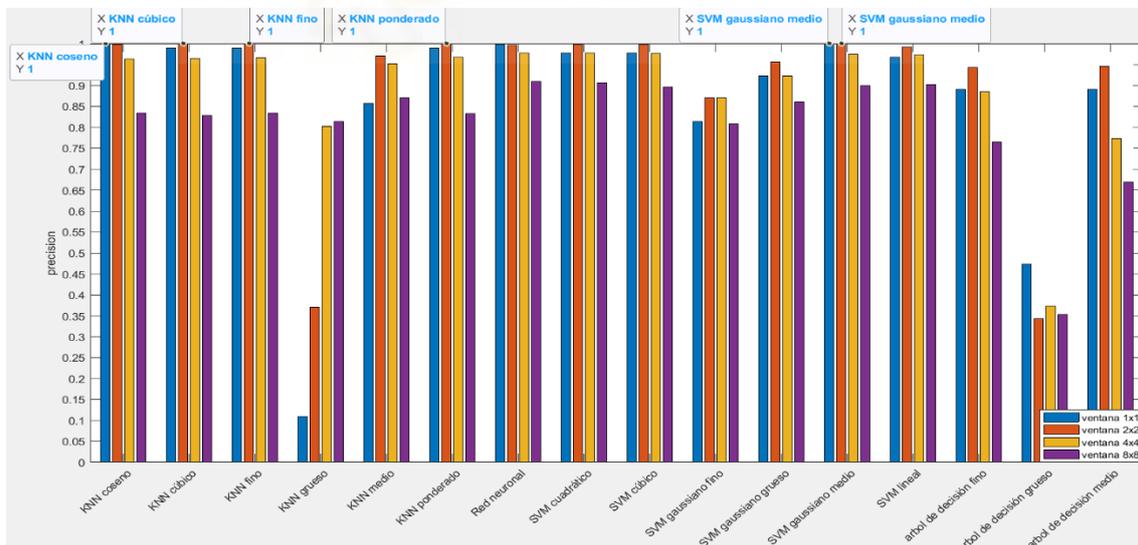
radio 5 se produce con el clasificador SVM gaussiano medio, pero la diferencia con los otros dos gaussianos es muy pequeña.



Gráfica 30. Validación del modelo de la gráfica 29

Usaremos el clasificador con más precisión, el SVM gaussiano medio, para representar la matriz de confusión y las tasas de acierto y error para LBP variante a rotación con radio 5 para ventanas columna de la gráfica 30.

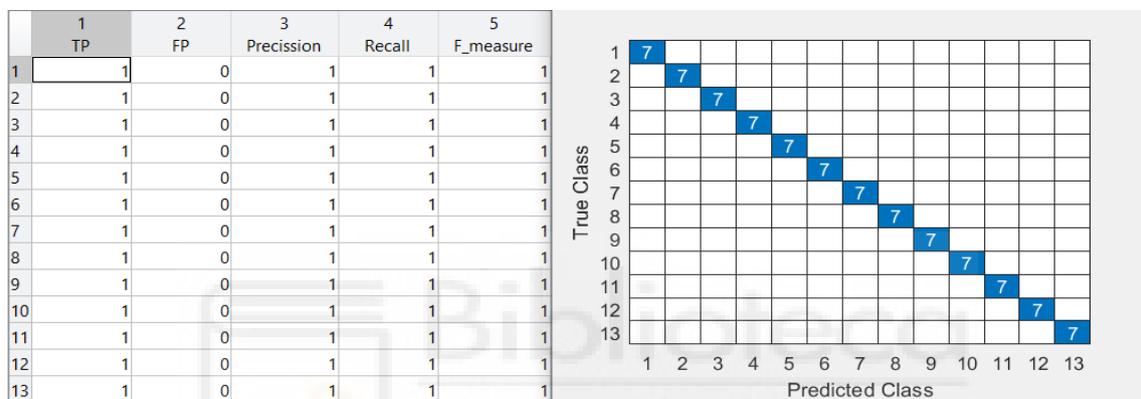
Viendo los resultados anteriores, podemos concluir que para LBP variante a rotación con radio 5 el SVM gaussiano medio para ventanas de 1x8 es el mejor.



Gráfica 31. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación y con radio 1 en escala de grises

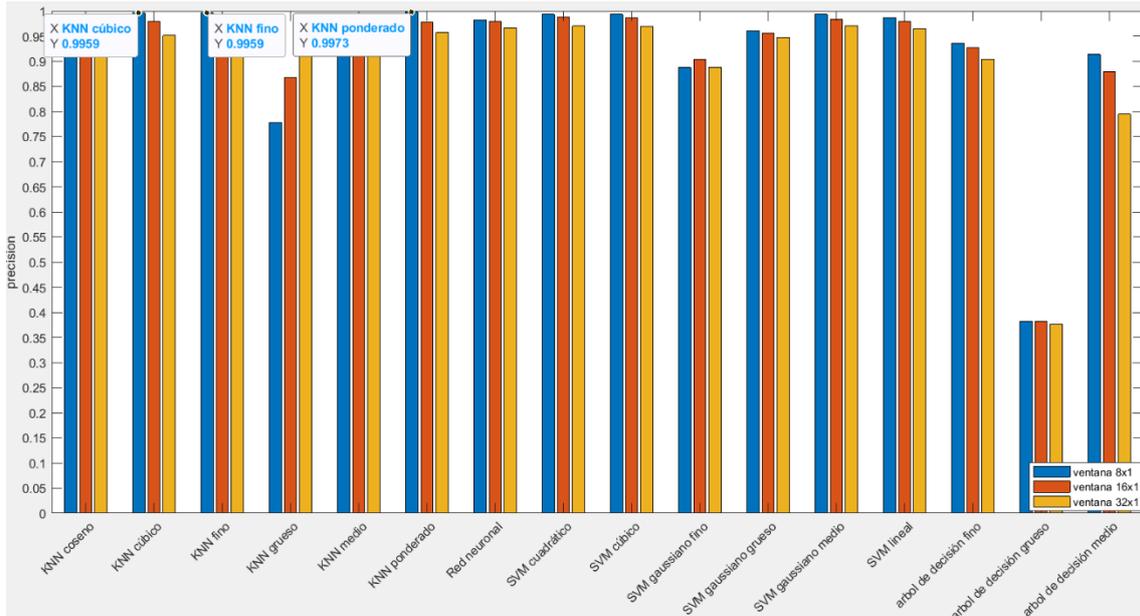
En la gráfica 31, usando LBP invariante a rotación y con radio 1 en escala de grises, en la gráfica 31 obtenemos la máxima precisión con varios clasificadores y con varios tamaños de ventana.

En general, los mejores resultados son para ventanas de 2x2, habiendo cuatro clasificadores que alcanzan el acierto total con esta ventana. Por otra parte, para la ventana de 1x1 tenemos dos clasificadores que alcanzan el acierto máximo. Cabe destacar que es el clasificador SVM gaussiano medio el adquiere la máxima precisión tanto para la ventana de 1x1 como la de 2x2.



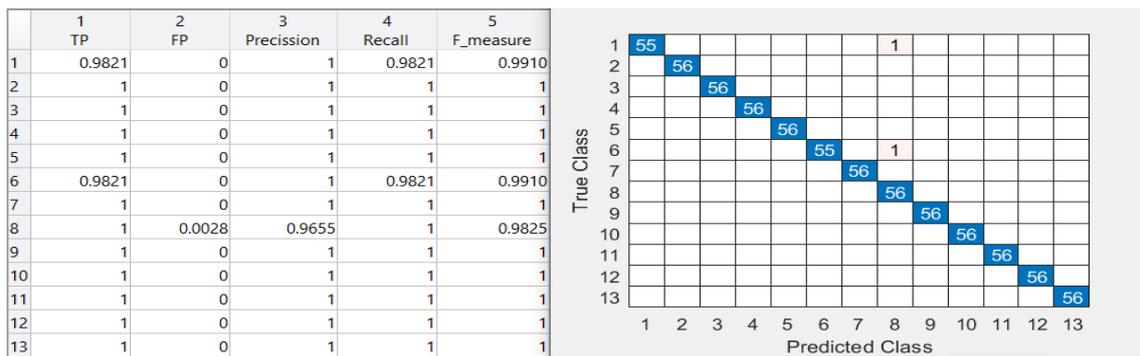
Gráfica 32. Validación del modelo de la gráfica 31

Hemos elegido el SVM gaussiano medio para representar la matriz de confusión y las tasas de acierto y error para LBP invariante a rotación con radio 1, de la gráfica 32, para ventanas cuadradas.



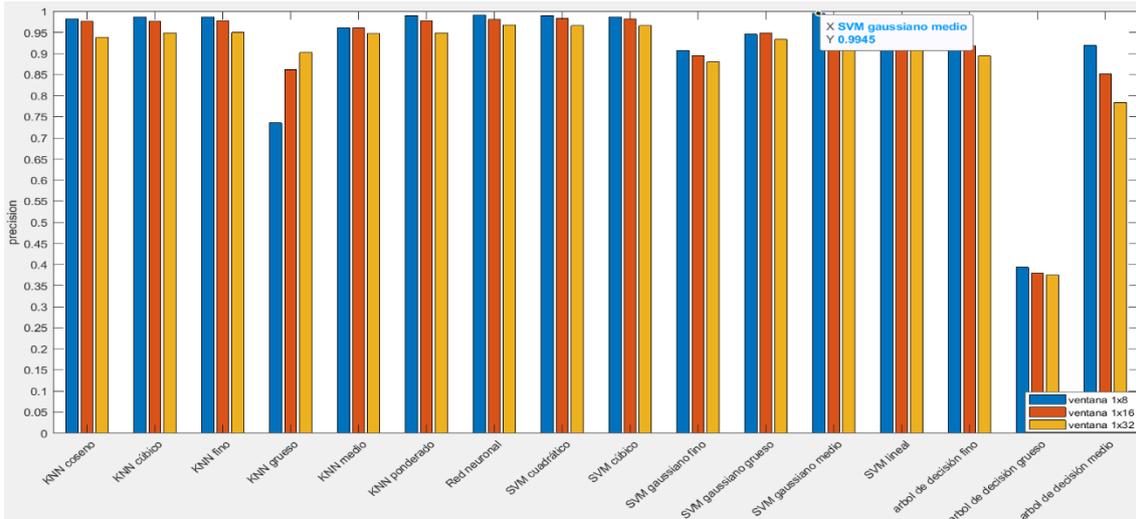
Gráfica 33. Comparación clasificadores para ventanas en filas para LBP invariante a rotación y con radio 1 en escala de grises

Se puede observar en la gráfica 33 que los clasificadores K-NN, menos el K-NN grueso, tienen mayor precisión que el resto de los clasificadores para LBP invariante a rotación y con radio 1 en escala de grises. Siendo el K-NN ponderado el que más precisión tiene para ventanas de 8x1, y en la mayoría de los clasificadores, es esta ventana la que mejor resultado da y, a medida que disminuimos la ventana también disminuye el resultado.



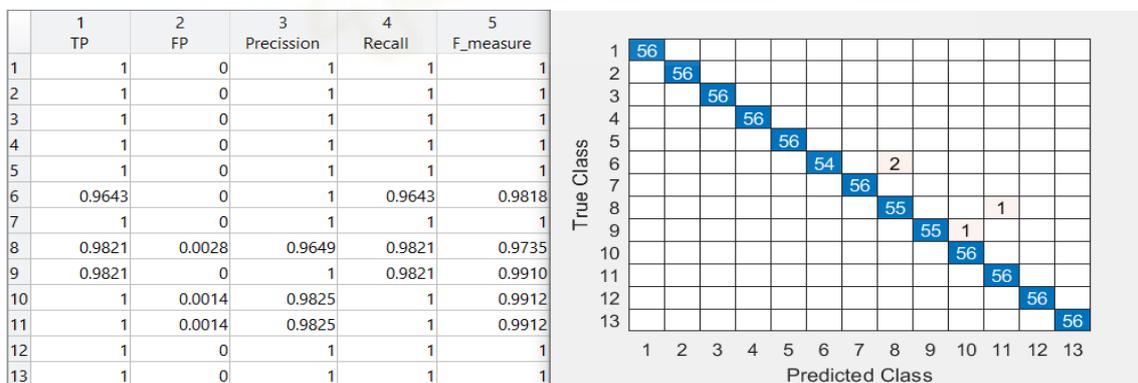
Gráfica 34. Validación del modelo de la gráfica 33

Usaremos el clasificador con más precisión, el K-NN ponderado, para representar la matriz de confusión y las tasas de acierto y error para LBP invariante a rotación con radio 1, de la gráfica 34, para ventanas fila.



Gráfica 35. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación y con radio 1 en escala de grises

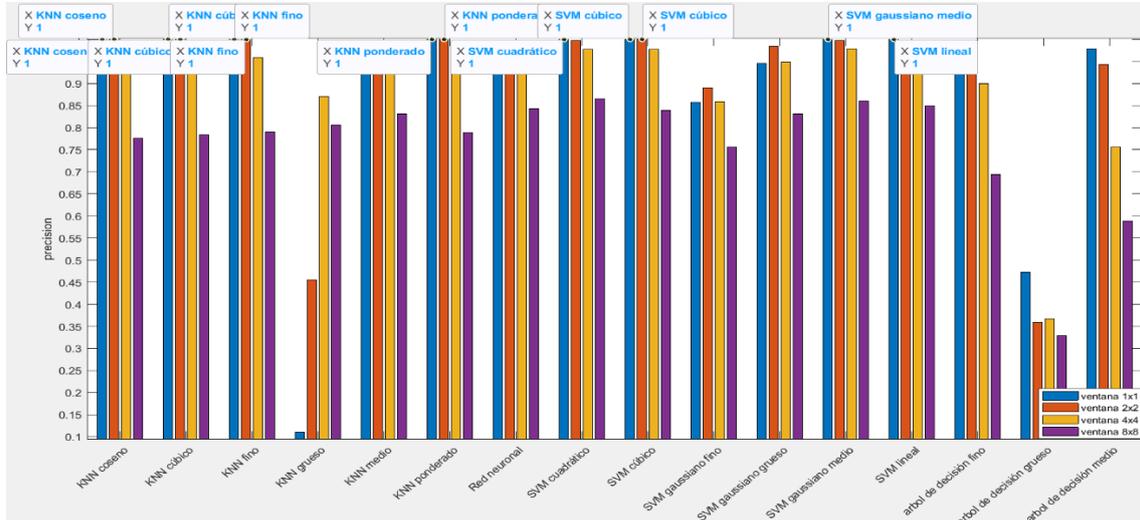
Con ventanas en columnas para LBP invariante a rotación con radio 1 en escala de grises, vemos en la gráfica 35 que el clasificador SVM gaussiano medio es el que mayor precisión nos ofrece con unas ventanas de 1x8. En general en la gráfica 35, para esta ventana los clasificadores se comportan mejor que para el resto y a medida que se reduce el tamaño también lo hace el resultado.



Gráfica 36. Validación del modelo de la gráfica 35

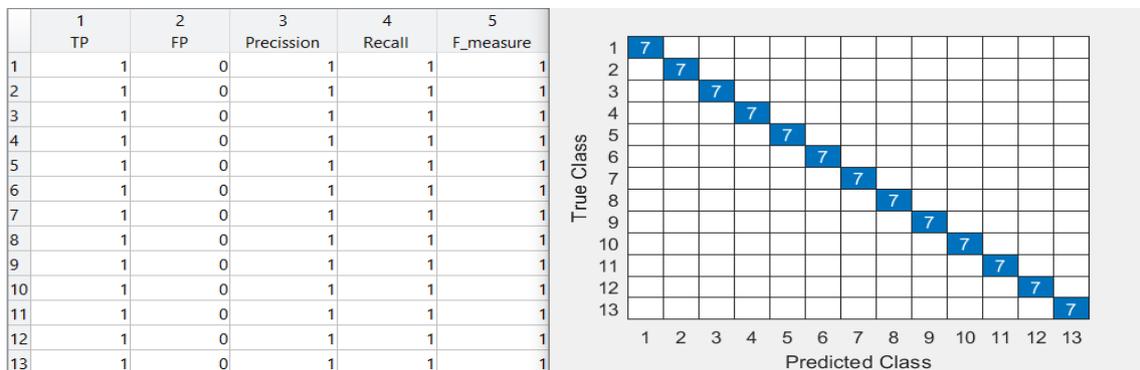
Usaremos el clasificador con más precisión, el SVM gaussiano medio, para representar la matriz de confusión y las tasas de acierto y error para LBP invariante a rotación con radio 1, de la gráfica 36, para ventanas columna.

Usando LBP invariante a rotación con radio 1 los mejores resultados son para la ventana de 1x1 donde podemos usar tanto K-NN coseno, fino, ponderado y cubico, también podemos usar el SVM gaussiano medio



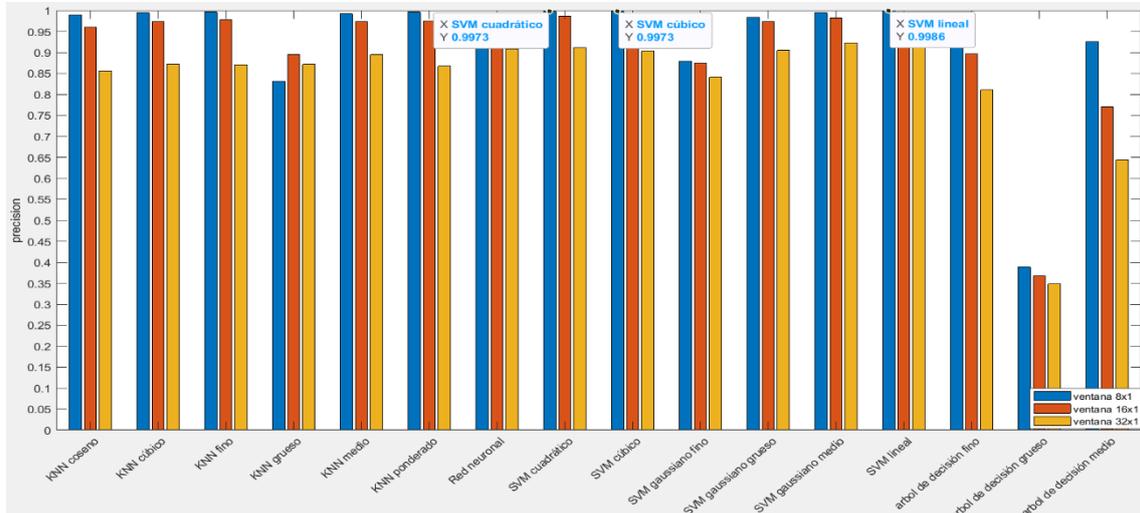
Gráfica 37. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación y con radio 3 en escala de grises

Em la gráfica 37, para LBP invariante a rotación con radio 3 en escala de grises son muchos los clasificadores que alcanzan la precisión máxima y, además, en más de un tipo de ventana. Cuatro de los seis K-NN alcanzan la máxima precisión para ventanas de 1x1 y de 2x2, mientras que los SVM que alcanza esta precisión solo lo hacen para la ventana 1x1.



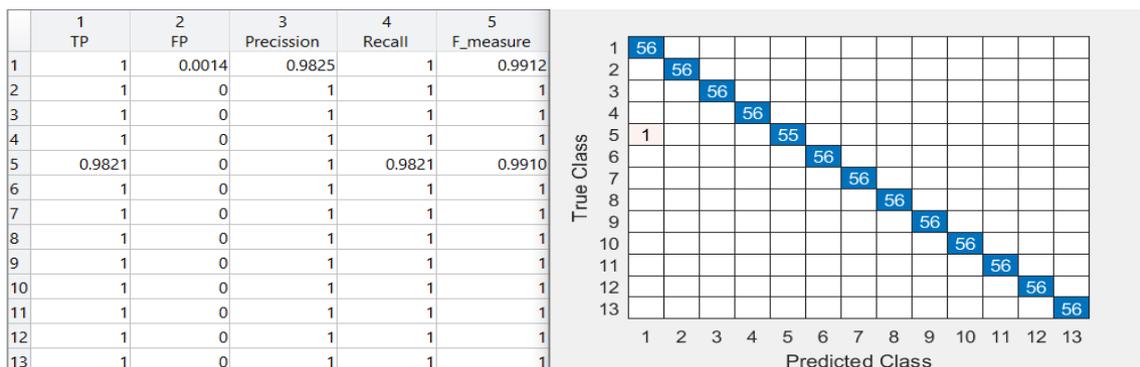
Gráfica 38. Validación del modelo de la gráfica 36

Hemos elegido el K-NN ponderado para representar la matriz de confusión y las tasas de acierto y error para LBP invariante a rotación con radio 3 para ventanas cuadradas de la gráfica 38.



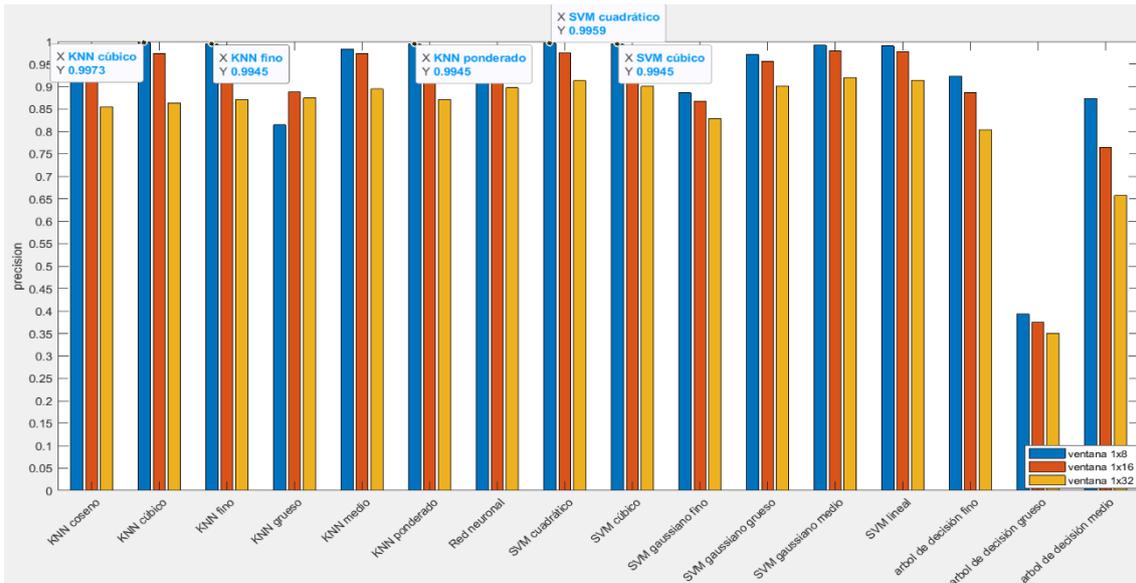
Gráfica 39. Comparación clasificadores para ventanas en filas para LBP invariante a rotación y con radio 3 en escala de grises

Por lo general en la gráfica 39, los clasificadores tienen mayor precisión para ventanas de 8x1 y a medida que el tamaño de la ventana disminuye también lo hace la precisión. El clasificador SVM lineal es el que mejor resultado ha dado a la hora de usar LBP invariante a rotación con radio 3 en escala de grises.



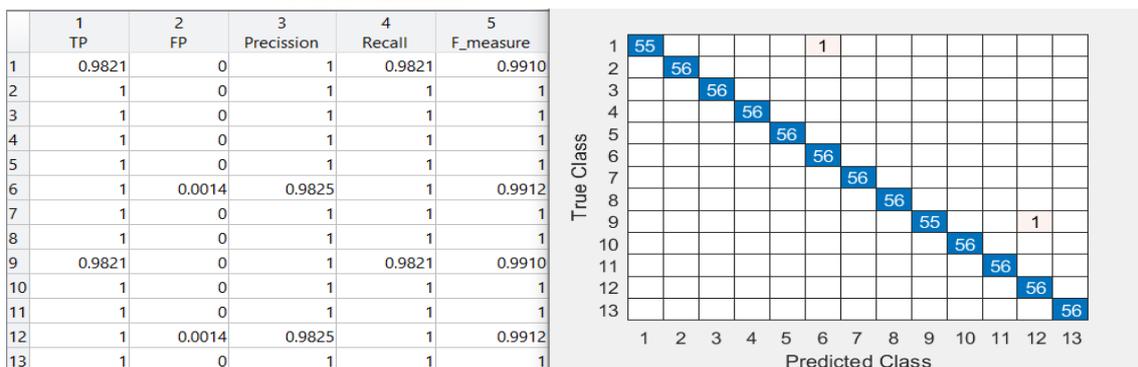
Gráfica 40. Validación del modelo de la gráfica 39

Usaremos el clasificador con más precisión, el SVM lineal, para representar la matriz de confusión y las tasas de acierto y error para LBP invariante a rotación con radio 3 para ventanas en fila de la gráfica 40.



Gráfica 41. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación y con radio 3 en escala de grises

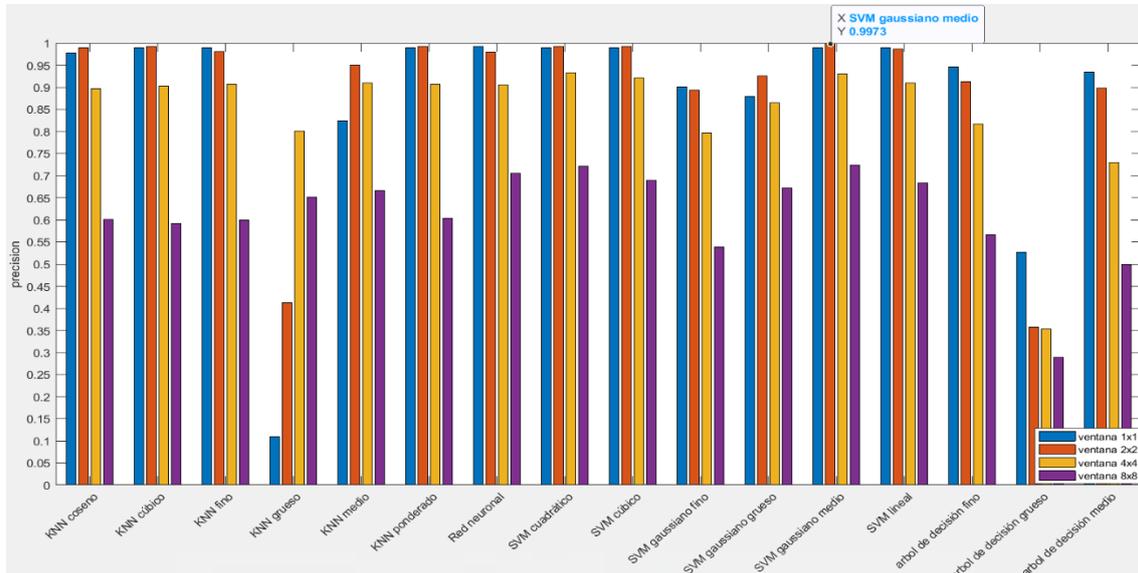
Se puede observar en la gráfica 41 que para la ventana de 1x8 se obtienen los mejores resultados en la mayoría de los clasificadores, y este valor va disminuyendo conforme lo hace el tamaño de la ventana. El mejor resultado viene por parte del SVL cuadrático para ventanas de 1x8, pero su valor no dista muchos del K-NN cúbico que es el siguiente de mayor precisión.



Gráfica 42. Validación del modelo de la gráfica 41

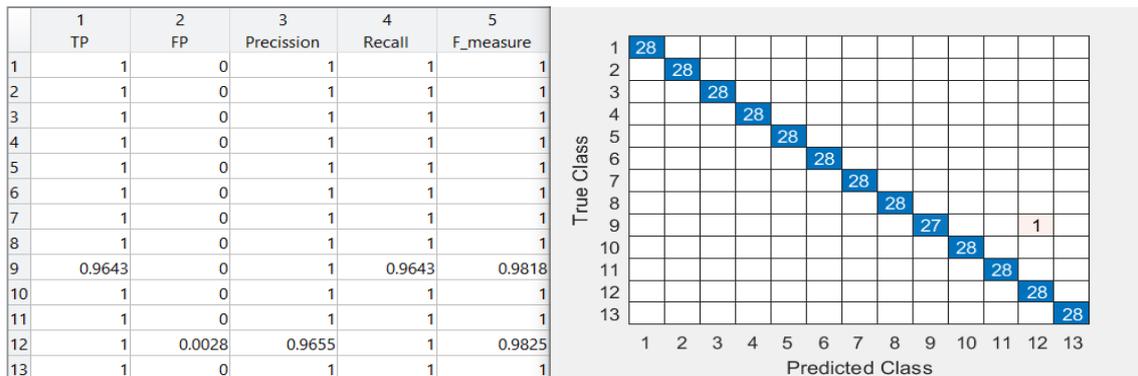
Usaremos el clasificador con más precisión, el K-NN cúbico, para representar la matriz de confusión y las tasas de acierto y error para LBP invariante a rotación con radio 3 para ventana en columnas de la gráfica 42.

En definitiva, los mejores resultados para LBP invariante a rotación con radio 3 en escala de grises se dan en ventanas de 1x1 y de 2x2 para clasificadores como SVM cúbico, K-NN ponderado, K-NN coseno, K-NN cúbico y K-NN fino.



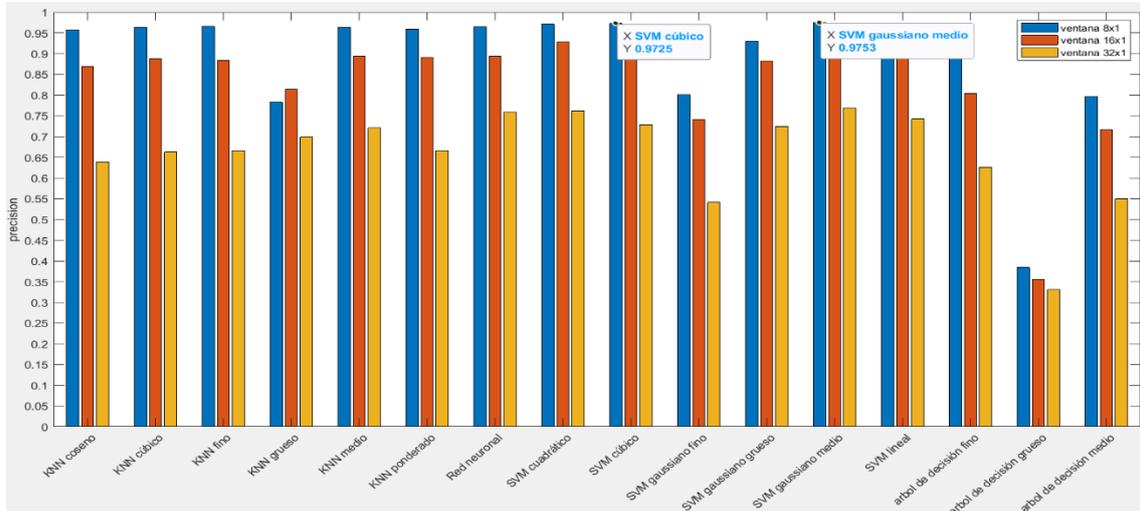
Gráfica 43. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación y con radio 5 en escala de grises

En la gráfica 43 los clasificadores para LBP invariante a rotación con radio 5 ofrecen sus mejores resultados para ventanas de 1x1 en unos casos y de 2x2 para otros, siendo el clasificador SVM gaussiano medio el que alcanza el mayor valor entre todos para ventanas de 2x2.



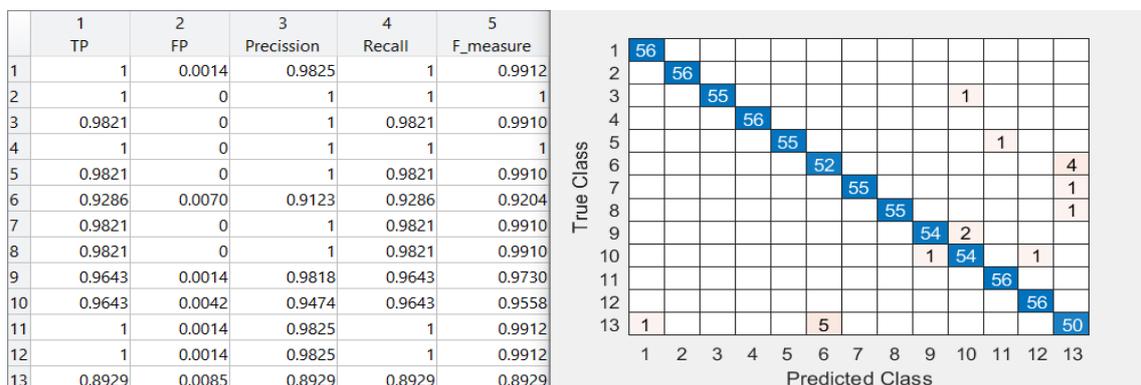
Gráfica 44. Validación del modelo de la gráfica 43

Usaremos el clasificador con más precisión, el SVM gaussiano medio, para representar la matriz de confusión y las tasas de acierto y error para LBP invariante a rotación con radio 5 para ventanas cuadradas de la gráfica 44.



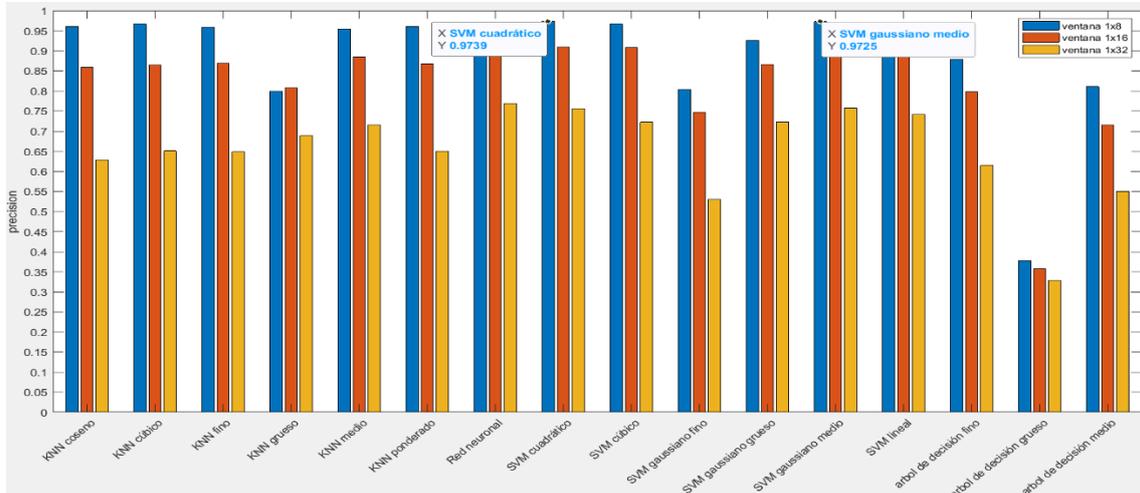
Gráfica 45. Comparación clasificadores para ventanas en filas para LBP invariante a rotación y con radio 5 en escala de grises

En la gráfica 45, haciendo ventanas en fila usando LBP invariante a rotación y con radio 5 en escala de grises el clasificador que mejor se comporta es el SVM gaussiano medio para ventanas de 8x1. En la mayoría de los clasificadores es esta ventana la que les hace alcanzar la mayor precisión y conforme se reduce el tamaño de la ventana también baja la precisión.



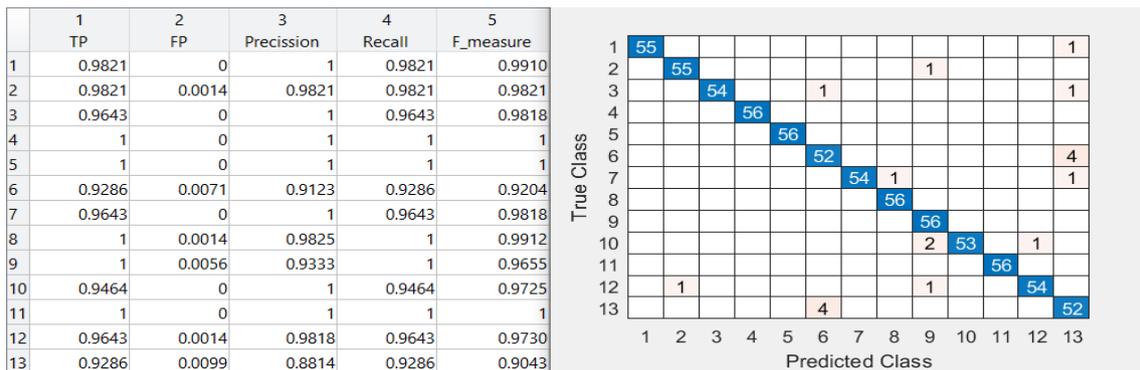
Gráfica 46. Validación del modelo de la gráfica 45

Usaremos el clasificador con más precisión, el SVM gaussiano medio, para representar la matriz de confusión y las tasas de acierto y error para LBP invariante a rotación con radio 5 para ventanas en fila.



Gráfica 47. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación y con radio 5 en escala de grises

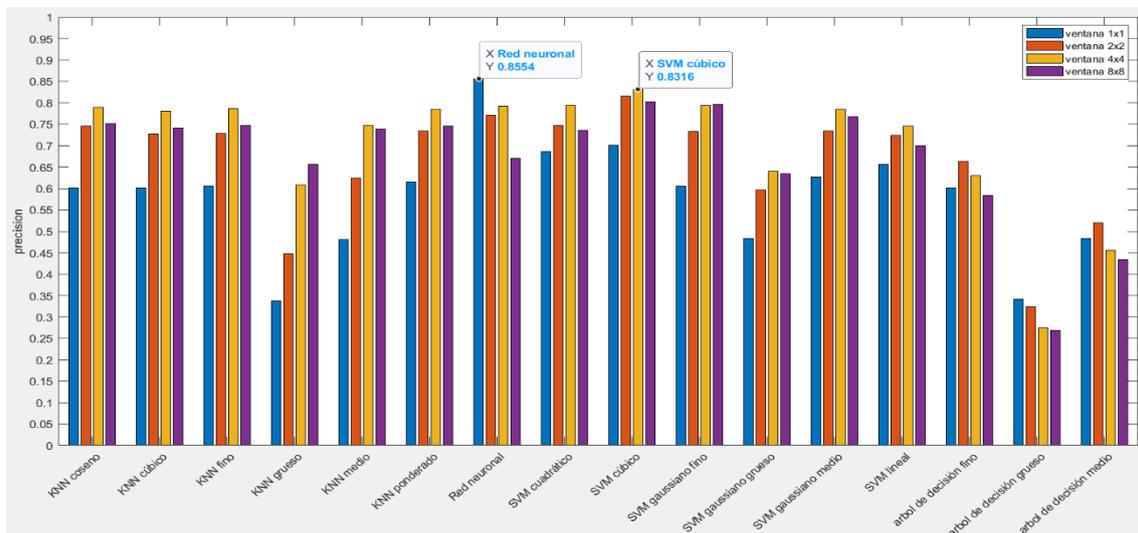
En la gráfica 47, la ventana de 1x8 es la que mejor resultados proporciona para LBP invariante a rotación con radio 5, y a medida que el tamaño de la ventana decrece también lo hace la precisión. El mejor resultado lo da el clasificador SVM cuadrático para ventanas 8x1.



Gráfica 48. Validación del modelo de la gráfica 47

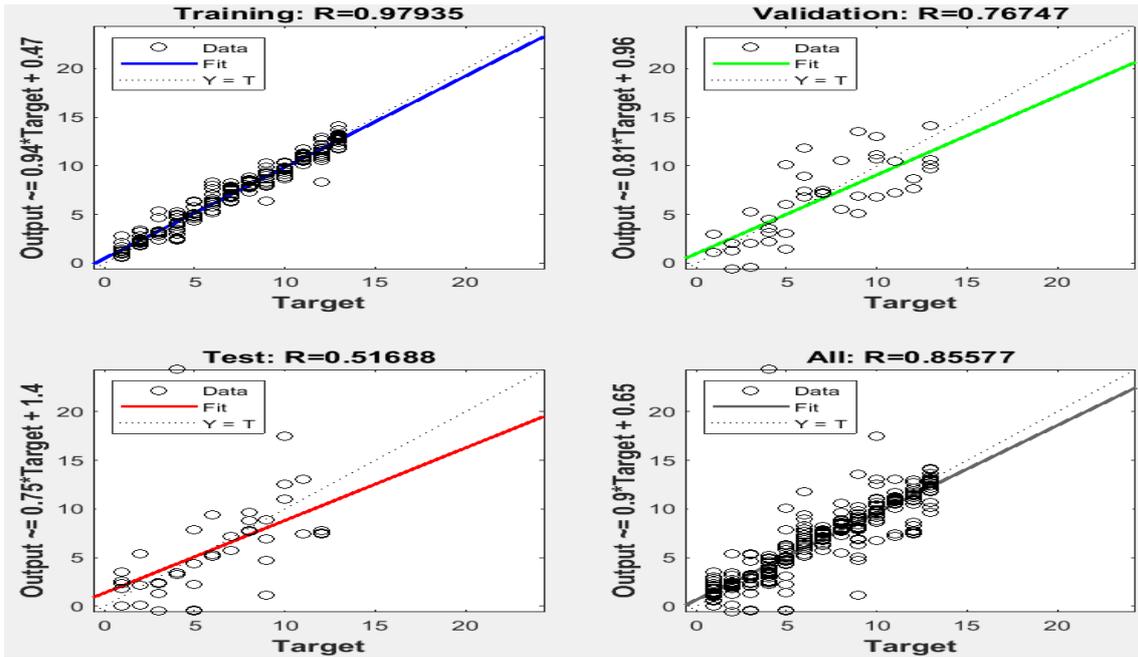
Usaremos el clasificador con más precisión, el SVM cuadrático, para representar la matriz de confusión y las tasas de acierto y error para LBP invariante a rotación con radio 5 para ventanas en columna de la gráfica 48.

## 4.1.2 Comparación en RGB con el segundo data set



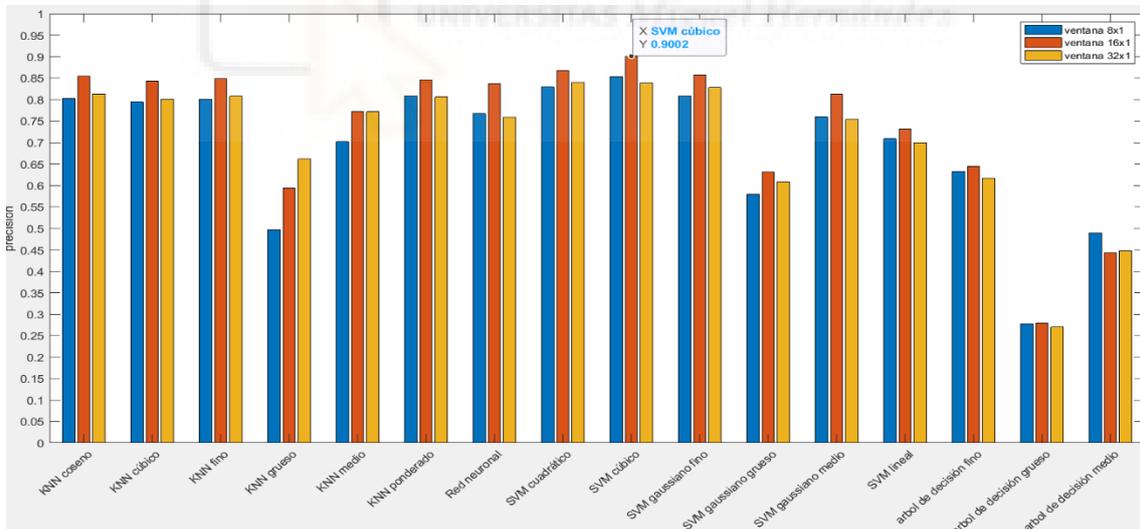
Gráfica 49. Comparación clasificadores para ventanas cuadradas para momentos de histograma en RGB

En la gráfica 49, usando los momentos de histograma en RGB para ventanas cuadradas vemos que la mayoría de los clasificadores tienen más precisión para ventanas de 4x4 y esta tiene valores muy cercanos, aun así el que mejor se ajusta es la red neuronal para una ventana de 1x1.



Gráfica 50. Regresión lineal de la red neuronal

En la gráfica 50 vemos como la red neuronal se adaptó a los datos usando momentos de histograma en RGB.



Gráfica 51. Comparación clasificadores para ventanas en filas para momentos de histograma en RGB

En la gráfica 51, siguiendo con el análisis en ventanas en filas, vemos que el clasificador SVM cúbico para ventanas de 1x16 es el que mejor precisión tiene usando momentos de histograma en RGB. También vemos que los mejores

resultados de los clasificadores, generalmente, se produce en las ventanas de 16x1.

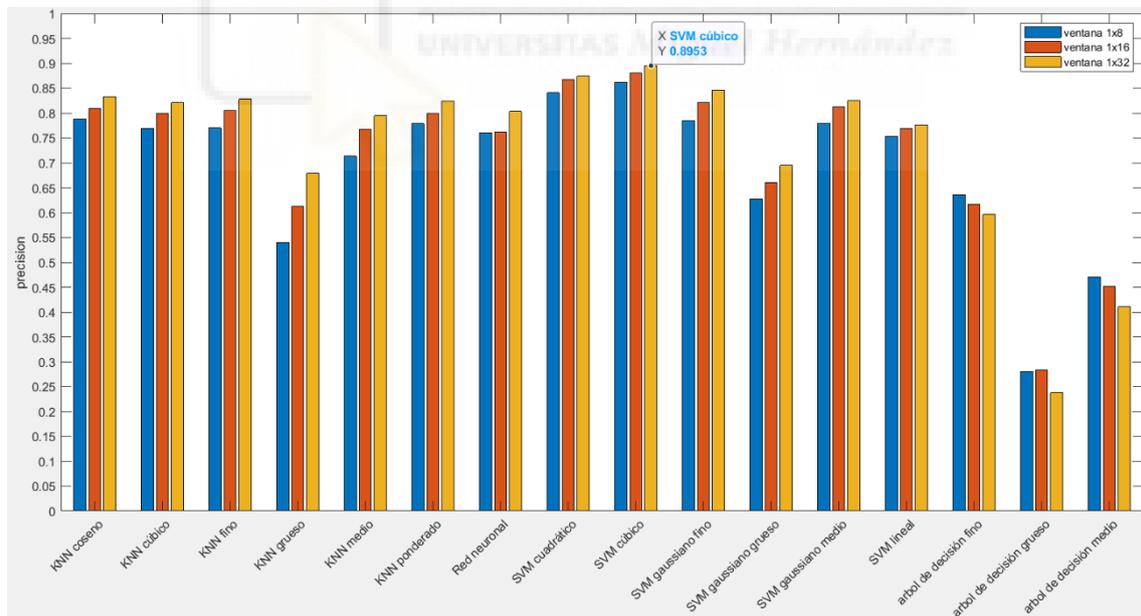
	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	0.9345	0.0025	0.9691	0.9345	0.9515
2	0.9375	0.0030	0.9633	0.9375	0.9502
3	0.8601	0.0094	0.8865	0.8601	0.8731
4	0.9286	0.0114	0.8739	0.9286	0.9004
5	0.9107	0.0089	0.8974	0.9107	0.9040
6	0.8929	0.0112	0.8721	0.8929	0.8824
7	0.9583	0.0028	0.9670	0.9583	0.9626
8	0.8214	0.0152	0.8214	0.8214	0.8214
9	0.9494	0.0025	0.9696	0.9494	0.9594
10	0.9911	0.0020	0.9765	0.9911	0.9838
11	0.8036	0.0119	0.8517	0.8036	0.8270
12	0.8929	0.0150	0.8357	0.8929	0.8633
13	0.8304	0.0140	0.8353	0.8304	0.8328

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	314		1	3		1	1		6	3	1		6
2		315	2		3	1							5 10
3			289	26		3		1	3				4 10
4	1		12	312									3 8
5					306		4	13		1	12		
6			1			300		1					34
7				3		322	4	1		5			1
8	1	2	2		7	8		276		1	24	5	10
9	5	1	4	2	3				319				2
10	1									333			1 1
11	1	3			19	1	6	29			270	3	4
12		1	1			30		1				300	3
13	1	5	14	14				11		3	5	4	279

Gráfica 52. Validación del modelo de la gráfica 51

Usaremos el clasificador con más precisión, el SVM cúbico, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en RGB para ventanas en fila de la gráfica 52.



Gráfica 53. Comparación clasificadores para ventanas en columnas para momentos de histograma en RGB

Generalmente en la gráfica 53, vemos que los clasificadores se comportan mejor para ventanas de 1x32 y a medida que la ventana es más grande la

precisión disminuye. El clasificador que más precisión tiene usando momentos de histograma en RGB es el SVM cúbico para ventanas de 1x32.

	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9598	0.0024	0.9714	0.9598	0.9656
2	0.8571	0.0087	0.8944	0.8571	0.8754
3	0.8795	0.0080	0.9037	0.8795	0.8914
4	0.9271	0.0088	0.9003	0.9271	0.9135
5	0.9003	0.0115	0.8705	0.9003	0.8851
6	0.9092	0.0110	0.8766	0.9092	0.8926
7	0.9792	0.0019	0.9777	0.9792	0.9784
8	0.7366	0.0204	0.7557	0.7366	0.7460
9	0.9628	0.0029	0.9657	0.9628	0.9642
10	0.9911	0.0011	0.9867	0.9911	0.9889
11	0.8304	0.0147	0.8291	0.8304	0.8297
12	0.9137	0.0100	0.8873	0.9137	0.9003
13	0.8051	0.0142	0.8298	0.8051	0.8172

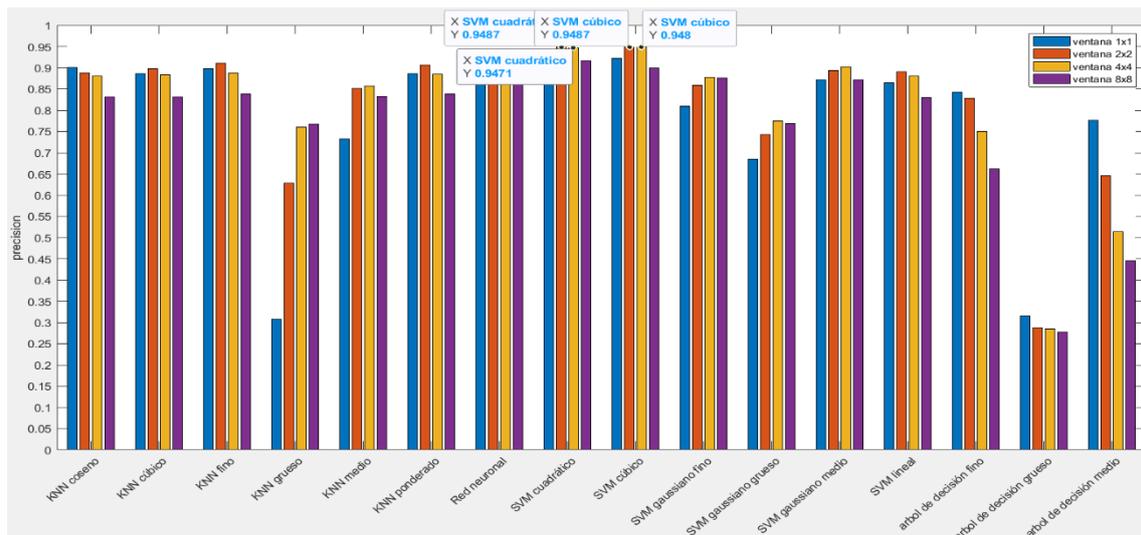
  

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13	
1	645								8	5	2		10	
2		576	2	1	6	18		28					18	23
3			591	31	1	7		4	8		1	5	24	
4	1		28	623		1						1	18	
5		3	2		605		5	29			26	1	1	
6		9				611		8			5	39		
7					8		658				6			
8	1	14	4	3	36	19	1	495	1		69	5	24	
9	5		8	2	1			1	647		2		6	
10		3								666			3	
11	1	6			32	3	9	54	4		558	3	2	
12		9		1		35	13					614		
13	11	24	19	29	6	3		23	2	4	4	6	541	

Gráfica 54. Validación del modelo de la gráfica 53

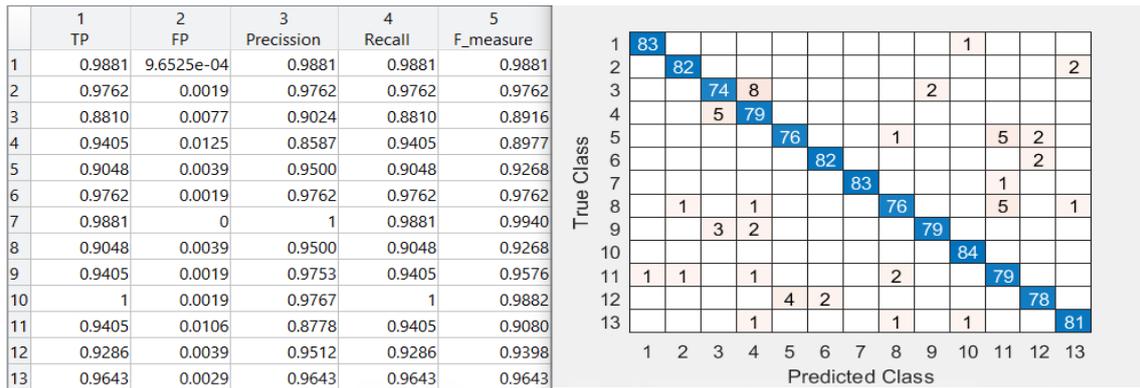
Usaremos el clasificador con más precisión, el SVM cúbico, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en RGB para ventanas en columna de la gráfica 54.

Después de ver todas las gráficas, el clasificador SVM cúbico para ventanas de 16x1 es el que mayor precisión nos da, y en general para los tres tipos de ventana es el que mejor se comporta.



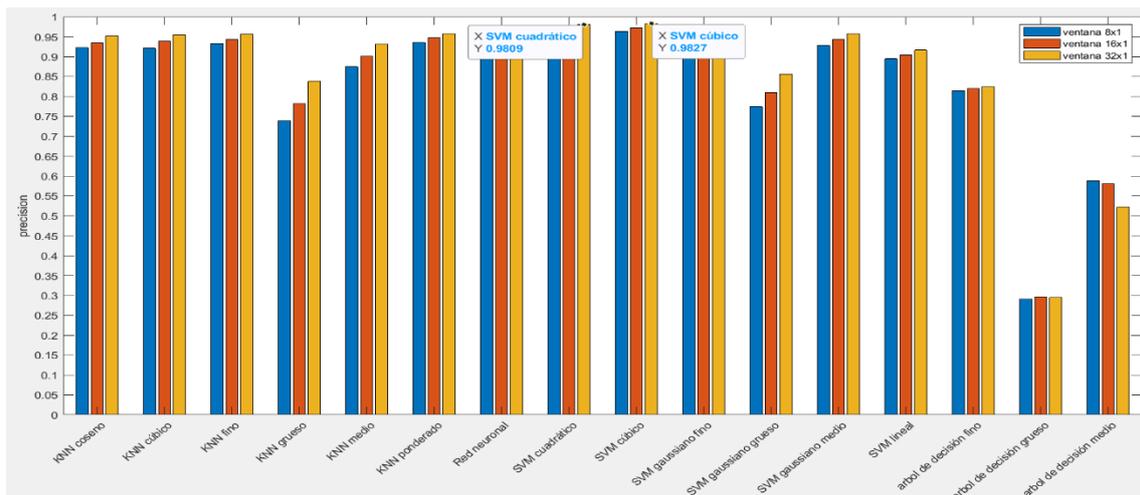
Gráfica 55. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en RGB

En la gráfica 55, dependiendo del clasificador el mejor resultado se produce en un tipo de ventana u otra. Pero, usando la matriz de coocurrencia en RGB, los clasificadores SVM cúbico y SVM cuadrático son los que mejor resultado ofrecen, ambos tienen el mismo valor cuando usamos la ventana de 2x2, sin embargo, el resultado de estos mismos clasificadores para ventanas de 4x4 está muy cerca del antes mencionado.



Gráfica 56. Validación del modelo de la gráfica 55

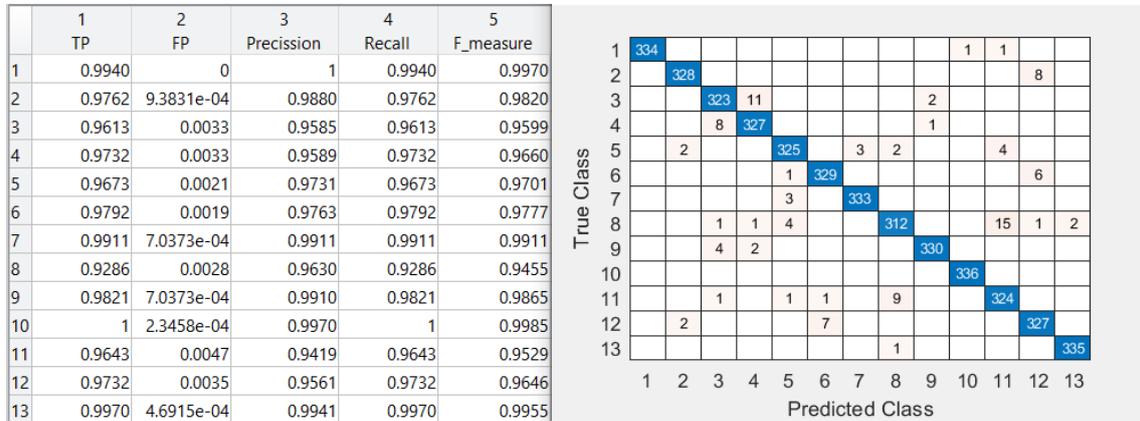
Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en RGB para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 56.



Gráfica 57. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en RGB

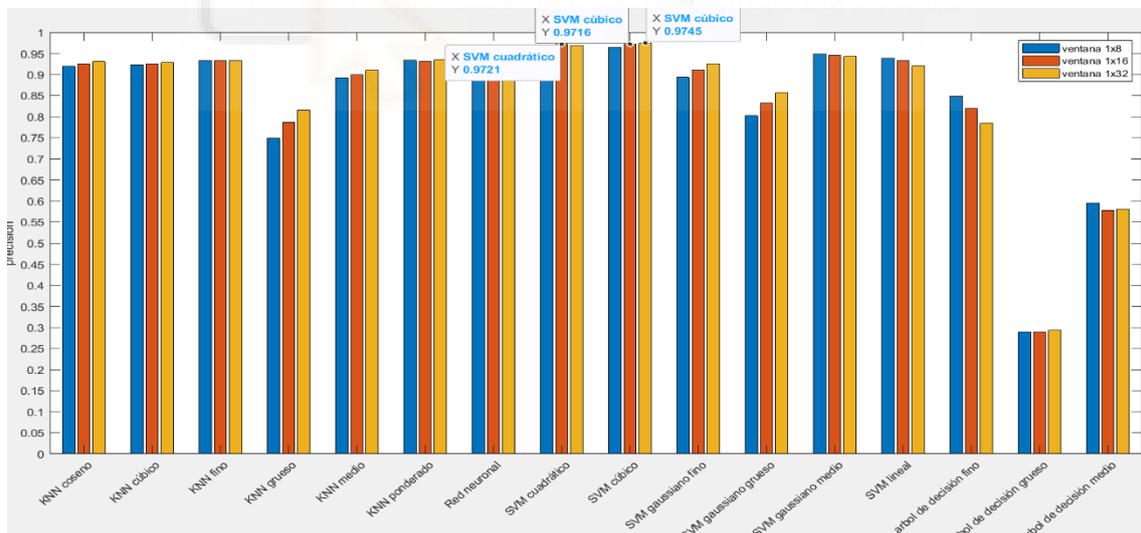
Vemos en la gráfica 57 que usando la matriz de coocurrencia en RGB el clasificador SVM cúbico es el que mejor se comporta cuando escogemos la

ventana 32x1. También se puede apreciar que los clasificadores, generalmente, ofrecen el mejor resultado para ese tipo de ventana y a medida que el tamaño de la ventana aumenta, la precisión decrece.



Gráfica 58. Validación del modelo de la gráfica 57

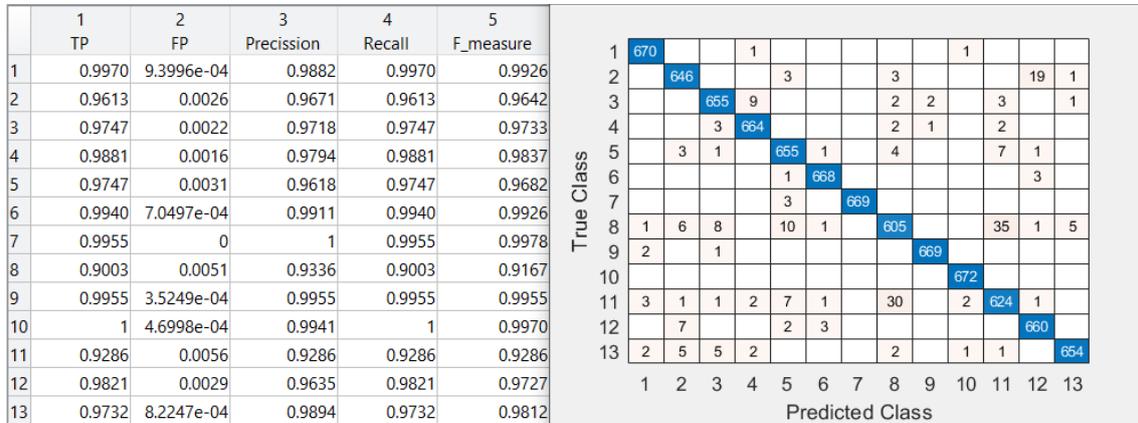
Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en RGB para ventanas en filas de la gráfica 58.



Gráfica 59. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en RGB

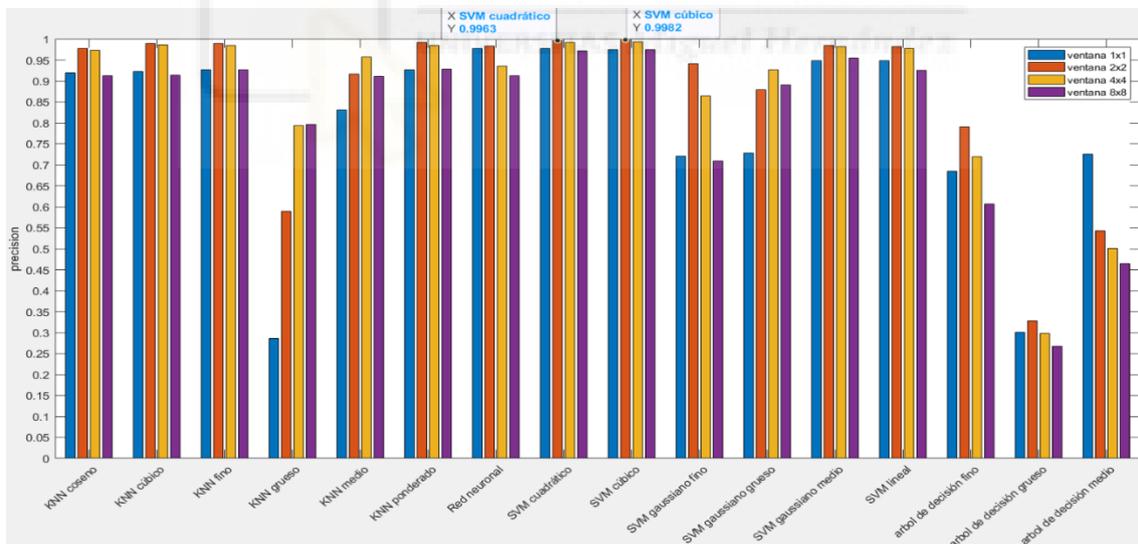
La gráfica 59 muestra el comportamiento de los clasificadores cuando usamos las ventanas en columna con la matriz de coocurrencia en RGB, vemos que el mejor resultado nos lo da el SVM cúbico para ventanas de 1x32 seguido muy de

cerca por el resultado del mismo clasificador para ventanas de 1x16 y el SVM cuadrático para ventanas de 1x16.



Gráfica 60. Validación del modelo de la gráfica 59

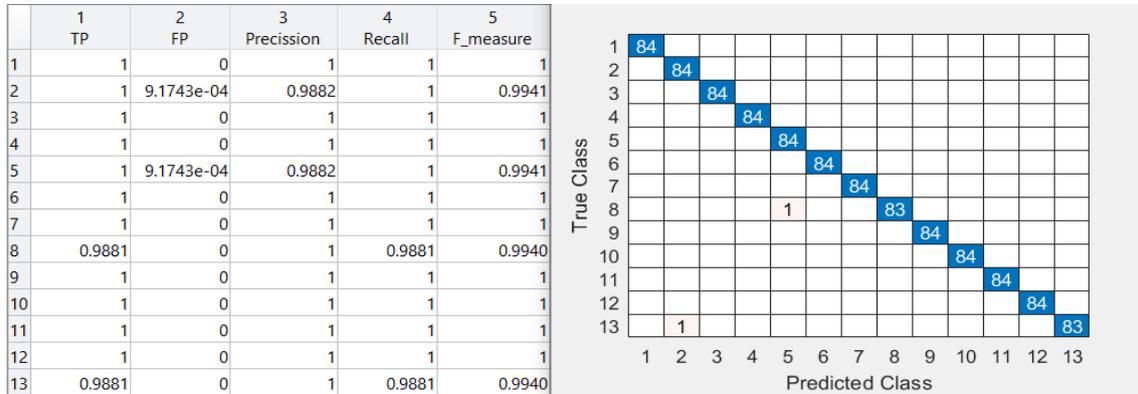
Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en RGB para ventanas en columnas, es del clasificador SVM cúbico gráfica 60.



Gráfica 61. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en RGB

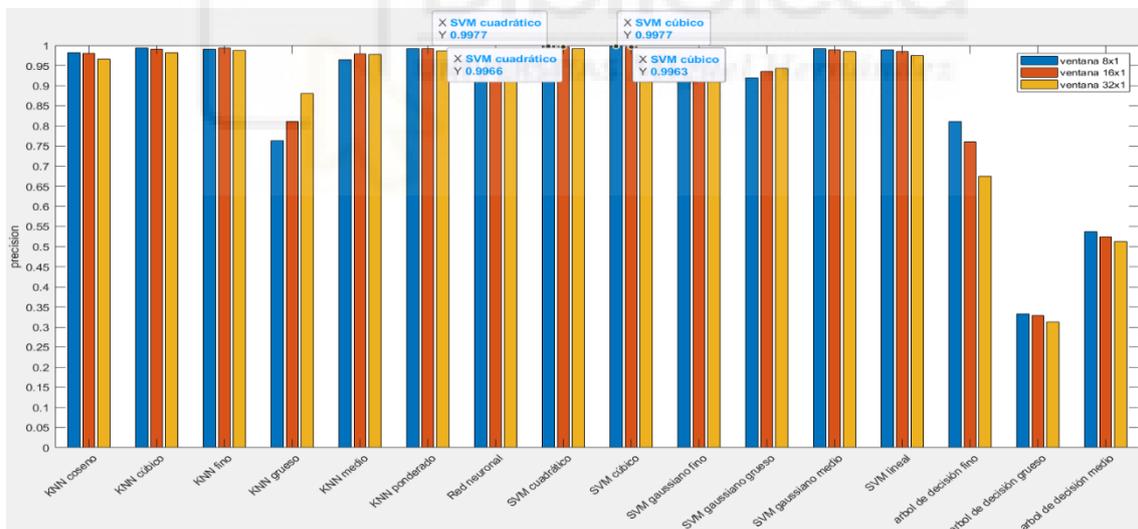
En la gráfica 61, usando LBP variante a rotación en RGB vemos que, en la mayoría de los clasificadores, los valores de las ventanas 2x2 y 4x4 son muy similares, siendo en la ventana 2x2 en la que mayor valor alcanzan. El

clasificador SVM cúbico es el que mayor precisión tiene usando la ventana de 2x2.



Gráfica 62. Validación del modelo de la gráfica 61

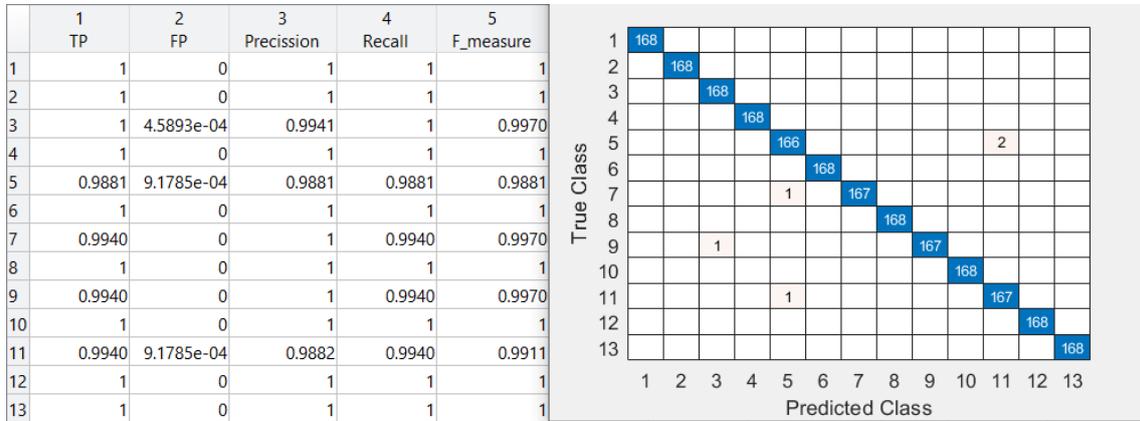
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en RGB para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 62.



Gráfica 63. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en RGB

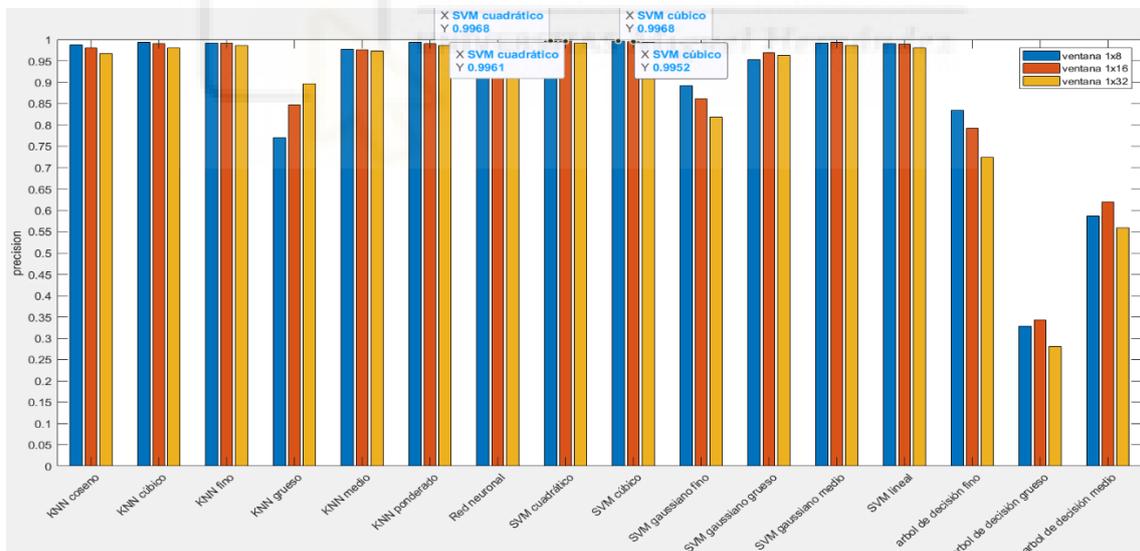
Los clasificadores no alcanzan su valor máximo en una ventana específica, va cambiando según el clasificador. Tenemos dos clasificadores que usando LBP variante a rotación con radio 1 alcanzan el valor más alto de la gráfica 63, son

el SVM cuadrático y el SVM cúbico para ventanas de 8x1, pero para estos mismos clasificadores el valor para ventanas de 16x1 es muy cercano.



Gráfica 64. Validación del modelo de la gráfica 63

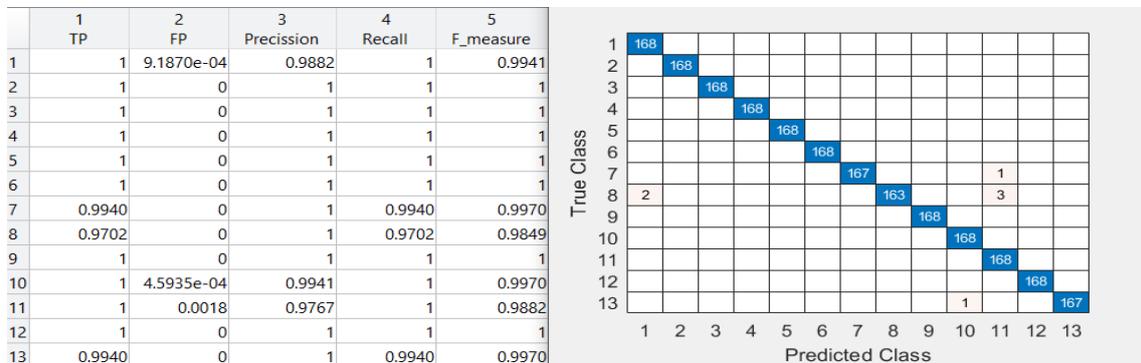
Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en RGB para ventanas en filas de la gráfica 64.



Gráfica 65. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en RGB

Vemos en la gráfica 65 que al analizar las ventanas en columna para LBP variante a rotación con radio 1 en RGB los valores de un mismo clasificador las diferentes ventanas tienen valores cercanos, hay excepciones. El mejor

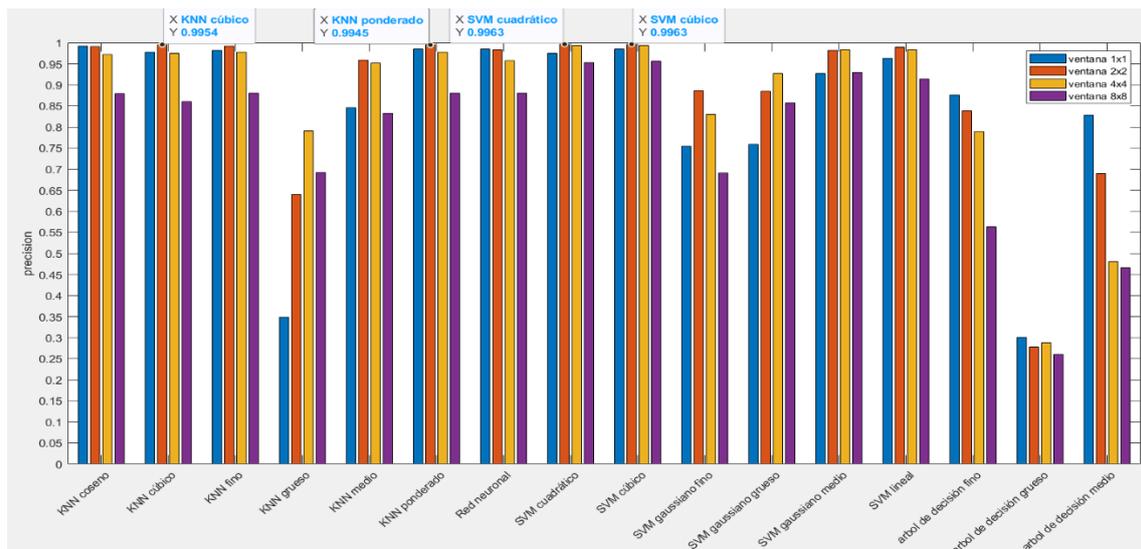
resultado es alcanzado tanto por el clasificador SVM cuadrático y SVM cúbico para ventanas de 1x8.



Gráfica 66. Validación del modelo de la gráfica 65

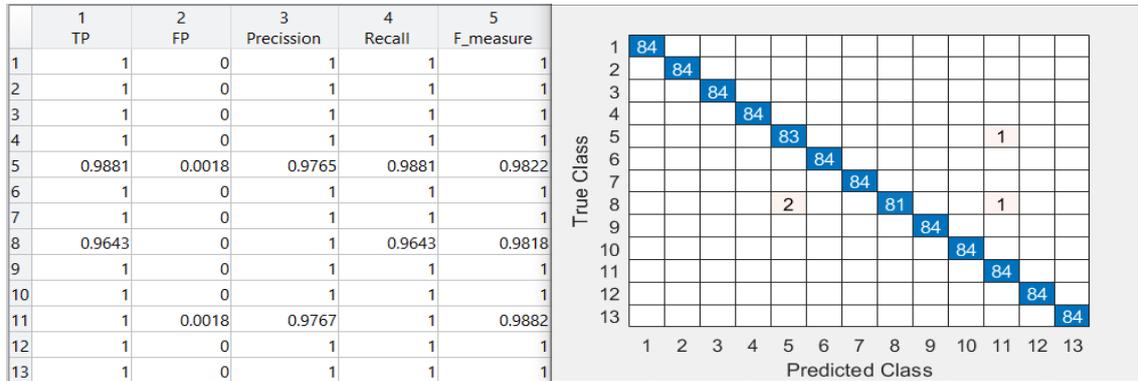
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en RGB para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 63.

Queda claro que el clasificador SVM cúbico es el que, independientemente de la ventana, siempre alcanza el mejor resultado respecto al resto de clasificadores. Siendo para la ventana 2x2 el de mayor valor para LBP variante a rotación con radio 1 en RGB.



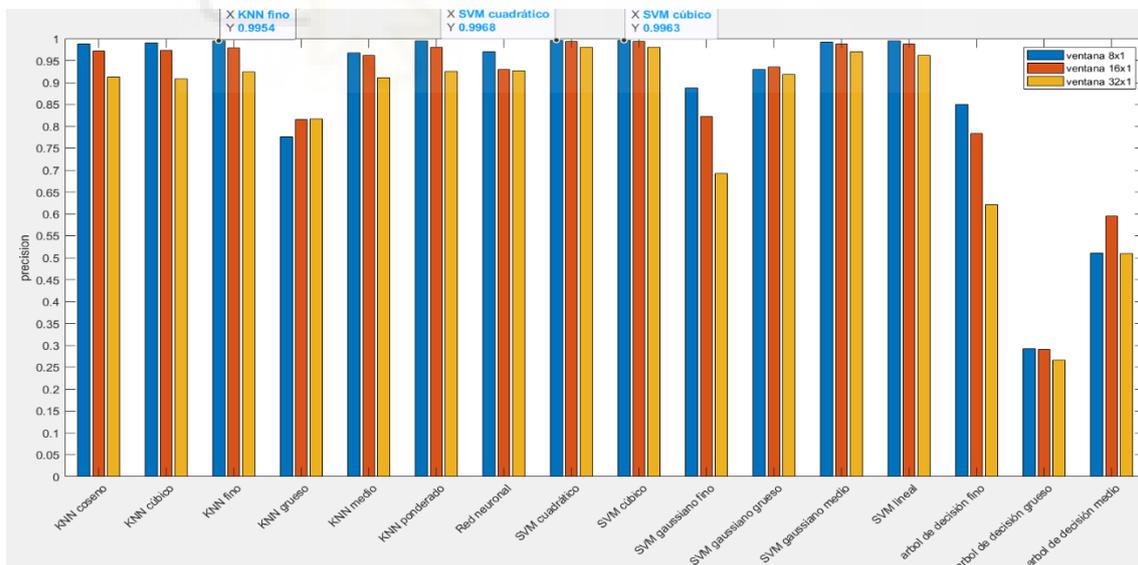
Gráfica 67. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en RGB

En la gráfica 67, usando LBP variante a rotación con radio 3 en RGB los valores más altos en general se encuentran cuando usamos ventanas de 2x2, siendo estas ventanas las que logran la mayor precisión con los clasificadores SVM cuadrático y SVM cúbico.



Gráfica 68. Validación del modelo de la gráfica 67

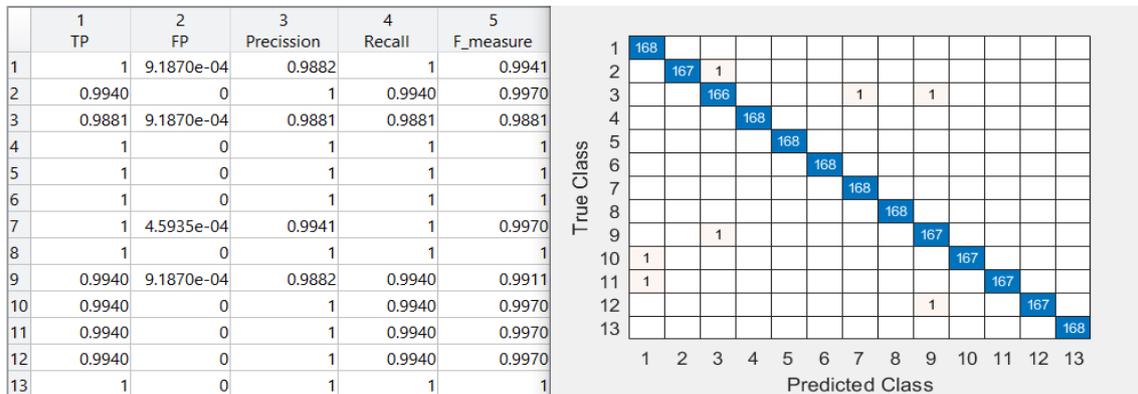
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en RGB para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 68.



Gráfica 69. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en RGB

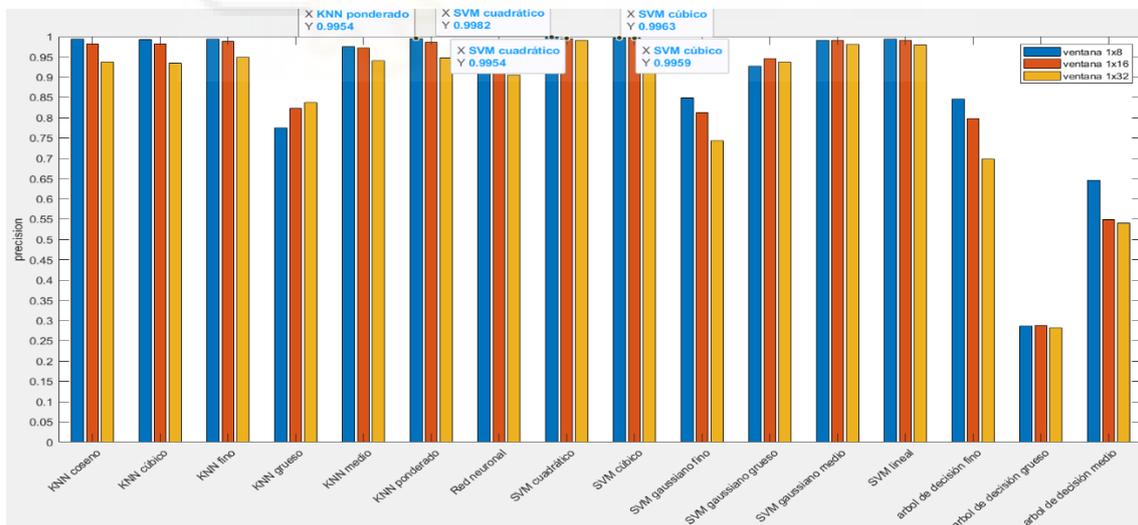
Analizando las ventanas en filas para LBP variante a rotación con radio 3 en RGB, vemos en la gráfica 69 que la gran mayoría de los clasificadores

estudiados alcanzan su valor más alto para las ventanas de 8x1, siendo el clasificador SVM cuadrático el que alcanza el valor más alto. Cabe destacar que algunos valores de otros clasificadores están muy cerca del valor del SVM cuadrático.



Gráfica 70. Validación del modelo de la gráfica 69

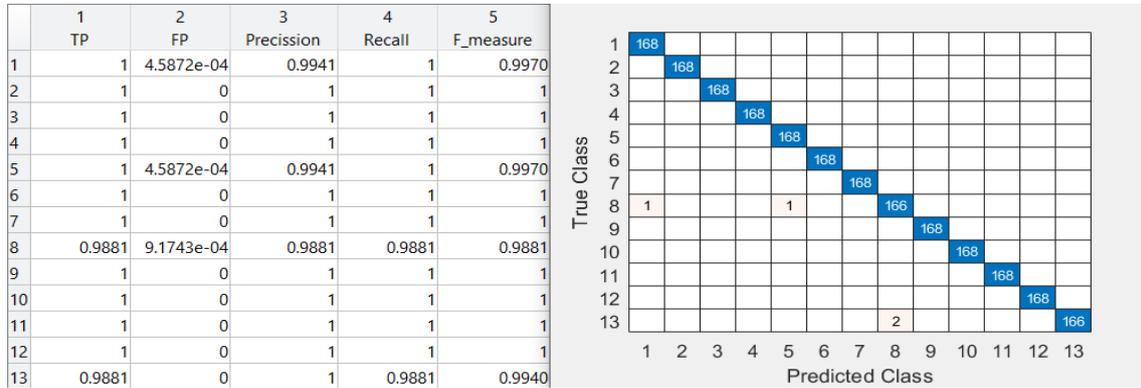
Sacamos del clasificador SVM cuadrático esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en RGB para ventanas en filas de la gráfica 70.



Gráfica 71. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en RGB

Podemos observar en la gráfica 71 que los resultados más altos usando LBP variante a rotación con radio 3 en RGB se dan cuando usamos las ventanas de

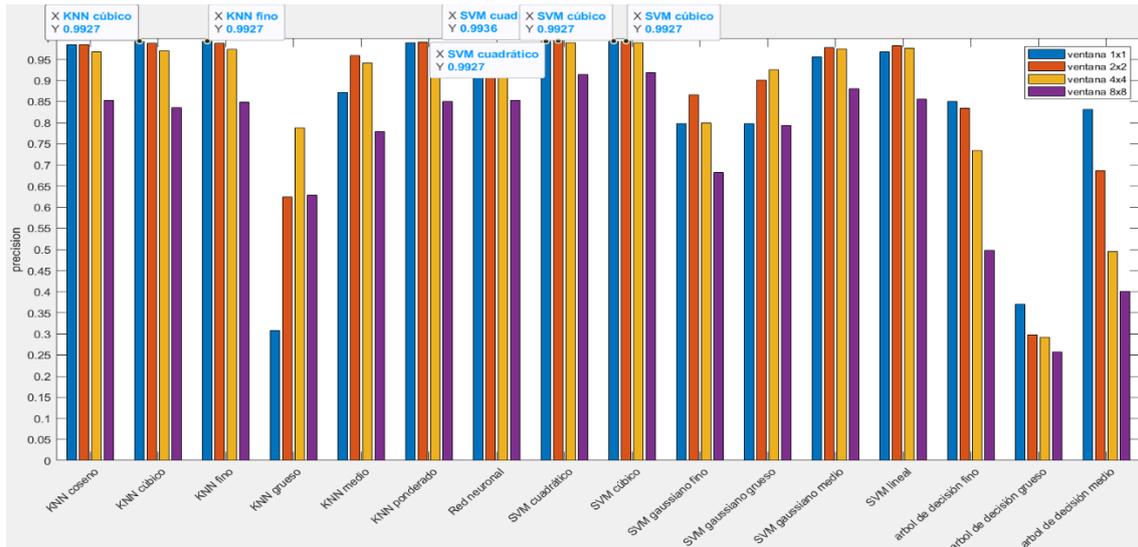
1x8. Para estas ventanas el clasificador SVM cuadrático es el que mayor valor alcanza seguido de cerca por el cúbico. Además, podemos ver que para ventanas de 1x16 los valores de estos mismos clasificadores tampoco distan mucho de los valores de las ventanas de 1x8.



Gráfica 72. Validación del modelo de la gráfica 71

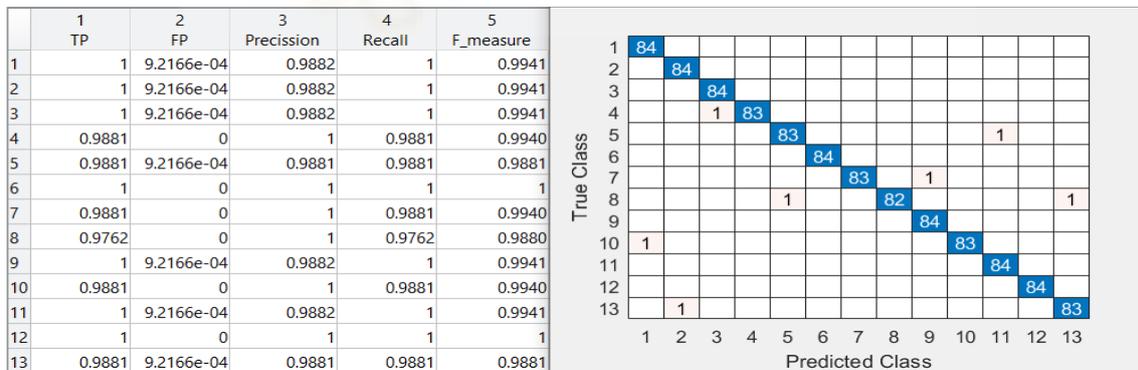
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en RGB para ventanas en columnas, es del clasificador SVM cuadrático.

Hemos comprobado que para LBP variante a rotación con radio 3 en RGB el clasificador SVM cuadrático es el que mejor se comporta, y no solo para un tipo de ventana. Es por eso que se considera este clasificador el mejor para este caso.



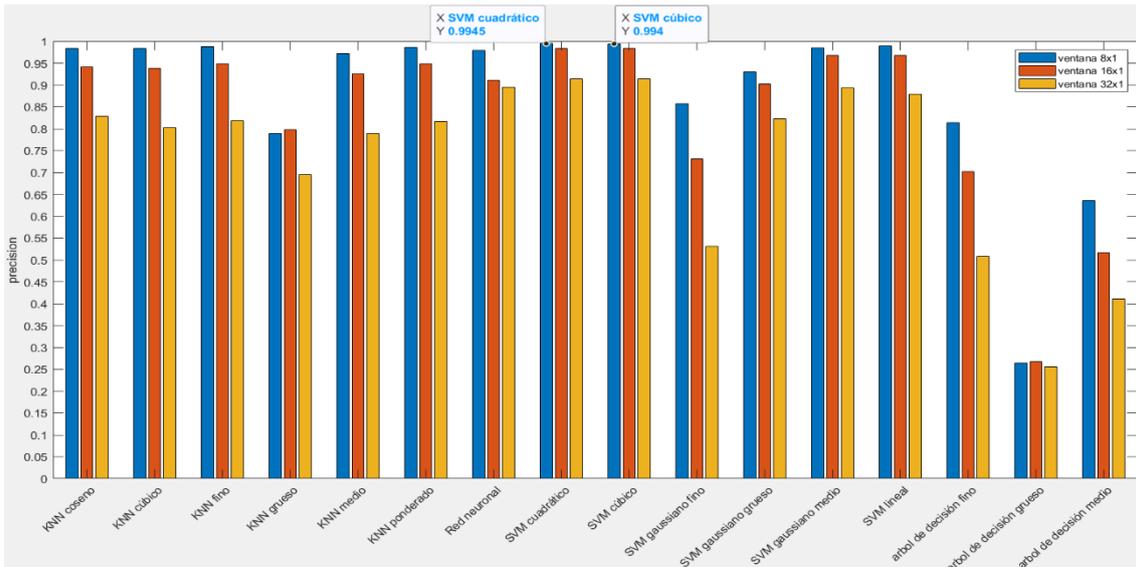
Gráfica 73. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en RGB

Ahora analizaremos en la gráfica 73 para ventanas cuadradas el uso de LBP variante a rotación con radio 5 en RGB, el valor más alto está localizado en la ventana 2x2 del clasificador SVM cuadrático. Hay que mencionar, que este valor máximo es muy cercano al valor ofrecido por otros clasificadores o incluso para el mismo clasificador, pero usando una ventana de 1x1.



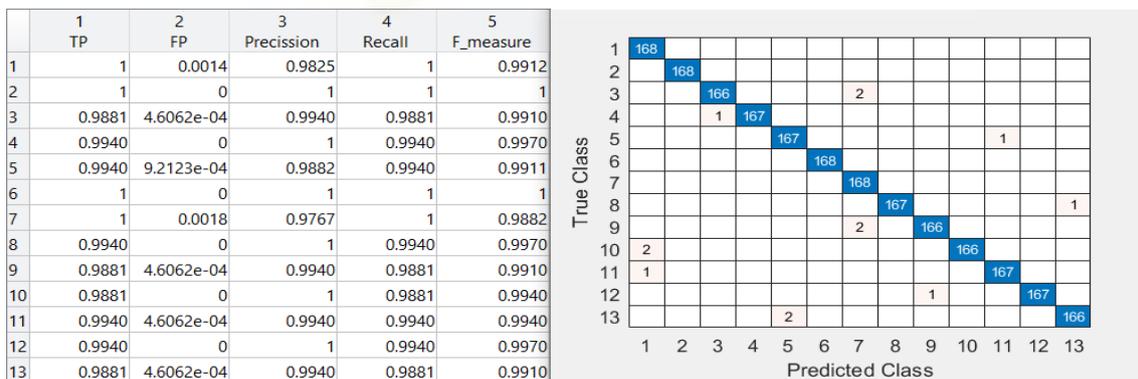
Gráfica 74. Validación del modelo de la gráfica 73

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en RGB para ventanas cuadradas, es del clasificador SVM cuadrático de la gráfica 74.



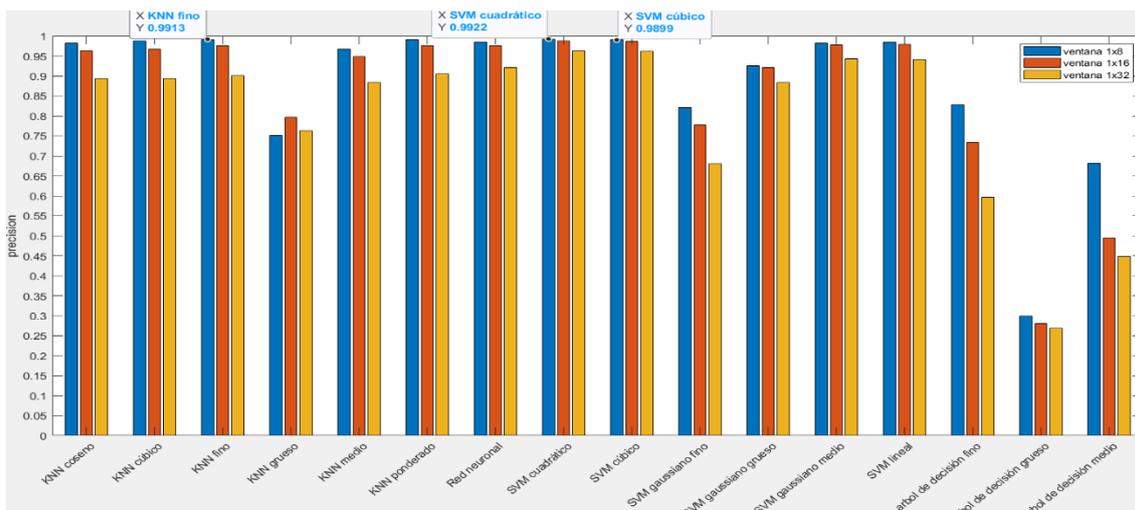
Gráfica 75. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en RGB

En la gráfica 75 el mejor clasificador usando LBP variante a rotación con radio 5 en RGB con ventanas en fila es el SVM cuadrático para ventanas de 8x1, seguido muy de cerca por el SVM cúbico para el mismo tamaño de ventana. También, podemos ver como a medida que se disminuye el tamaño de la ventana también disminuye la precisión del clasificador.



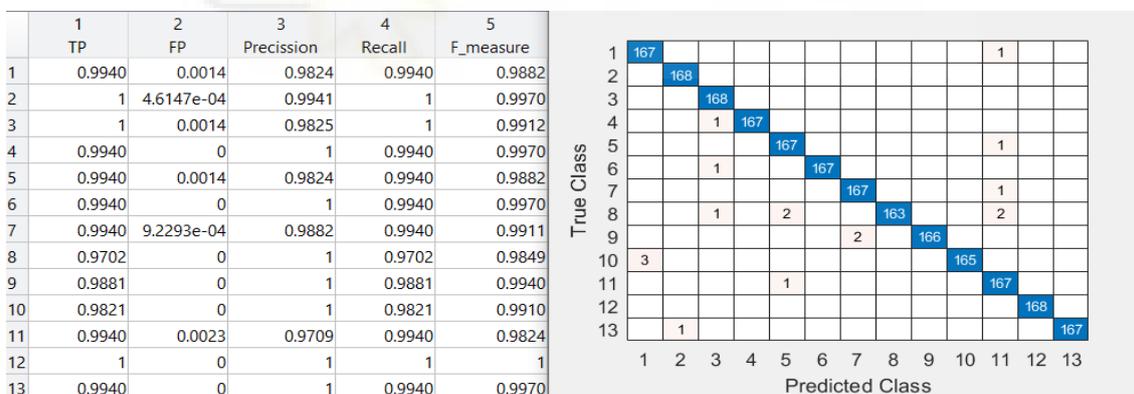
Gráfica 76. Validación del modelo de la gráfica 75

Sacamos del clasificador SVM cuadrático esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en RGB para ventanas en filas de la gráfica 76.



Gráfica 77. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en RGB

Terminando de analizar el LBP variante a rotación con radio 5 en RGB, vemos en la gráfica 77 que para ventanas en columnas los clasificadores se comportan mejor para el tamaño de 1x8 y conforme este tamaño disminuye, el resultado empeora. El mejor resultado lo encontramos en el clasificador SVM cuadrático para la ventana de 1x8.

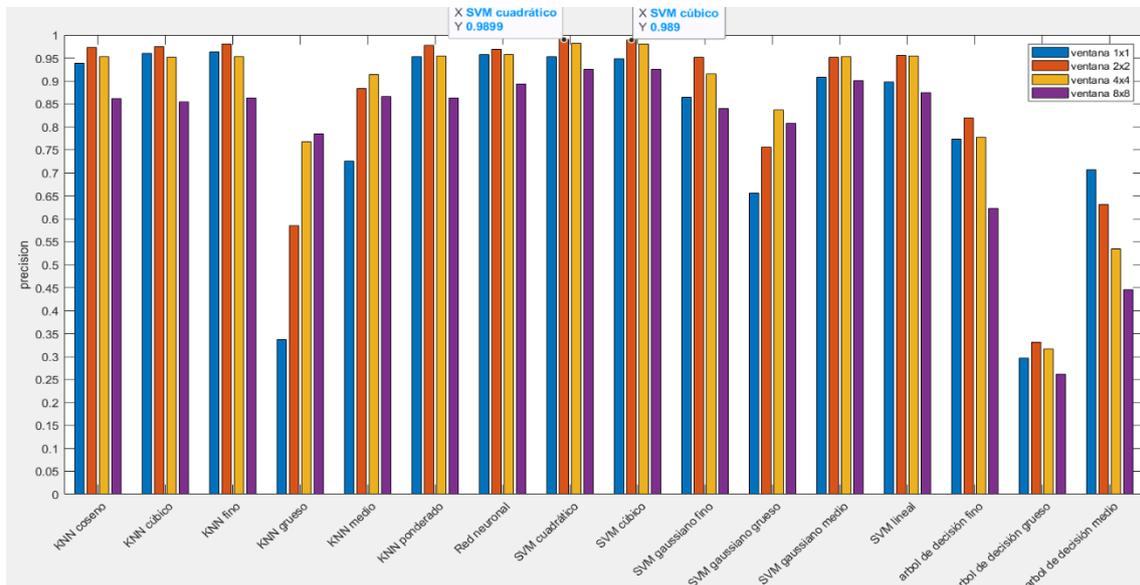


Gráfica 78. Validación del modelo de la gráfica 77

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en RGB para ventanas en columnas, es del clasificador SVM cuadrático de la gráfica 78.

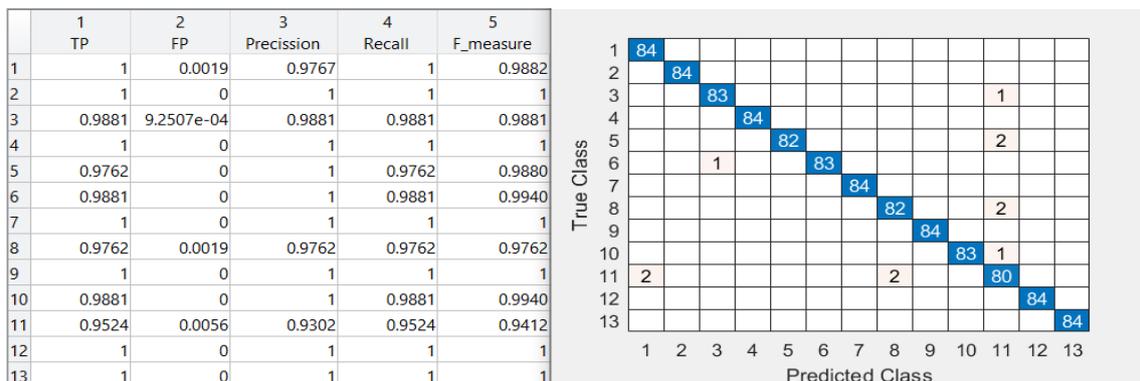
Viendo el comportamiento de los clasificadores usando LBP variante a rotación con radio 5 en RGB, que el clasificador SVM cuadrático es el que por lo general

mejor se comporta, y, específicamente, para la ventana de 8x1 es el resultado más alto.



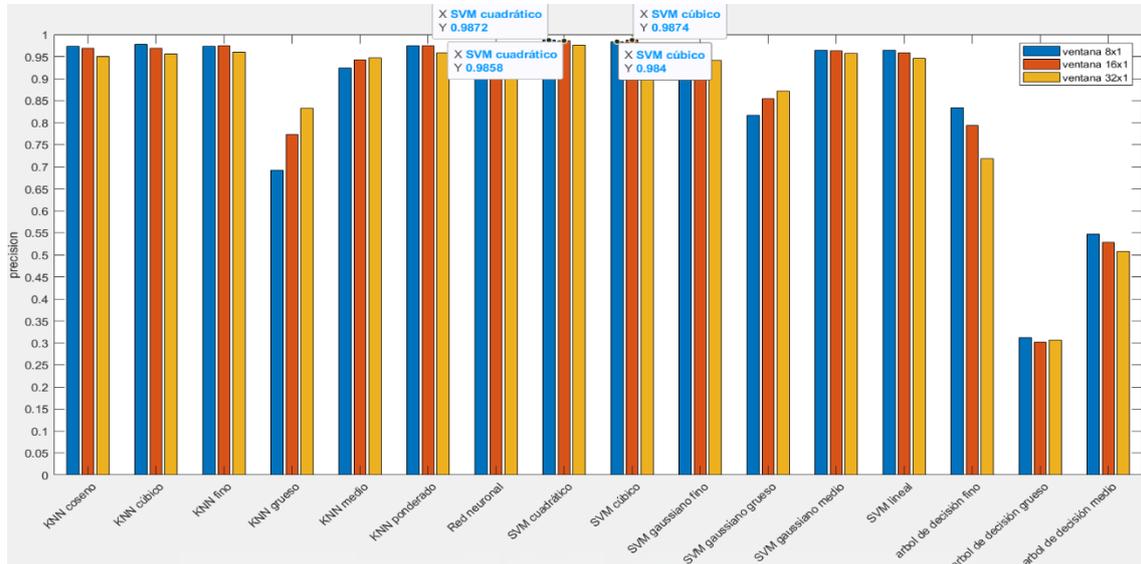
Gráfica 79. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en RGB

Ahora, usando LBP invariante a rotación con radio 1 en RGB, vemos en la gráfica 79 que la mayoría los clasificadores adquieren una mayor precisión cuando se usa la ventana de 2x2, siendo el SVM cuadrático el que mayor precisión alcanza, seguido muy de cerca del SVM cúbico para el mismo tamaño de ventana.



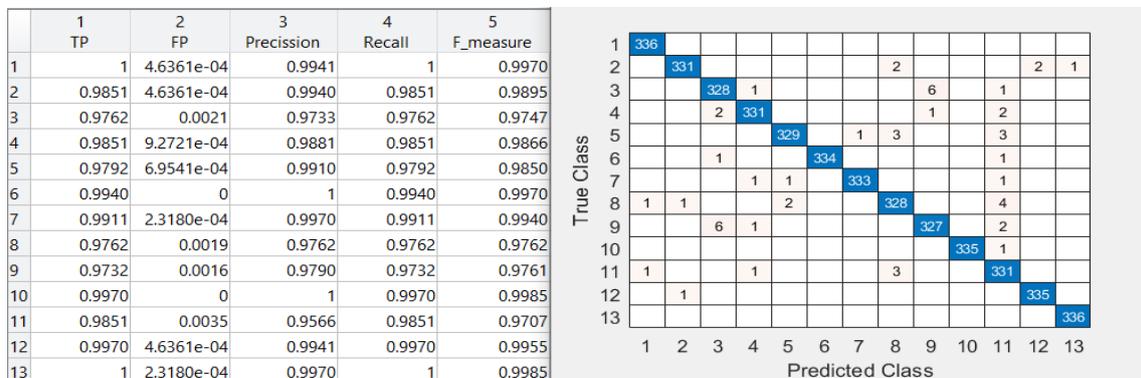
Gráfica 80. Validación del modelo de la gráfica 79

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en RGB para ventanas cuadradas, es del clasificador SVM cuadrático de la gráfica 80.



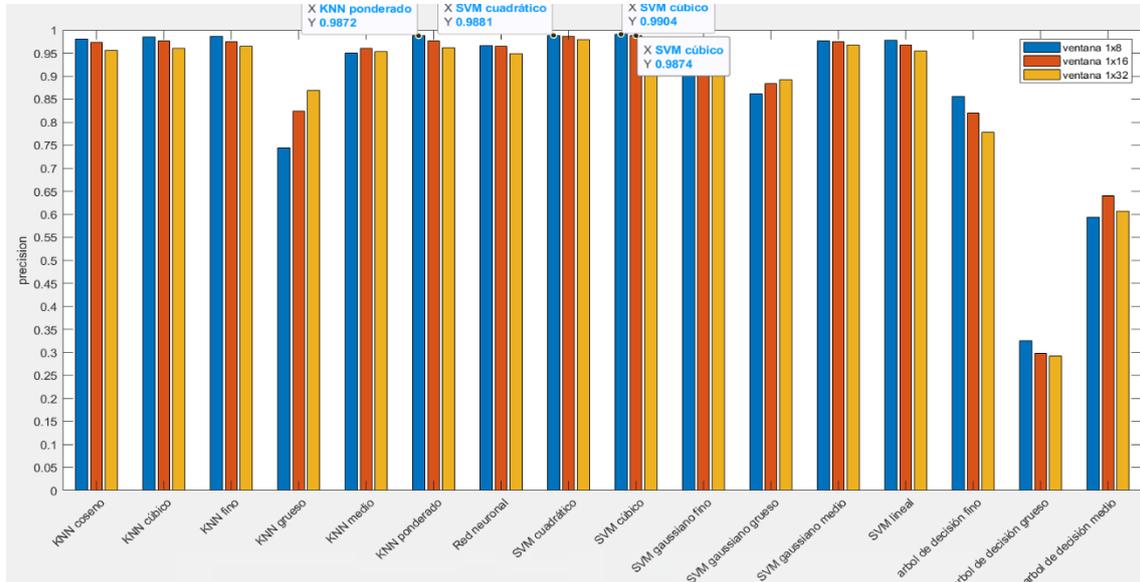
Gráfica 81. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en RGB

En muchos clasificadores vemos en la gráfica 81 que los valores en cada ventana son muy parecidos entre sí. Por eso, el clasificador que usando LBP invariante a rotación con radio 1 en RGB tiene la mayor precisión dista muy poco del mismo clasificador, pero para otra ventana. El SVM cúbico para ventana de 16x1 es el de mayor precisión y, seguido muy de cerca, el SVM cuadrático para ventanas de 8x1 es el siguiente.



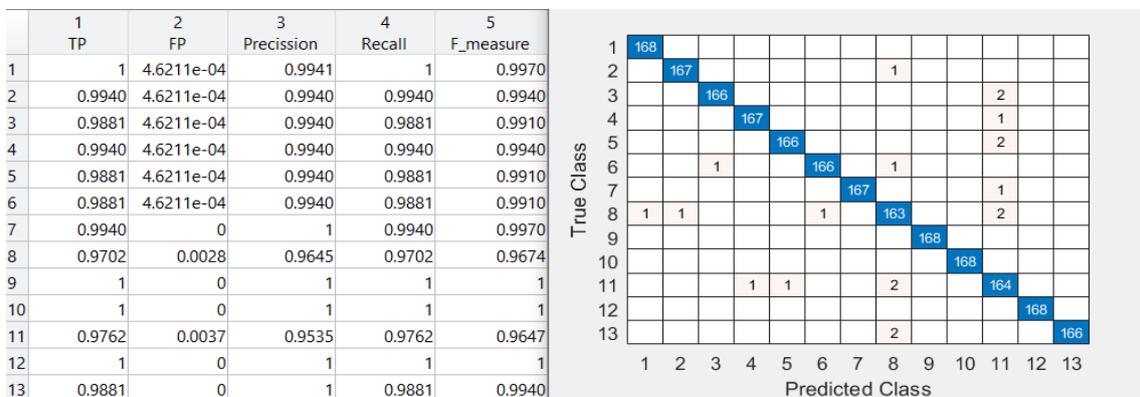
Gráfica 82. Validación del modelo de la gráfica 81

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en RGB para ventanas en filas de la gráfica 82.



Gráfica 83. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en RGB

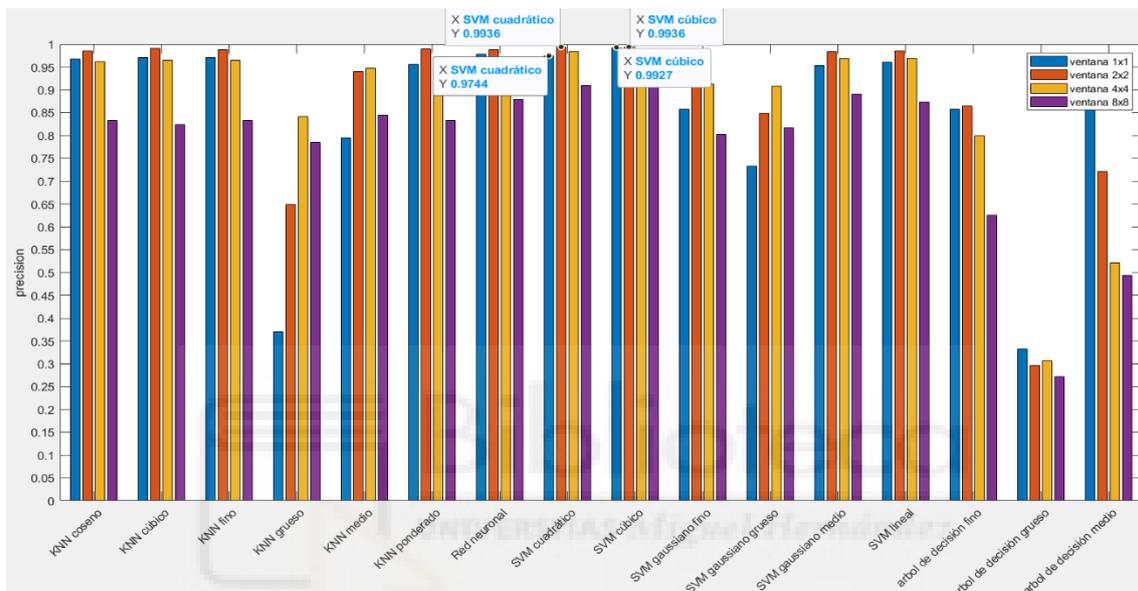
Generalmente en la gráfica 83, los clasificadores tienen su mejor resultado para ventana de 1x8, pero la diferencia con los valores de las otras ventanas tampoco es muy grande. Por ello, usando LBP invariante a rotación con radio 1 en RGB, el clasificador SVM cúbico con ventana de 1x8 es el que mejor resultado proporciona.



Gráfica 84. Validación del modelo de la gráfica 83

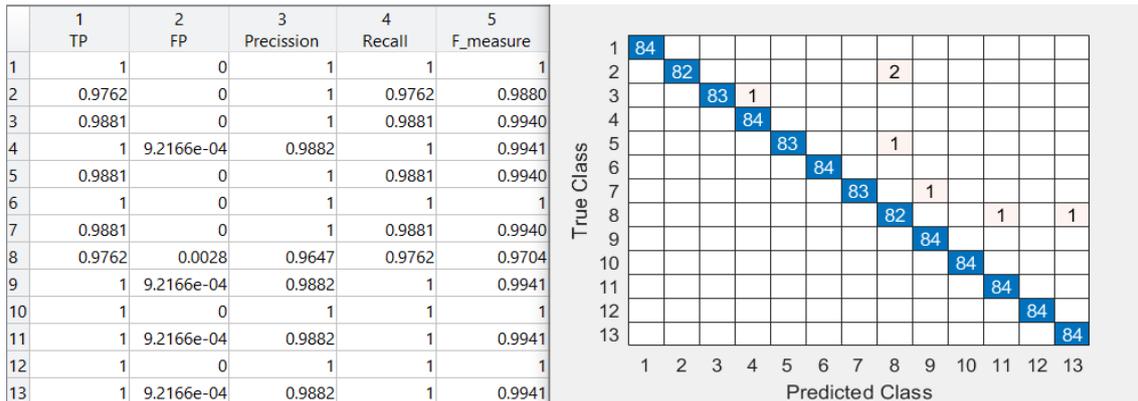
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en RGB para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 84.

Una vez vistas las tres gráficas (gráfica 79,81 y 83) usando LBP invariante a rotación con radio 1 en RGB el clasificador SVM cúbico para ventanas de 1x8 es el que mejor resultado nos ofrece.



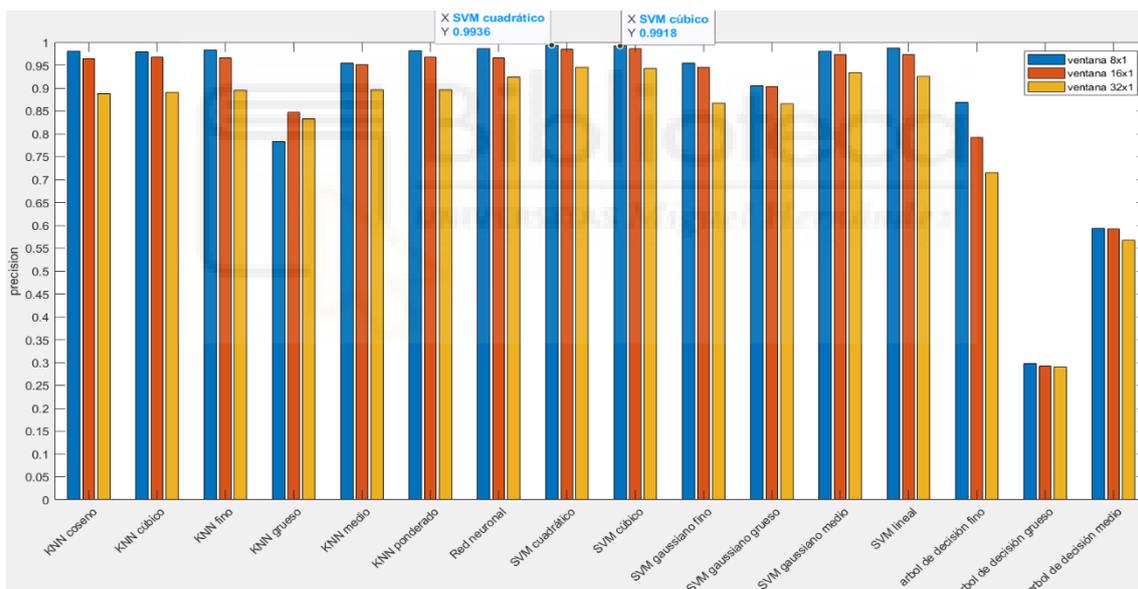
Gráfica 85. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en RGB

Con LBP invariante a rotación con radio 3 en RGB, tanto el clasificador SVM cúbico como el cuadrático alcanzan la misma y más alta precisión de toda la gráfica, ambos para la ventana de 2x2. Generalmente en la gráfica 85, es en esta ventana en la que la mayoría de los clasificadores tienen mejores resultados.



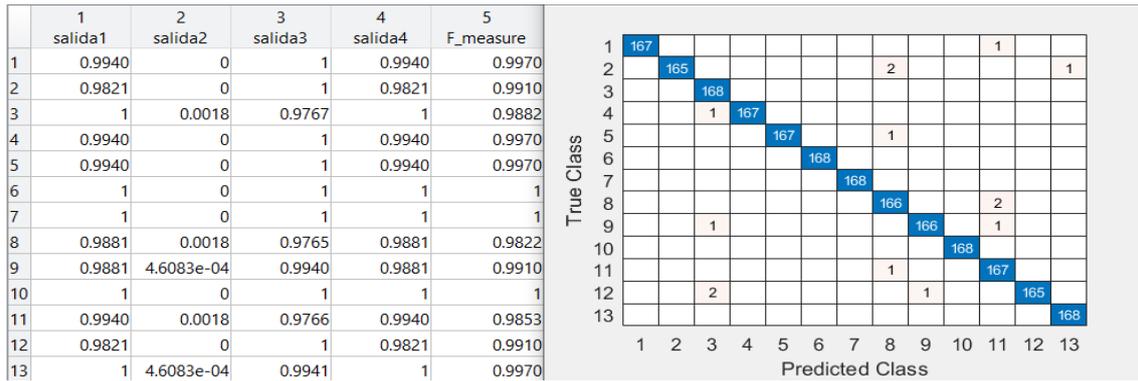
Gráfica 86. Validación del modelo de la gráfica 85

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en RGB para ventanas cuadradas, es del clasificador SVM cuadrático de la gráfica 86.



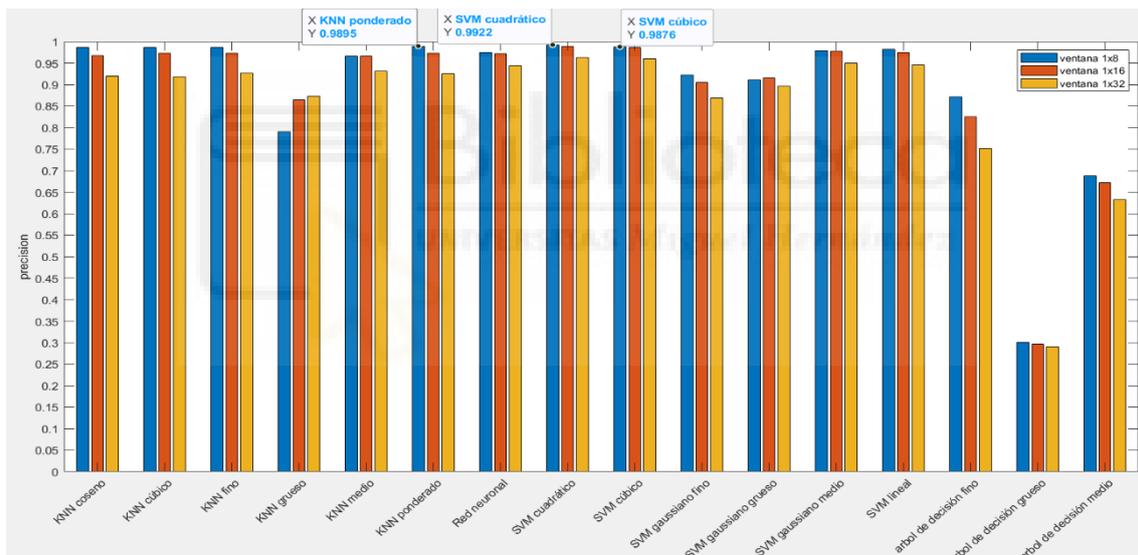
Gráfica 87. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en RGB

Podemos observar en la gráfica 87 que los mejores resultados, de la mayoría de los clasificadores, aparece cuando usamos ventanas de 8x1 y, a medida que este tamaño decrece, también lo hace la precisión. El mejor resultado viene por el clasificador SVM cuadrático para ventana de 8x1, sin embargo, el SVM cúbico para ventana de 8x1 tiene un valor también muy elevado y cercano al anterior.



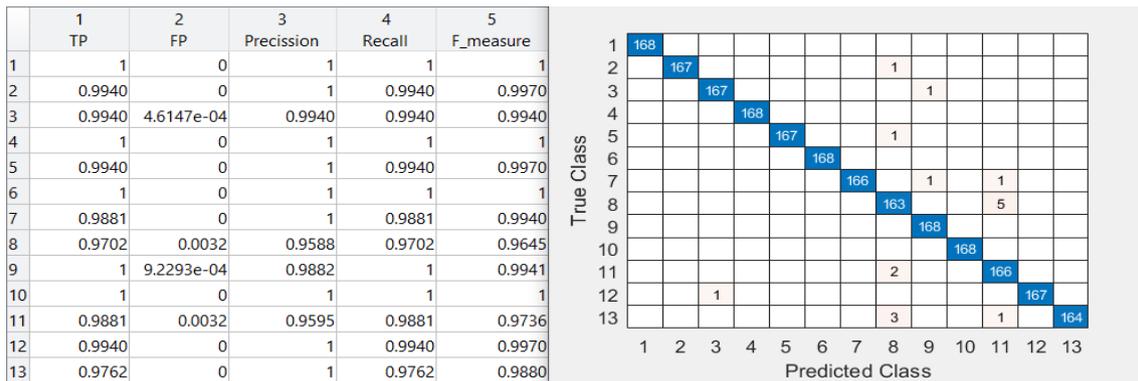
Gráfica 88. Validación del modelo de la gráfica 87

Sacamos del clasificador SVM cuadrático esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en RGB para ventanas en filas de la gráfica 88.



Gráfica 89. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en RGB

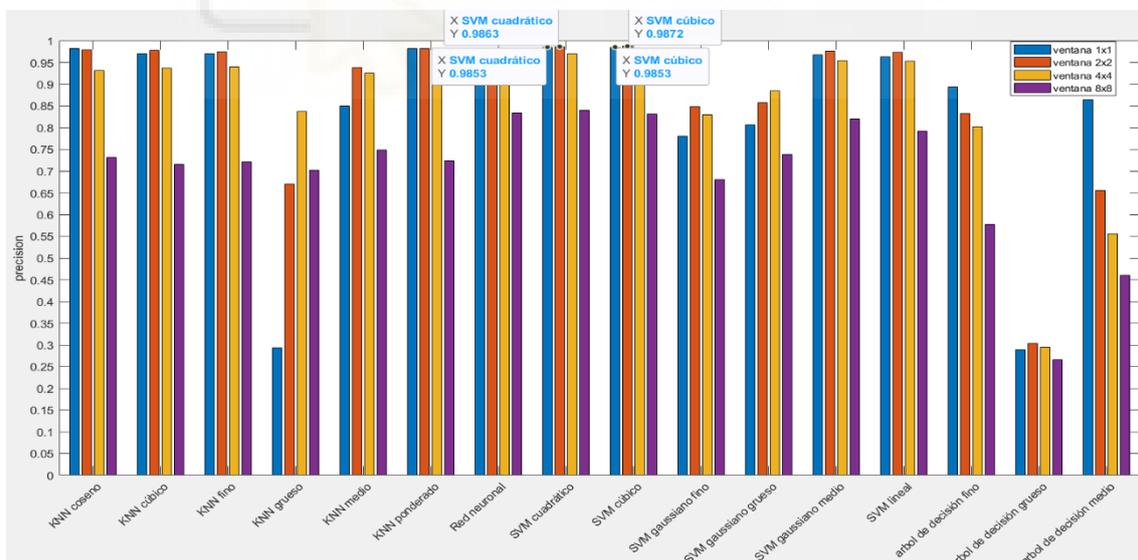
En la gráfica 89, para LBP invariante a rotación con radio 3 en RGB, la ventana de 1x8 es la que provoca los mejores resultados de muchos clasificadores y, conforme la ventana se hace más pequeña, la precisión disminuye. El que mejor resultado ofrece en este caso es el SVM cuadrático con ventana de 1x8.



Gráfica 90. Validación del modelo de la gráfica 89

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en RGB para ventanas en columnas, es del clasificador SVM cuadrático de la gráfica 90.

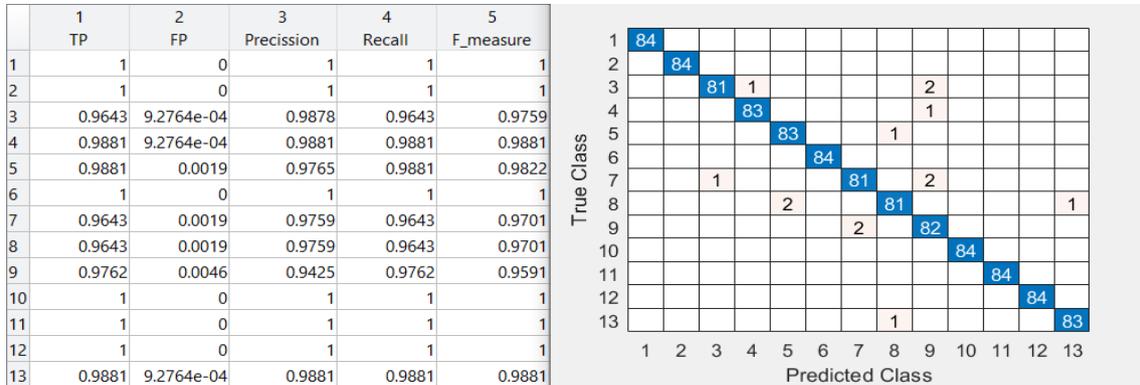
Una vez visto todos los resultados usando LBP invariante a rotación con radio 3 en RGB, el clasificador SVM cuadrático es el que mejores resultados ha ofrecido en los tres casos, siendo el mayor de todos para ventana de 2x2 y ventana de 8x1.



Gráfica 91. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en RGB

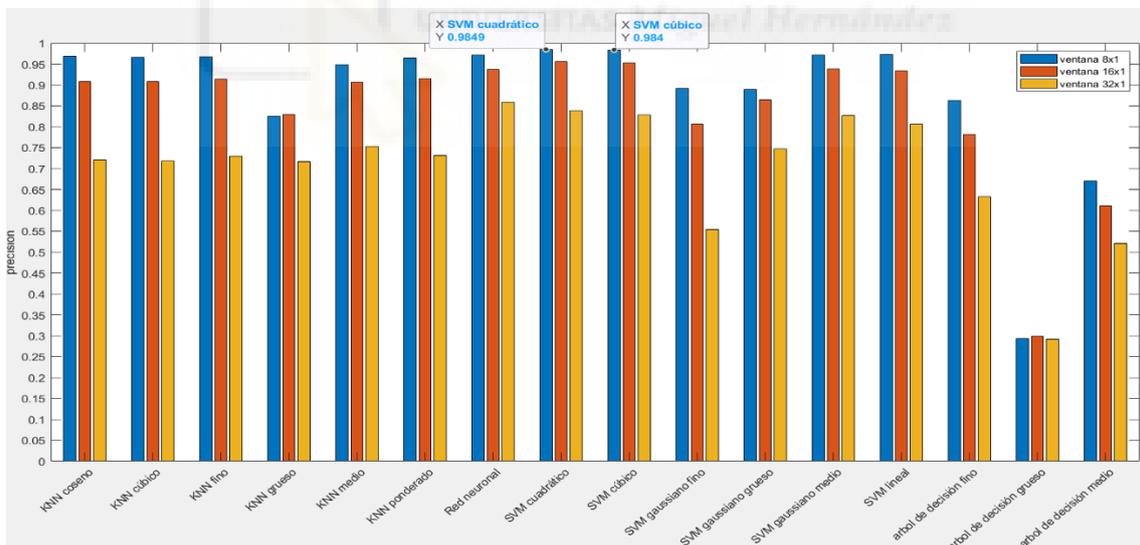
Continuando con LBP invariante a rotación con radio 5 en RGB, vemos en la gráfica 91 que no hay ninguna ventana cuadrada en la que todos los

clasificadores adquieren su mayor valor. El valor más alto viene por parte del clasificador SVM cúbico con ventana de 2x2, y el siguiente valor más alto también es con esta ventana, pero con el clasificador SVM cuadrático.



Gráfica 92. Validación del modelo de la gráfica 91

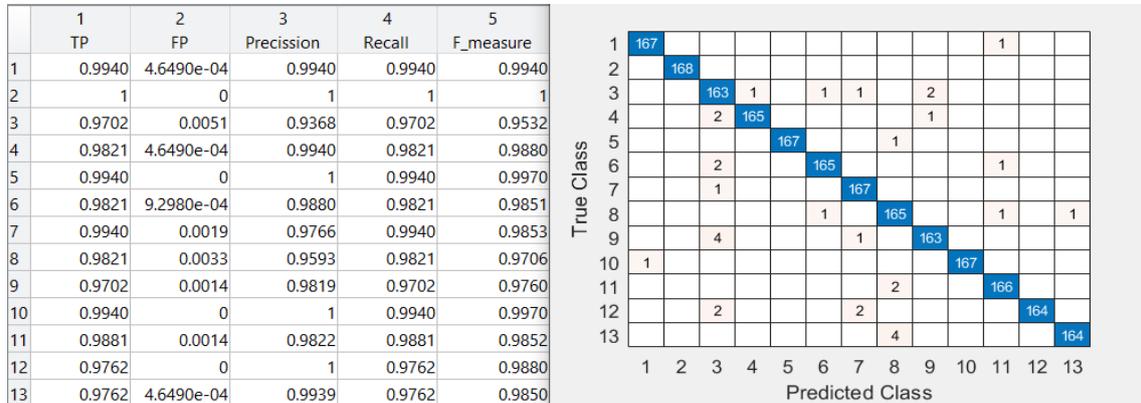
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en RGB para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 92.



Gráfica 93. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en RGB

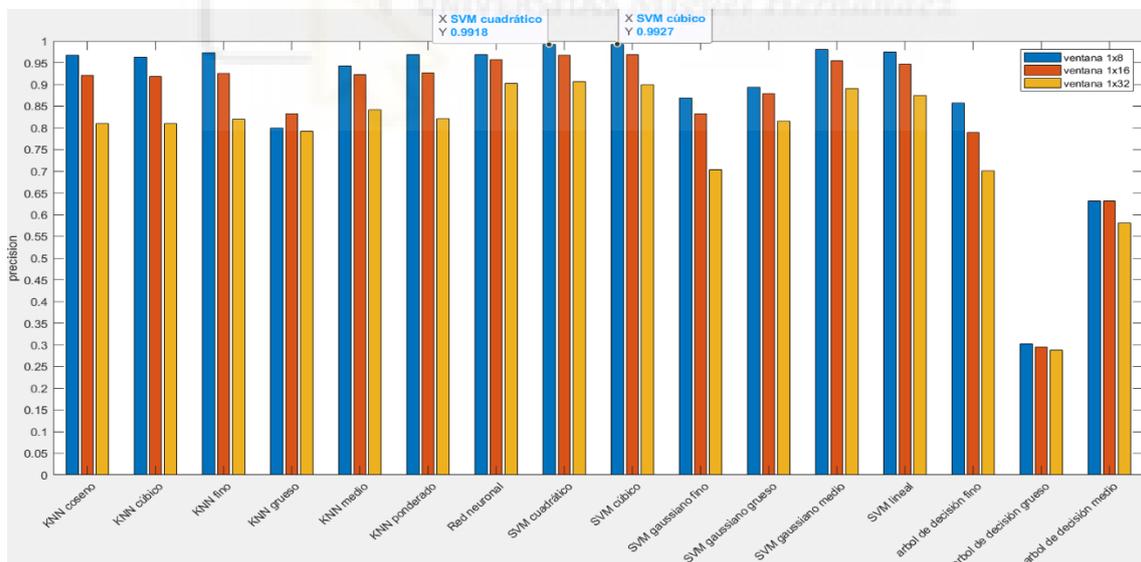
En la gráfica 93 la ventana de 8x1 es la que consigue el mejor resultado en la mayoría de los clasificadores usando LBP invariante a rotación con radio 5 en RGB y, si la ventana cambia su tamaño a uno menor la precisión se ve

reducida. El mejor clasificador es el SVM cuadrático para ventana de 8x1, pero para esta misma ventana el SVM cúbico también proporciona un resultado muy similar.



Gráfica 94. Validación del modelo de la gráfica 93

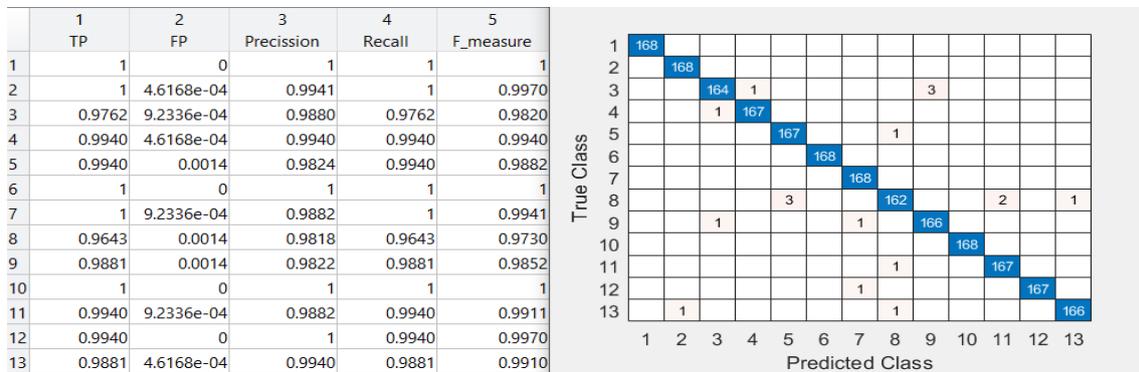
Sacamos del clasificador SVM cuadrático esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en RGB para ventanas en filas de la gráfica 94.



Gráfica 95. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en RGB

En la gráfica 95 el mejor resultado nos lo da el clasificador SVM cúbico para ventana de 1x8 usando LBP invariante a rotación con radio 5 en RGB. También hay que mencionar que el SVM cuadrático tienen un valor semejante usando el

mismo tamaño de ventana. Por último, es apreciable que a medida que la ventana se hace más pequeña la precisión también se reduce.

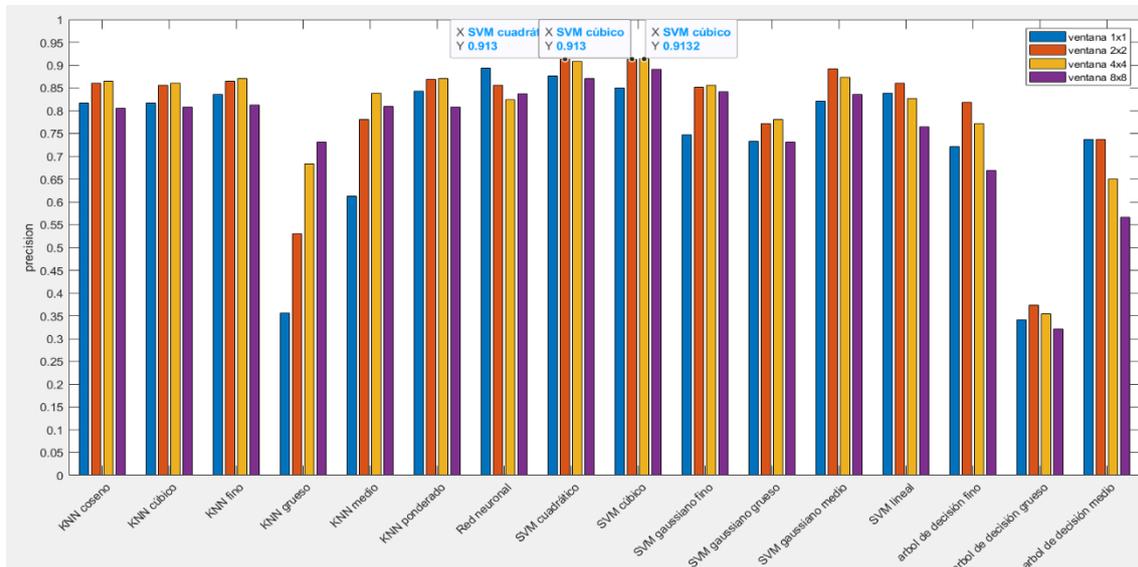


Gráfica 96. Validación del modelo de la gráfica 95

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en RGB para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 96.

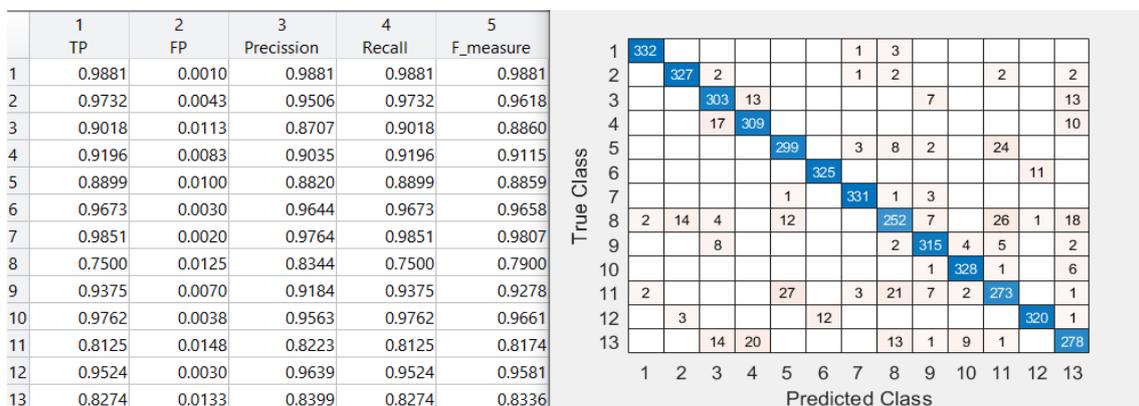
Visto los resultados anteriores, el clasificador SVM cúbico es el que mejor se comporta usando LBP invariante a rotación con radio 5 en RGB y una ventana de 1x8.

### 4.1.3 Comparación en colores opuestos con el segundo data set



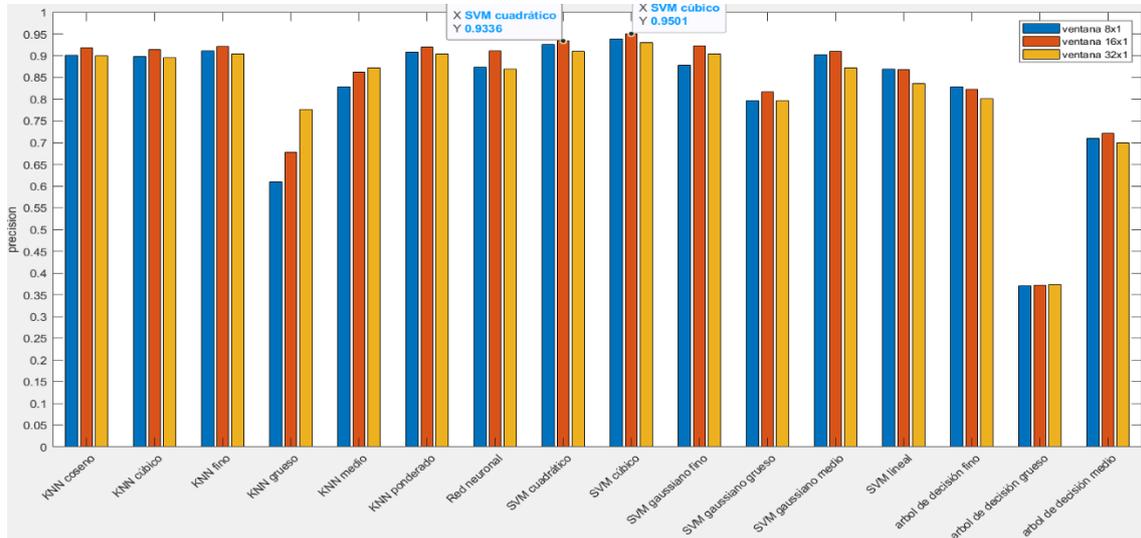
Gráfica 97. Comparación clasificadores para ventanas cuadradas para momentos de histograma en colores opuestos

En la gráfica 97, usando los momentos de histograma en colores opuestos para ventanas cuadradas vemos que el mejor resultado de cada clasificador varía entre la ventana de 2x2 y la de 4x4. También se puede observar que resultado más alto viene por parte del clasificador SVM cúbico en ventana de 4x4, pero el valor es prácticamente el mismo para una ventana de 2x2 del mismo clasificador y del SVM cuadrático.



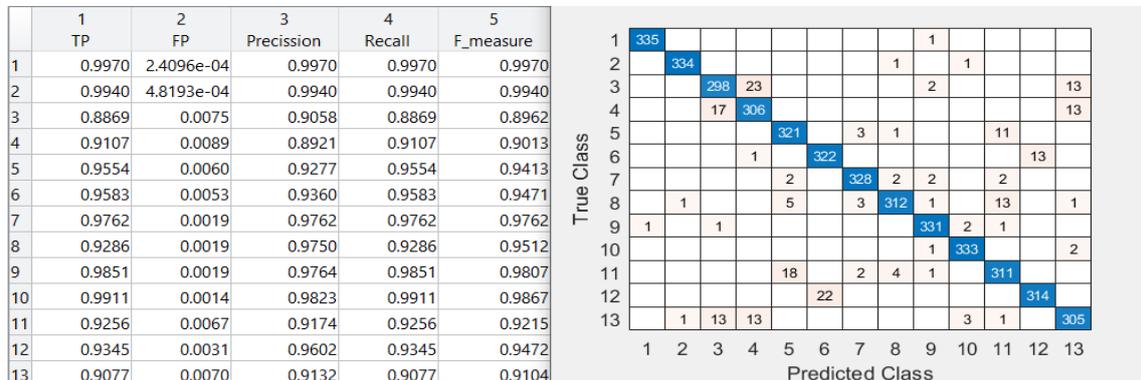
Gráfica 98. Validación del modelo elegido de la gráfica 97

Esta representación de la matriz de confusión y las tasas de acierto y error, para momentos de histograma en colores opuestos para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 98.



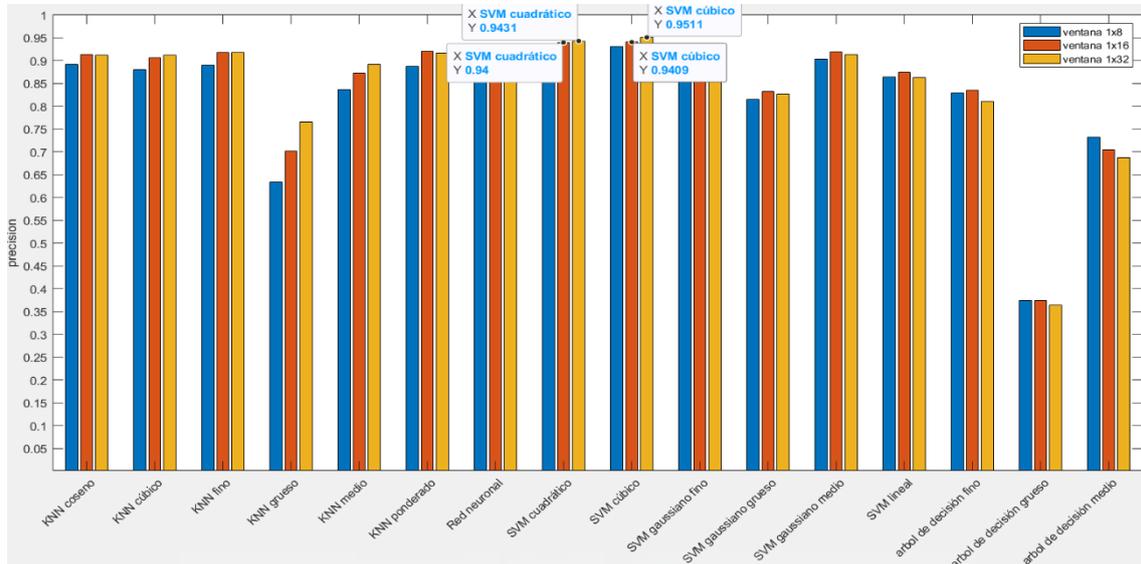
Gráfica 99. Comparación clasificadores para ventanas en filas para momentos de histograma en colores opuestos

En la gráfica 99, siguiendo con el análisis en ventanas en filas, vemos que el clasificador SVM cúbico para ventanas de 16x1 es el que mejor precisión tiene usando momentos de histograma en colores opuestos. También vemos que los mejores resultados de los clasificadores, generalmente, se produce en las ventanas de 16x1.



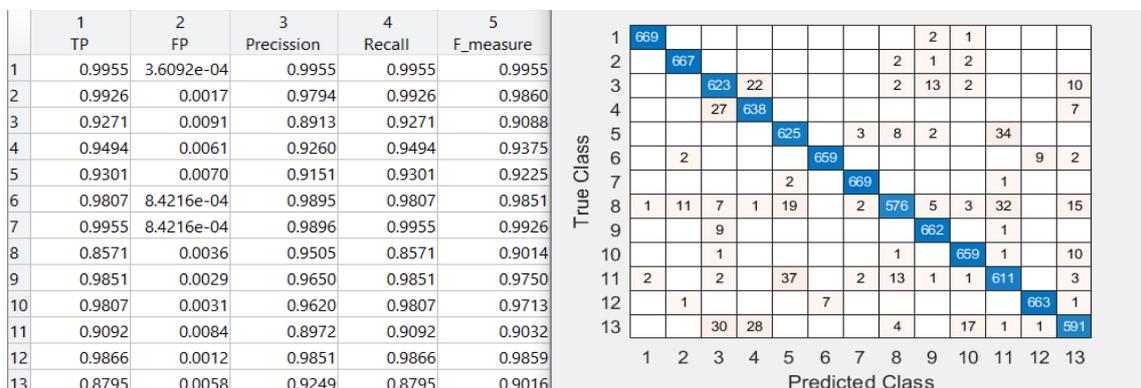
Gráfica 100. Validación del modelo elegido de la gráfica 99

Usaremos el clasificador con más precisión, el SVM cúbico, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en colores opuestos para ventanas en columna de la gráfica 100.



Gráfica 101. Comparación clasificadores para ventanas en columnas para momentos de histograma en colores opuestos

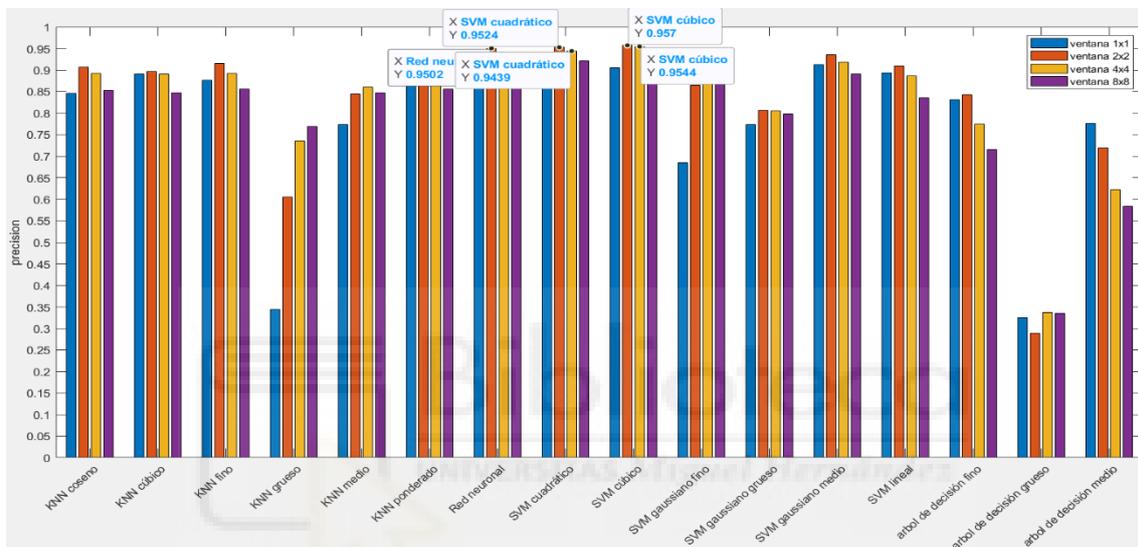
Generalmente en la gráfica 101, vemos que el clasificador que más precisión tiene, usando momentos de histograma en colores opuestos, es el SVM cúbico para ventanas de 1x32. En todos los K-NN y en el SVM cuadrático y cúbico esta ventana es en la que se encuentra el valor máximo, en el resto de los clasificadores varían entre las otras dos.



Gráfica 102. Validación del modelo elegido de la gráfica 101

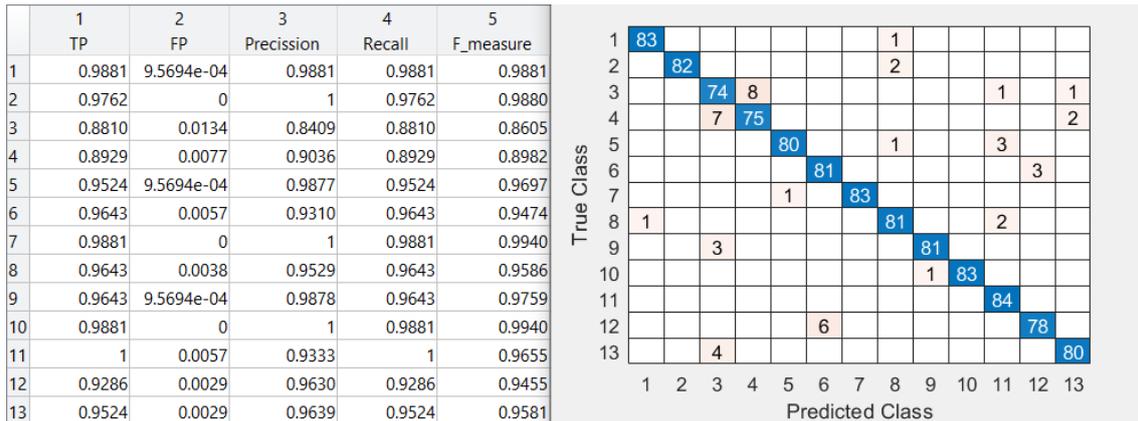
Usaremos el clasificador con más precisión, el SVM cúbico, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en colores opuestos para ventanas en columna de la gráfica 102.

Después de ver todas las gráficas, el clasificador SVM cúbico para ventanas de 1x32 es el que mayor precisión nos da, y en general para los tres tipos de ventana es el que mejor se comporta. El peor resultado en general ha sido en las ventanas cuadradas.



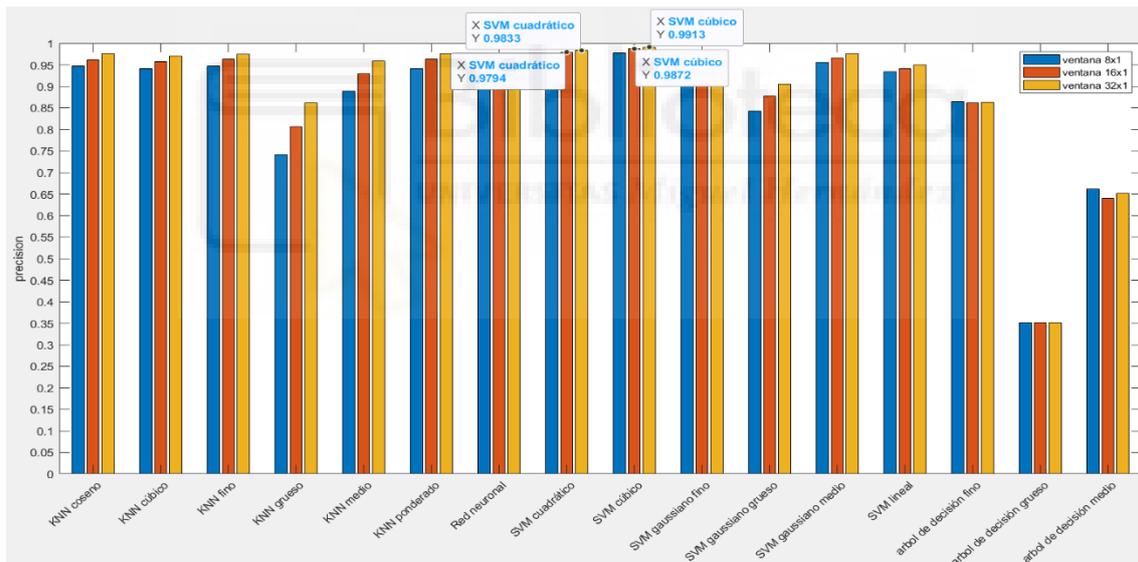
Gráfica 103. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en colores opuestos

Generalmente en la gráfica 103, obtenemos el mayor valor en las ventanas de 2x2. Entonces, usando la matriz de coocurrencia en colores opuestos, el clasificador SVM cúbico para la ventana de 2x2 es el que mejor resultado nos ofrece, sin embargo, cabe destacar que para el mismo clasificador usando ventanas 4x4 el valor es muy próximo al anterior, al igual que con el SVM cuadrático.



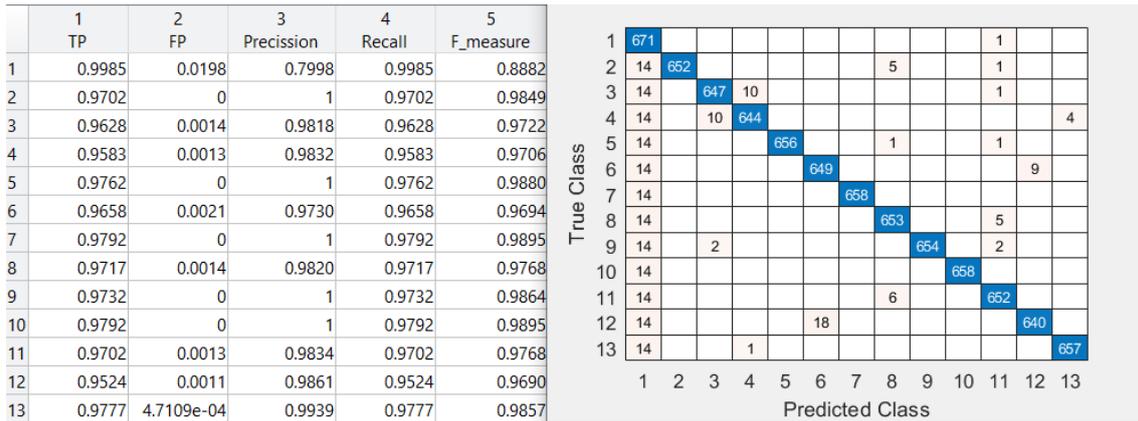
Gráfica 104. Validación del modelo elegido de la gráfica 103

Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en colores opuestos para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 104.



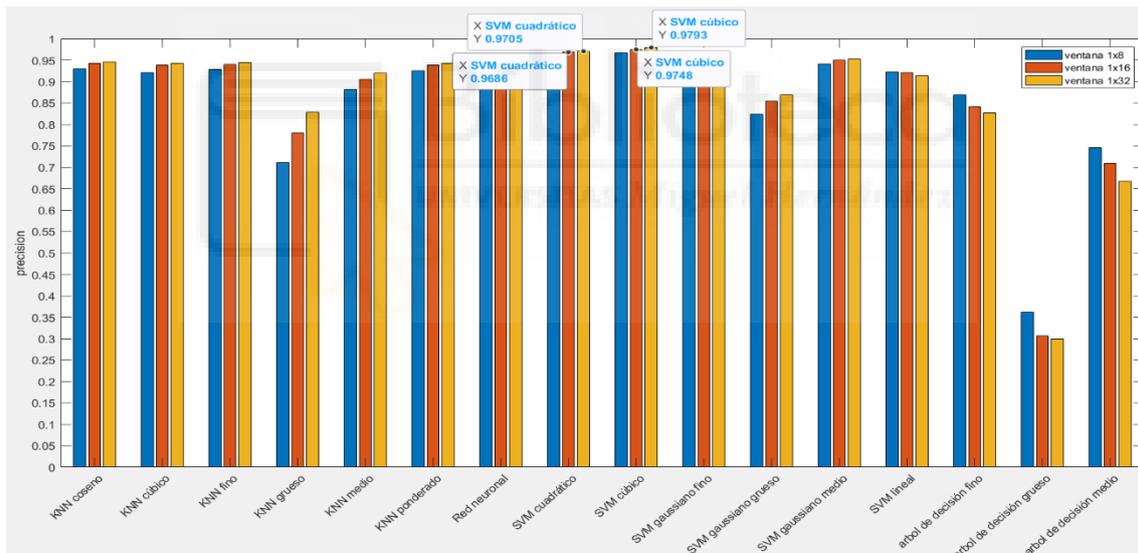
Gráfica 105. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en colores opuestos

Vemos en la gráfica 105 que usando la matriz de coocurrencia en colores opuestos el clasificador SVM cúbico es el que mejor se comporta cuando escogemos la ventana 32x1. También se puede apreciar que los clasificadores, generalmente, ofrecen el mejor resultado para ese tipo de ventana y a medida que el tamaño de la ventana aumenta, la precisión decrece.



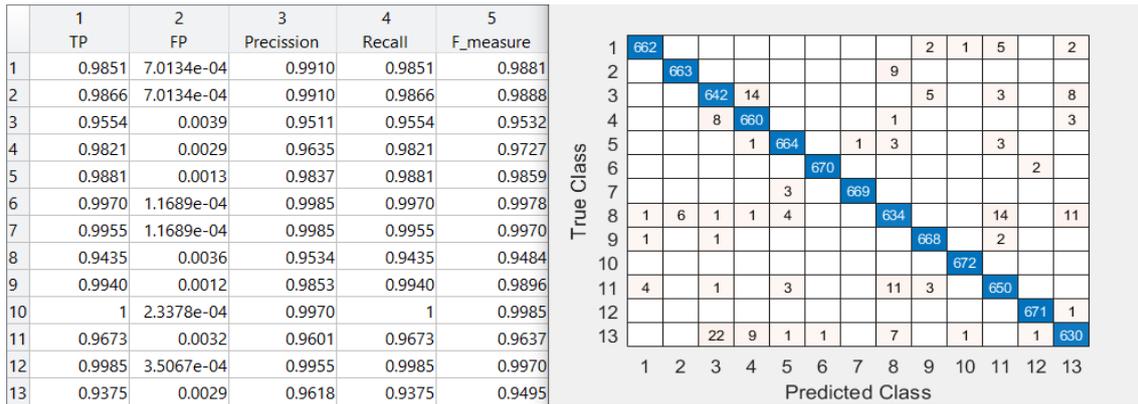
Gráfica 106. Validación del modelo elegido de la gráfica 105

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en colores opuestos para ventanas en filas de la gráfica 106.



Gráfica 107. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en colores opuestos

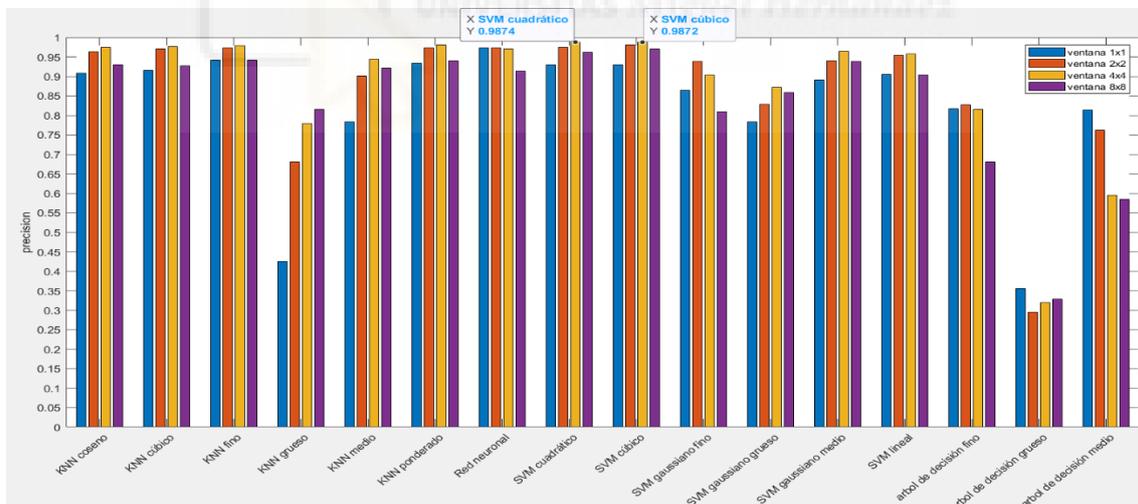
La gráfica 107 muestra el comportamiento de los clasificadores cuando usamos las ventanas en columna con la matriz de coocurrencia en colores opuestos, vemos que el mejor resultado nos lo da el SVM cúbico para ventanas de 1x32 seguido muy de cerca por el resultado del mismo clasificador para ventanas de 1x16 y el SVM cuadrático para ventanas de 1x32.



Gráfica 108. Validación del modelo elegido de la gráfica 107

Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en colores opuestos para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 108.

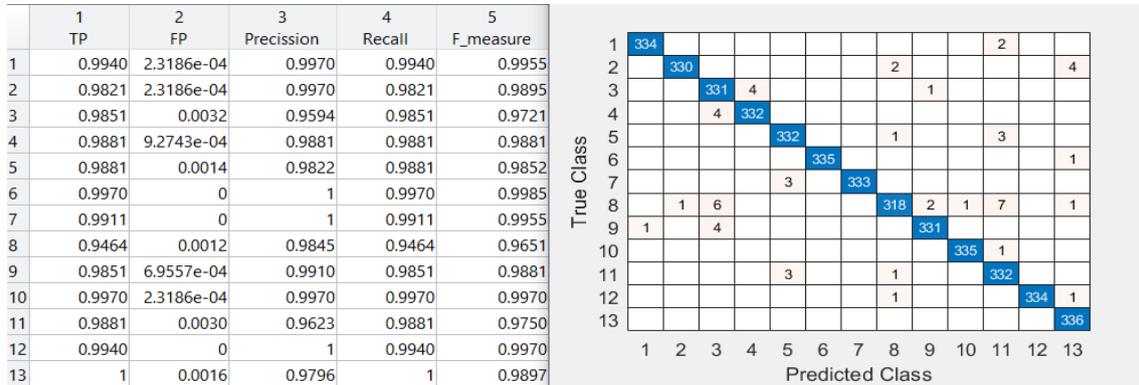
Una vez vistos los resultados anteriores, el mejor clasificador es el SVM cúbico con ventana de 32x1, cabe destacar que este clasificador se comporta muy bien, incluso, en el resto de los tipos de ventana.



Gráfica 109. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en colores opuestos

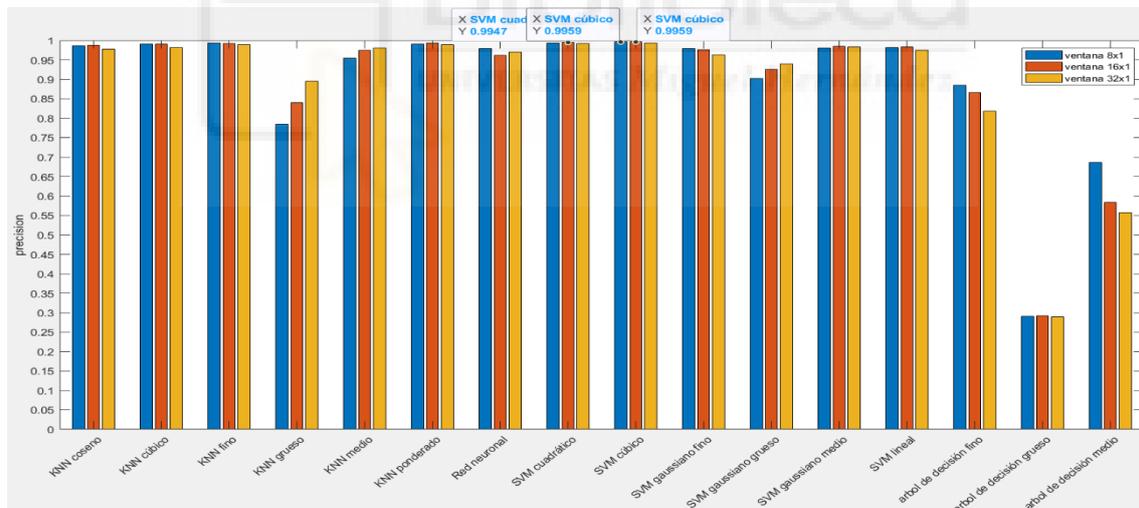
En la gráfica 109, usando LBP variante a rotación en colores opuestos vemos que, en la mayoría de clasificadores, los valores de las ventanas 2x2 y 4x4 son muy similares, siendo en la ventana 4x4 en la que mayor valor alcanzan. El

clasificador SVM cuadrático es el que mayor precisión tiene usando la ventana de 4x4.



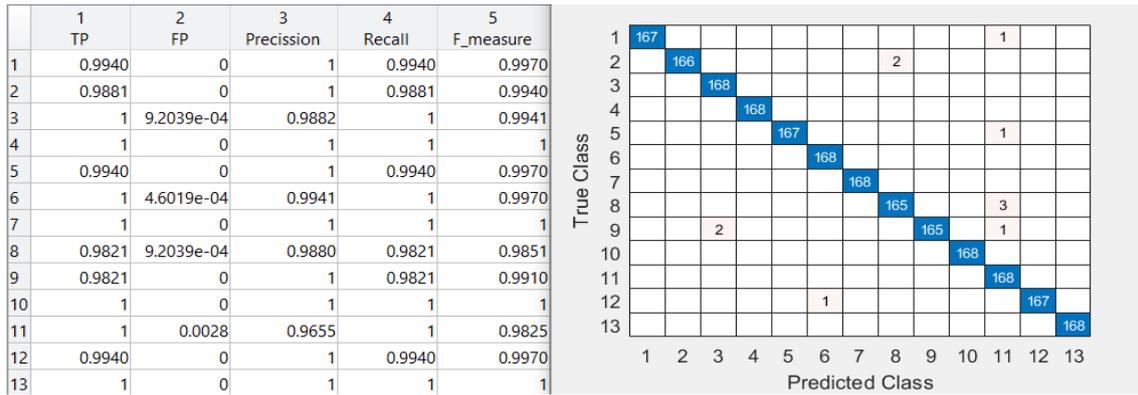
Gráfica 110. Validación del modelo elegido de la gráfica 109

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en colores opuestos para ventanas cuadradas, es del clasificador SVM cuadrático de la gráfica 110.



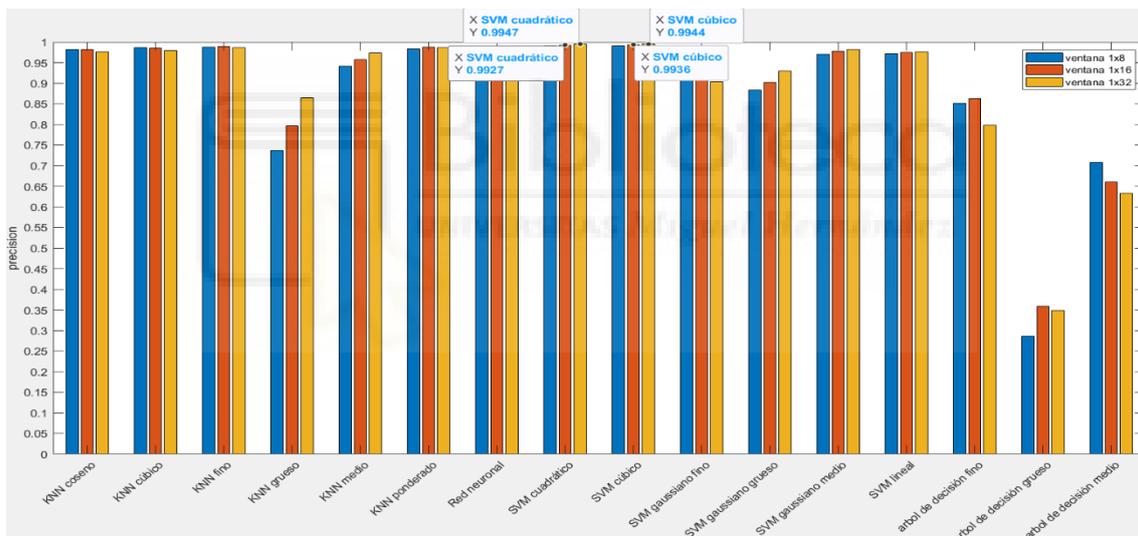
Gráfica 111. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en colores opuestos

En la gráfica 111 los clasificadores no alcanzan su valor máximo en una ventana específica, va cambiando según el clasificador. Tenemos dos ventanas, que usando LBP variante a rotación con radio 1, alcanzan el valor más alto de la gráfica. Esto se produce al usar el SVM cúbico. En general, los resultados obtenidos son elevados en los distintos clasificadores.



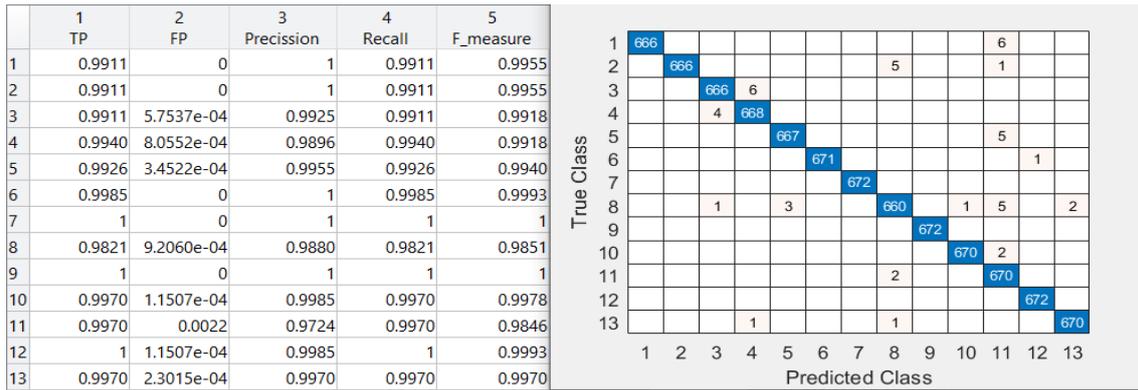
Gráfica 112. Validación del modelo elegido de la gráfica 111

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en colores opuestos para ventanas en filas de la gráfica 112.



Gráfica 113. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en colores opuestos

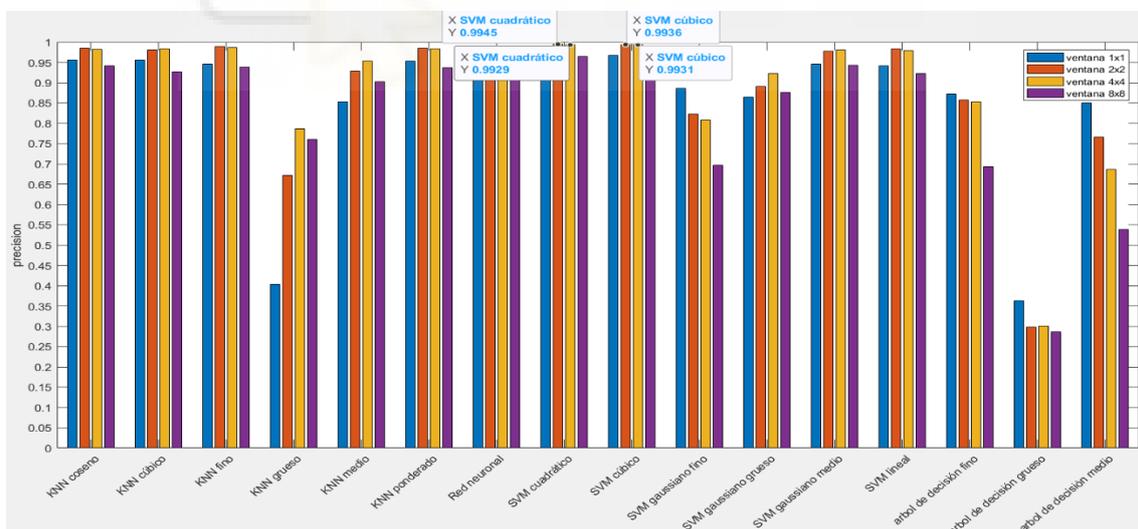
Vemos en la gráfica 113 que al analizar las ventanas en columna para LBP variante a rotación con radio 1 en colores opuestos los valores de un mismo clasificador las diferentes ventanas tienen valores cercanos, hay excepciones. El mejor resultado es alcanzado tanto por el clasificador SVM cuadrático con ventana de 1x32, pero muy cerca esta también el SVM cúbico para ventanas de 1x32.



Gráfica 114. Validación del modelo elegido de la gráfica 113

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en colores opuestos para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 114.

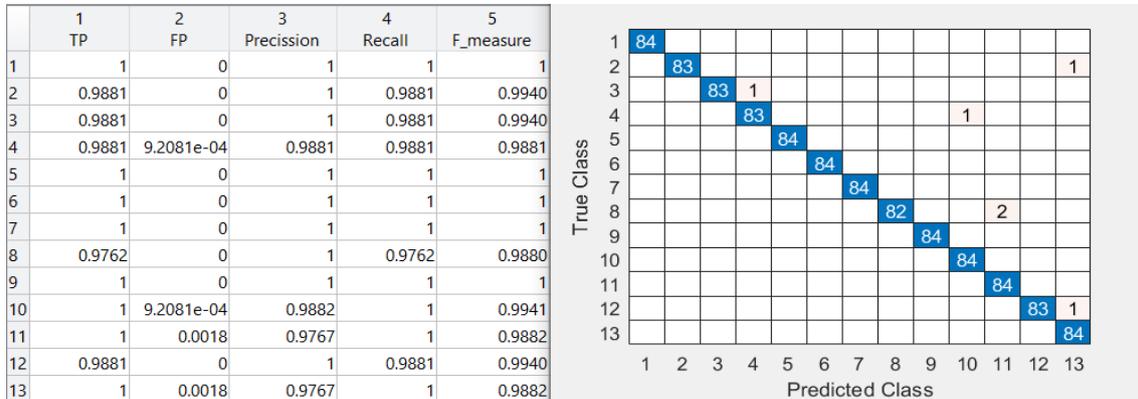
Queda claro que el clasificador SVM cúbico es el que, independientemente de la ventana, siempre alcanza un resultado muy bueno respecto al resto de clasificadores. Siendo para la ventana 8x1 y 16x1 el de mayor valor para LBP variante a rotación con radio 1 en colores opuestos.



Gráfica 115. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en colores opuestos

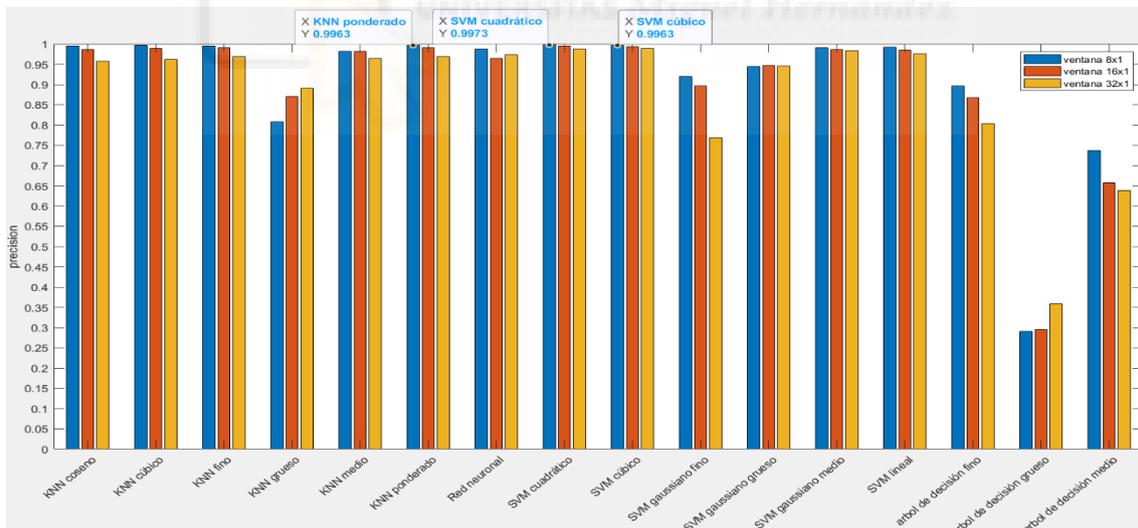
En la gráfica 115, usando LBP variante a rotación con radio 3 en colores opuestos los valores más altos en general se encuentran cuando usamos

ventanas de 2x2, siendo esta ventana las que logran la mayor precisión con el clasificador SVM cuadrático, que con la ventana 4x4 también alcanza un buen resultado.



Gráfica 116. Validación del modelo elegido de la gráfica 115

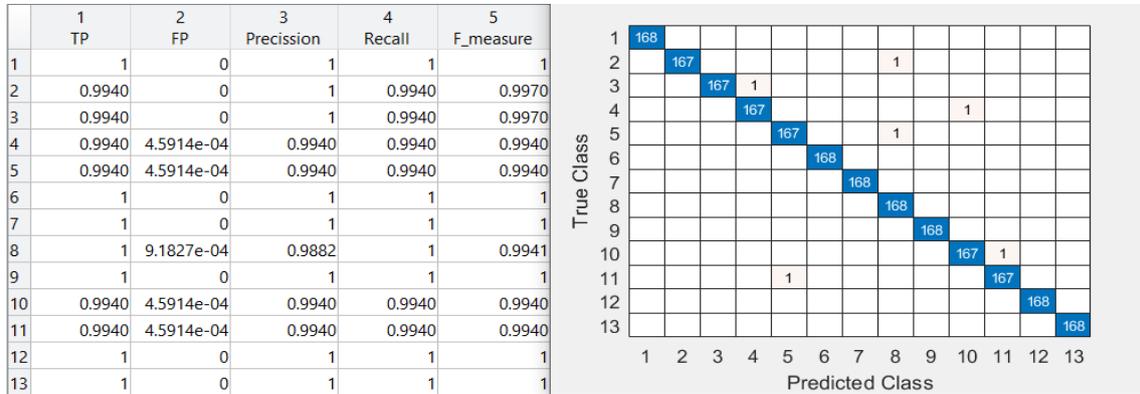
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en colores opuestos para ventanas cuadradas, es del clasificador SVM cuadrático de la gráfica 116.



Gráfica 117. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en colores opuestos

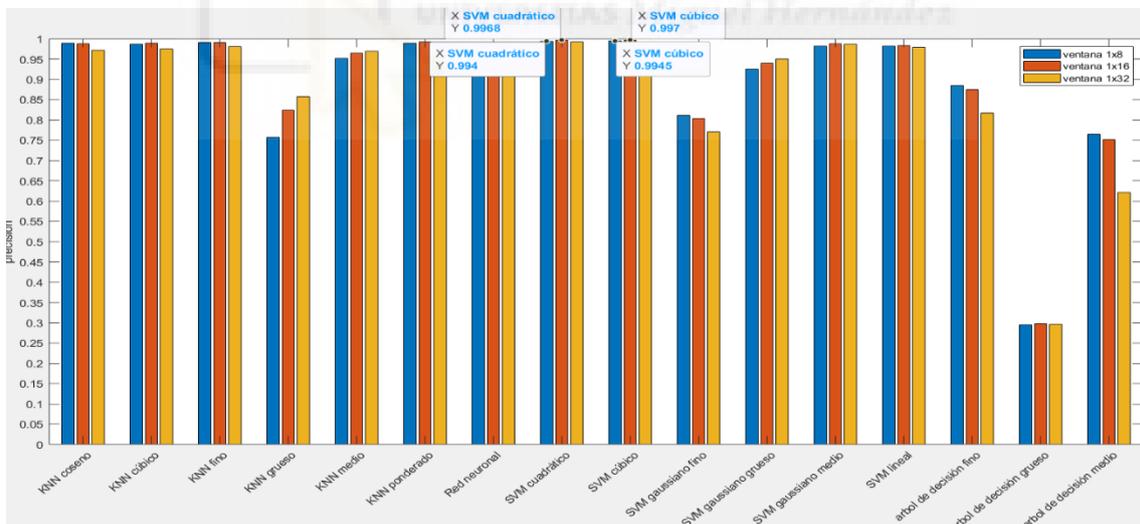
Analizando las ventanas en filas para LBP variante a rotación con radio 3 en colores opuestos, vemos en la gráfica 117 que la gran mayoría de los clasificadores estudiados alcanzan su valor más alto para las ventanas de 8x1,

siendo el clasificador SVM cuadrático el que alcanza el valor más alto. Cabe destacar que algunos valores de otros clasificadores, SVM cúbico y K-NN ponderado, están muy cerca del valor del SVM cuadrático.



Gráfica 118. Validación del modelo elegido de la gráfica 117

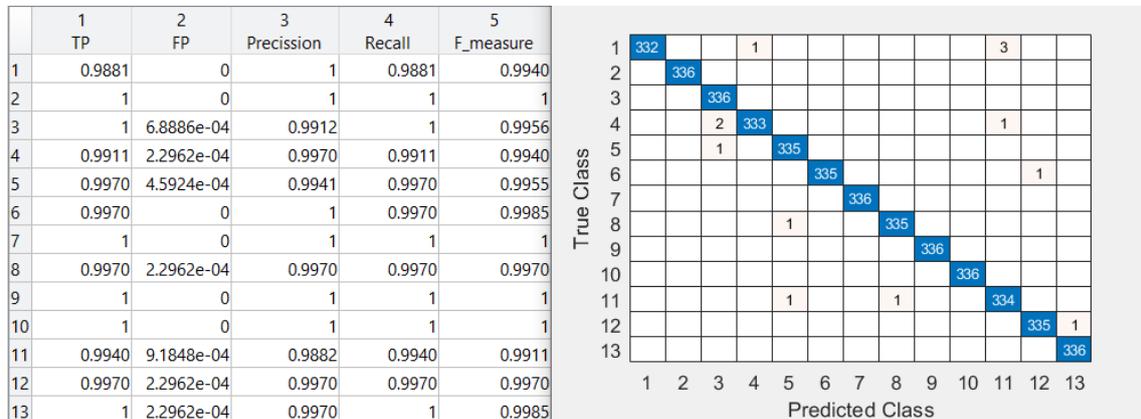
Sacamos del clasificador SVM cuadrático esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en colores opuestos para ventanas en filas de la gráfica 118.



Gráfica 119. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en colores opuestos

En la gráfica 119 podemos observar en la gráfica que los resultados para los diferentes tamaños de ventana, usando LBP variante a rotación con radio 3 en colores opuestos, son muy cercanos en la mayoría de clasificadores. Para estas

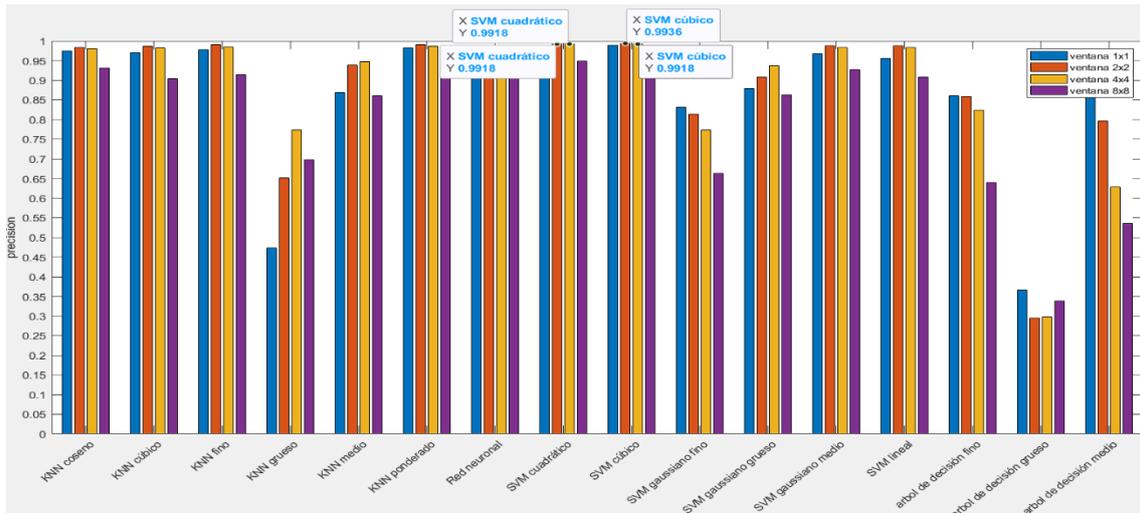
ventanas el clasificador SVM cúbico es el que mayor valor alcanza, seguido de cerca por el cuadrático con ventana de 1x16. Además, podemos ver que para ventanas de 1x8 los valores de estos mismos clasificadores tampoco distan mucho de los valores de las ventanas de 1x16.



Gráfica 120. Validación del modelo elegido de la gráfica 119

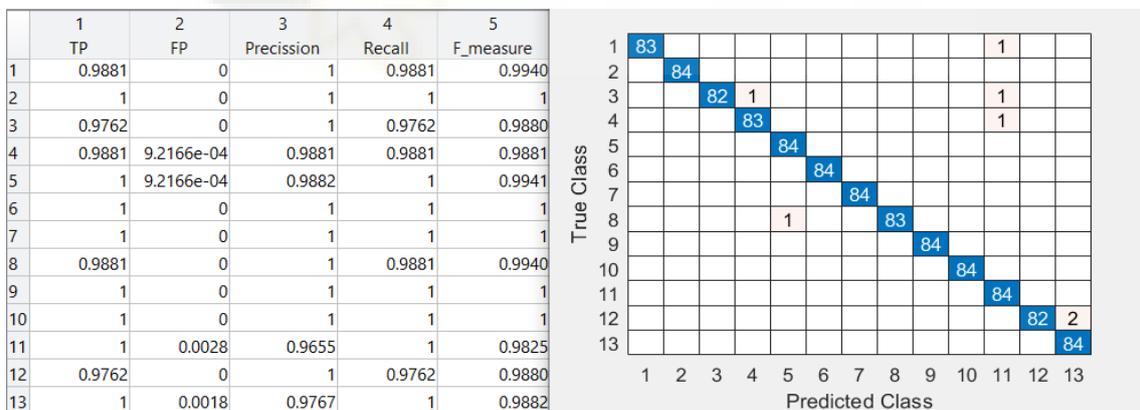
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en colores opuestos para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 120.

Hemos comprobado que para LBP variante a rotación con radio 3 en RGB el clasificador SVM cúbico es el que mejor se comporta con una ventana de 1x16, aunque no solo lo hace para un tipo de ventana. Es por eso que se considera este clasificador el mejor para este caso.



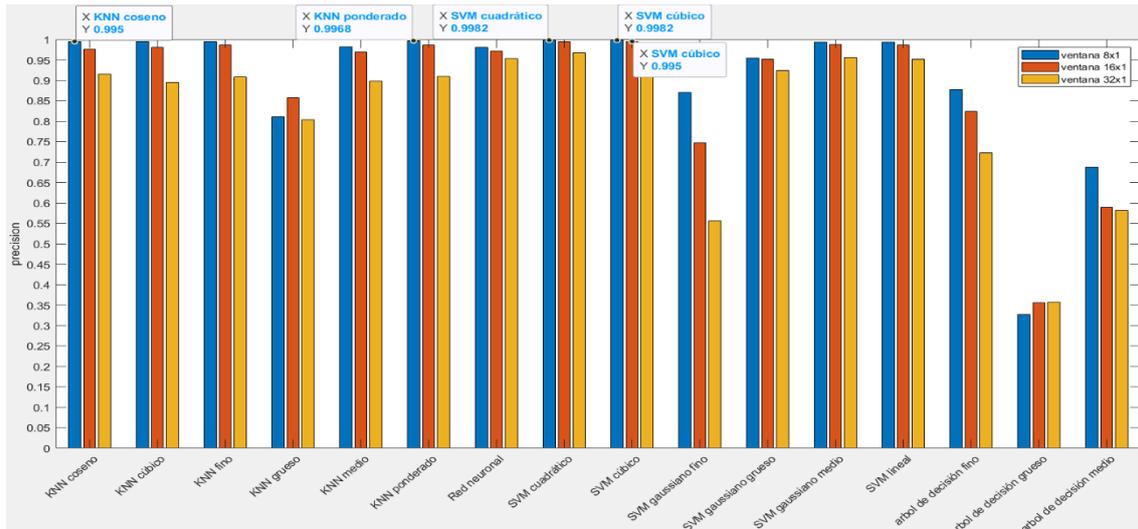
Gráfica 121. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en colores opuestos

Ahora analizaremos la gráfica 121 para ventanas cuadradas el uso de LBP variante a rotación con radio 5 en colores opuestos, el valor más alto está localizado en la ventana 2x2 del clasificador SVM cúbico. Hay que mencionar, que este valor máximo es muy cercano al valor ofrecido por otros clasificadores o incluso para el mismo clasificador, pero usando una ventana de 4x4.



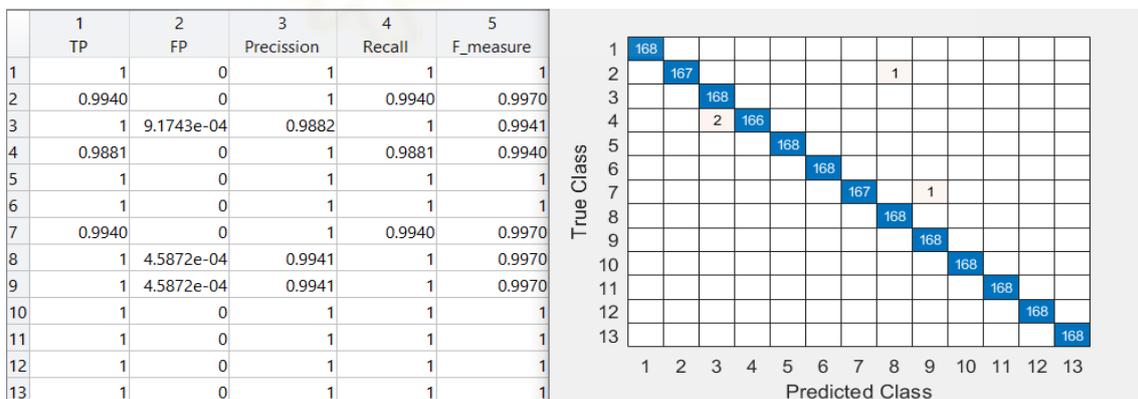
Gráfica 122. Validación del modelo elegido de la gráfica 121

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en colores opuestos para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 122.



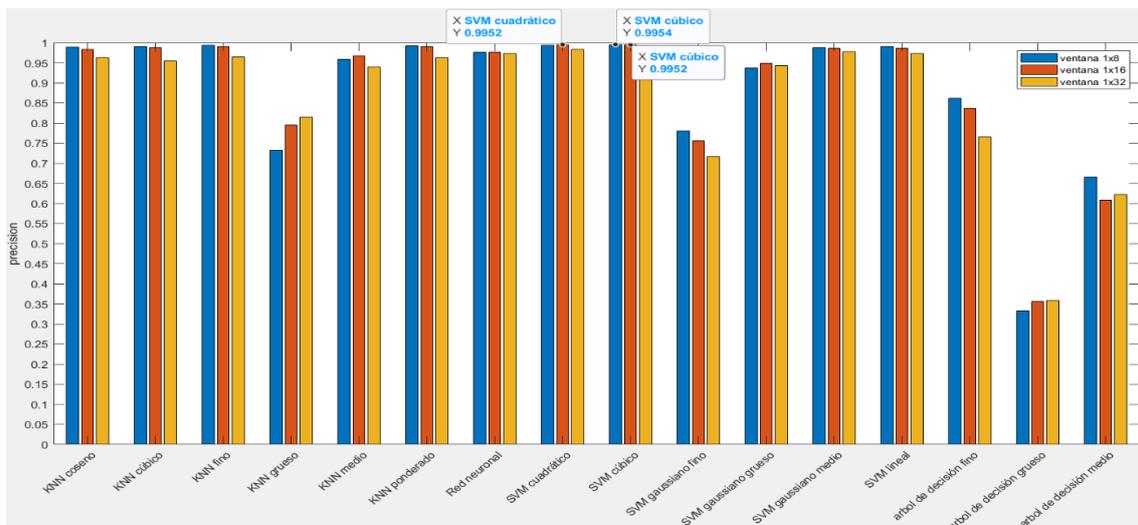
Gráfica 123. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en colores opuestos

En la gráfica 123 los mejores clasificadores, usando LBP variante a rotación con radio 5 en colores opuestos con ventanas en fila, son el SVM cuadrático y el SVM cúbico para ventanas de 8x1. También, podemos ver como a medida que se disminuye el tamaño de la ventana también disminuye la precisión del clasificador.



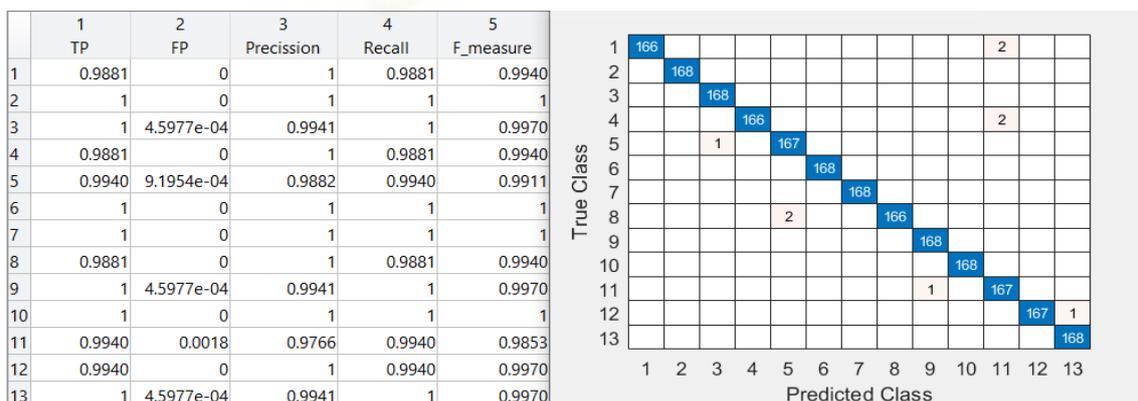
Gráfica 124. Validación del modelo elegido de la gráfica 123

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en colores opuestos para ventanas en filas de la gráfica 124.



Gráfica 125. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en colores opuestos

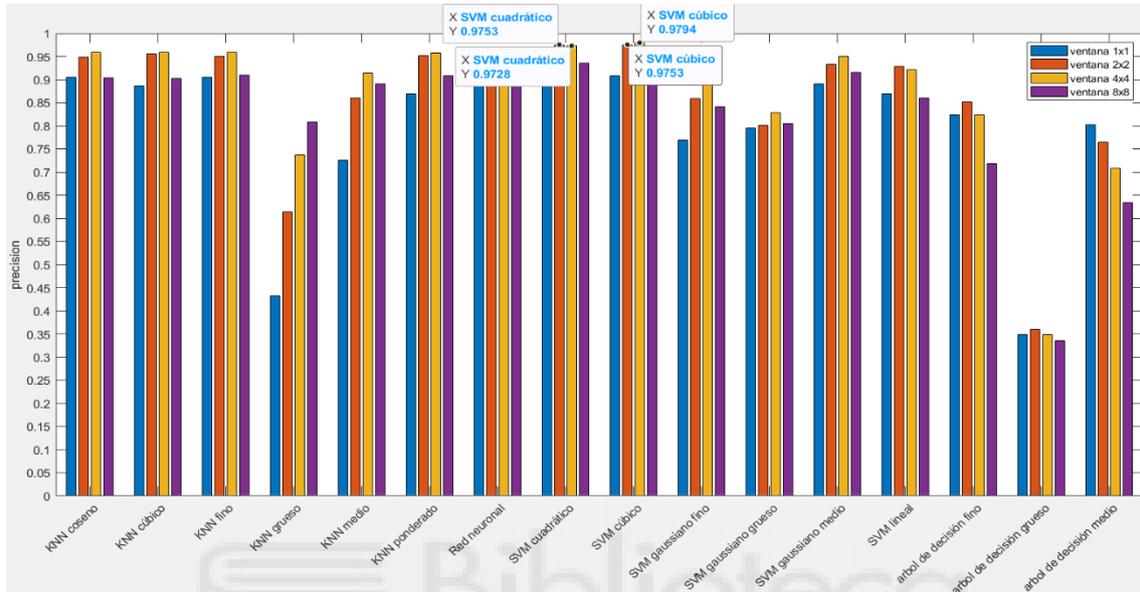
Terminando de analizar el LBP variante a rotación con radio 5 en colores opuestos, vemos en la gráfica 125 que, en general, para ventanas en columnas los clasificadores se comportan mejor para el tamaño de 1x8 y conforme este tamaño disminuye, el resultado empeora. El mejor resultado lo encontramos en el clasificador SVM cúbico para la ventana de 1x8.



Gráfica 126. Validación del modelo elegido de la gráfica 125

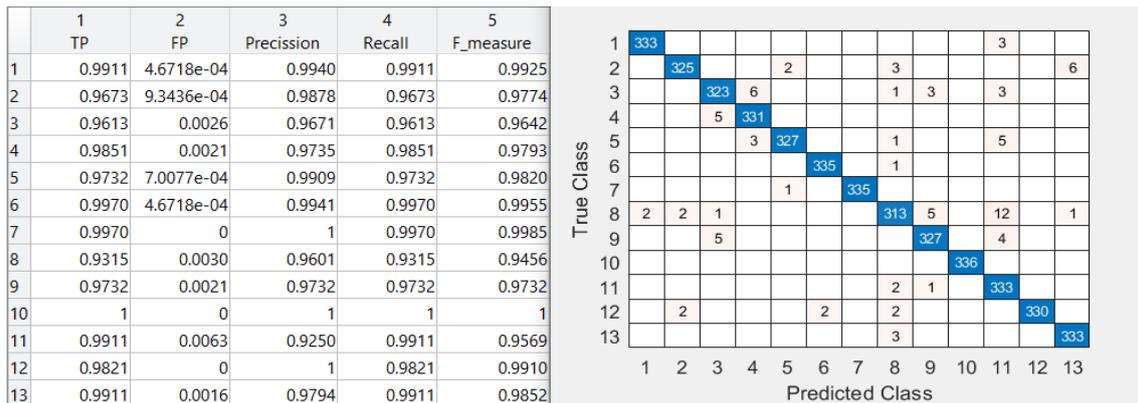
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en colores opuestos para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 126.

Viendo el comportamiento de los clasificadores usando LBP variante a rotación con radio 5 en colores opuestos, que el clasificador SVM cúbico es el que por lo general mejor se comporta, y, específicamente, para la ventana de 8x1 es el resultado más alto.



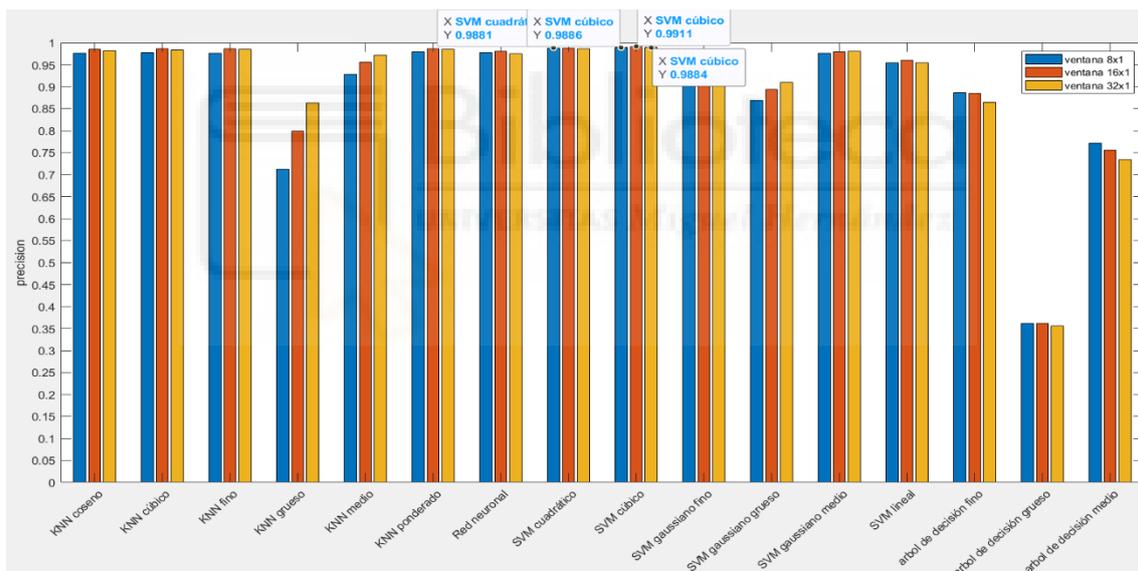
Gráfica 127. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en colores opuestos

Ahora, usando LBP invariante a rotación con radio 1 en colores opuestos, vemos en la gráfica 127 que la mayoría los clasificadores adquieren una mayor precisión cuando se usa la ventana de 4x4, siendo el SVM cúbico el que mayor precisión alcanza, seguido muy de cerca del SVM cuadrático para una ventana de 2x2.



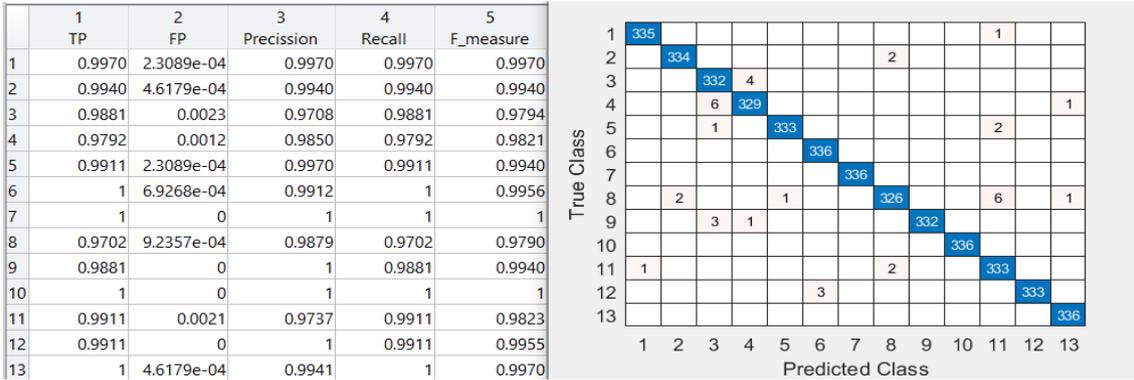
Gráfica 128. Validación del modelo elegido de la gráfica 127

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en colores opuestos para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 128.



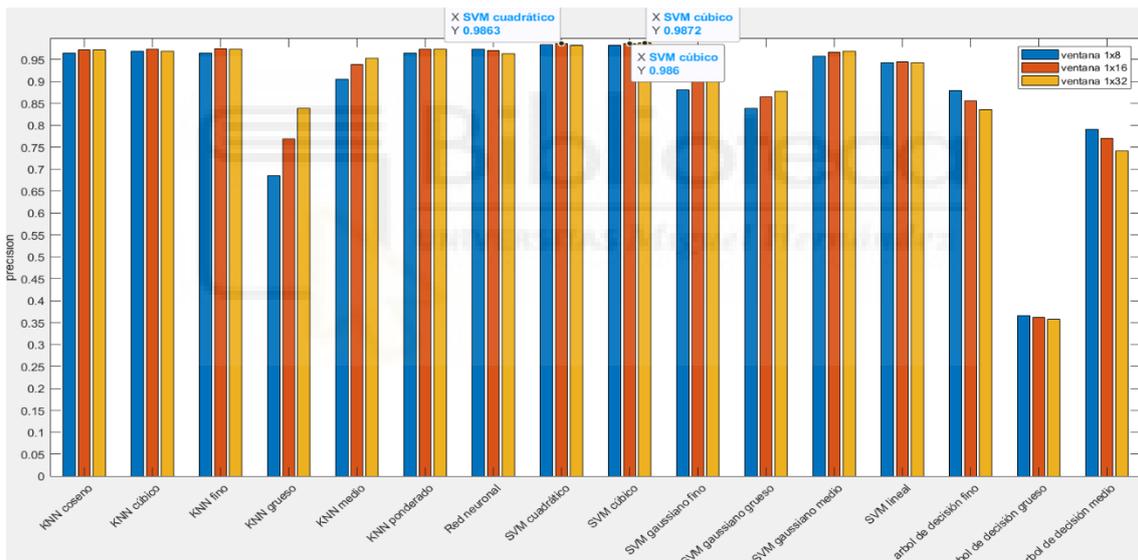
Gráfica 129. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en colores opuestos

En muchos clasificadores vemos en la gráfica 129 que los valores en cada ventana son muy parecidos entre sí. Por eso, el clasificador que, usando LBP invariante a rotación con radio 1 en colores opuestos, tiene la mayor precisión dista muy poco del mismo clasificador, pero para otra ventana. El SVM cúbico para ventana de 16x1 es el de mayor precisión y, seguido muy de cerca, por los valores de las otras ventanas del mismo clasificador.



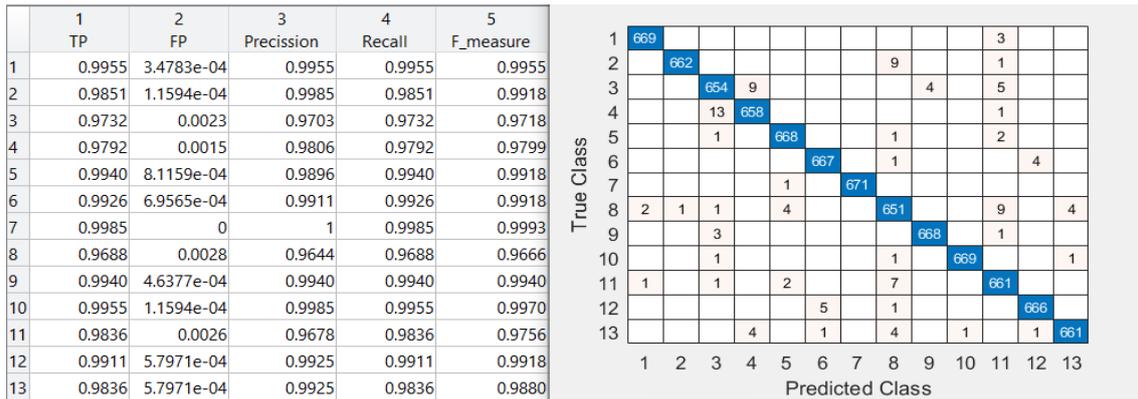
Gráfica 130. Validación del modelo elegido de la gráfica 129

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en colores opuestos para ventanas en filas de la gráfica 130.



Gráfica 131. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en colores opuestos

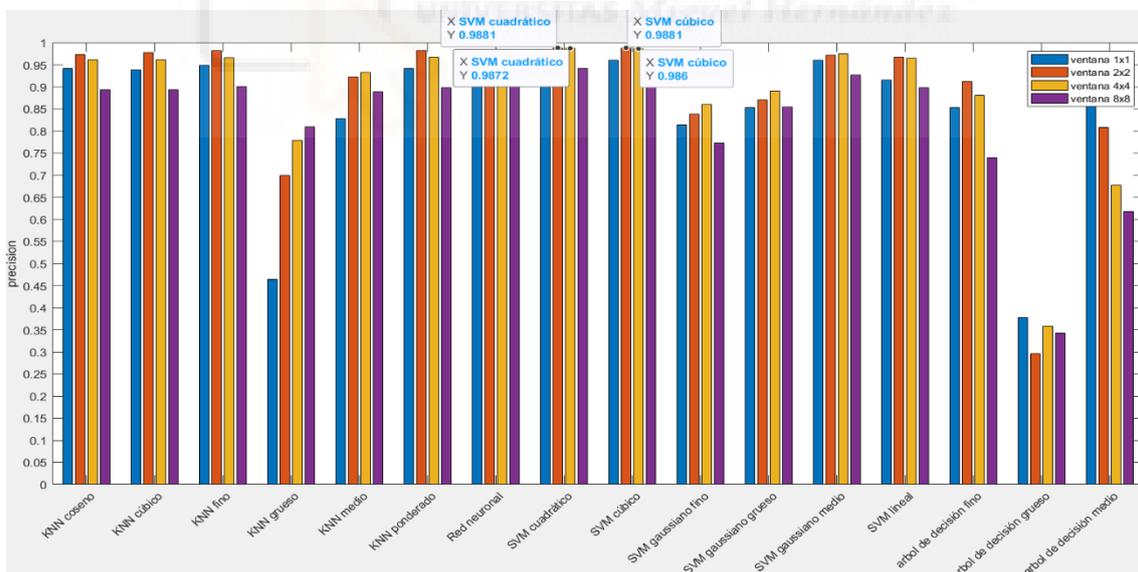
Generalmente en la gráfica 131, los clasificadores tienen unos valores semejantes para los distintos tipos de ventana. Por ello, usando LBP invariante a rotación con radio 1 en colores opuestos, el clasificador SVM cúbico con ventana de 1x32 es el que mejor resultado proporciona, pero dista muy poco del SVM cuadrático con ventana de 1x16.



Gráfica 132. Validación del modelo elegido de la gráfica 131

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en colores opuestos para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 132.

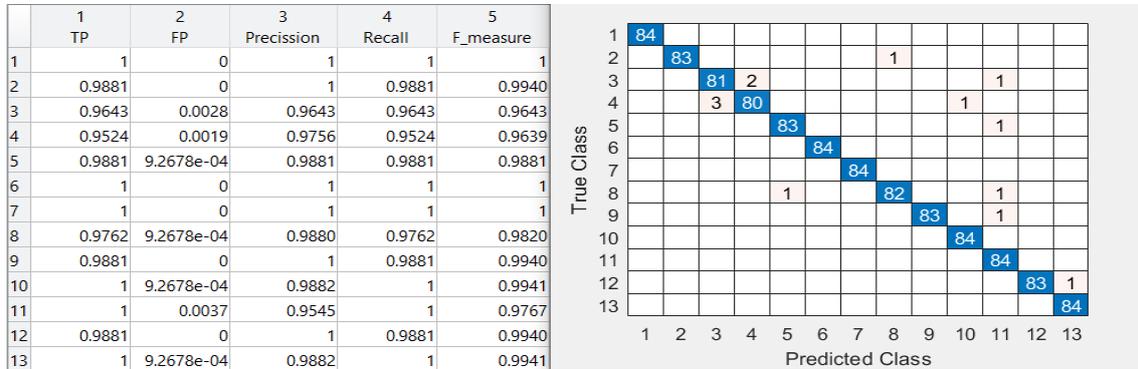
Una vez vistas las tres graficas (gráfica 127, 129 y 131) usando LBP invariante a rotación con radio 1 en colores opuestos el clasificador SVM cúbico para ventanas de 16x1 es el que mejor resultado nos ofrece.



Gráfica 133. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en colores opuestos

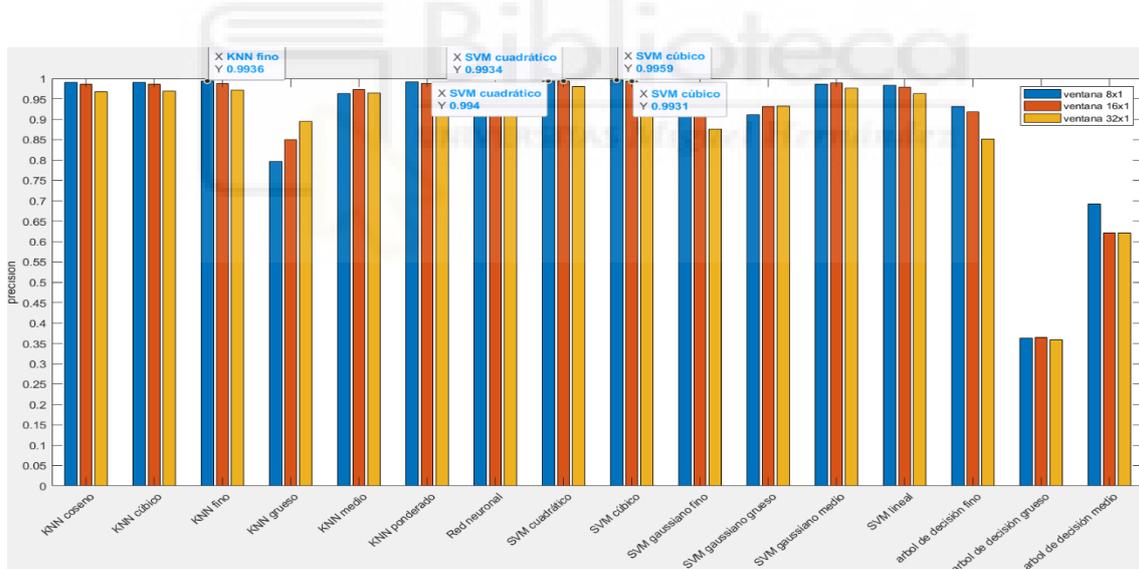
Con LBP invariante a rotación con radio 3 en colores opuestos, tanto el clasificador SVM cúbico como el cuadrático alcanzan la misma y más alta precisión de toda la gráfica, ambos para la ventana de 2x2. Generalmente en la

gráfica 133, es en esta ventana en la que la mayoría de los clasificadores tienen mejores resultados.



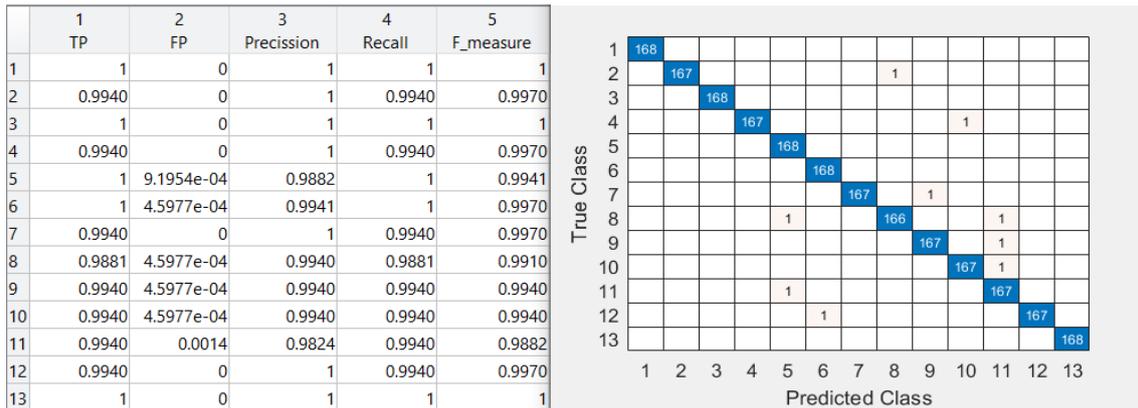
Gráfica 134. Validación del modelo elegido de la gráfica 133

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en colores opuestos para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 134.



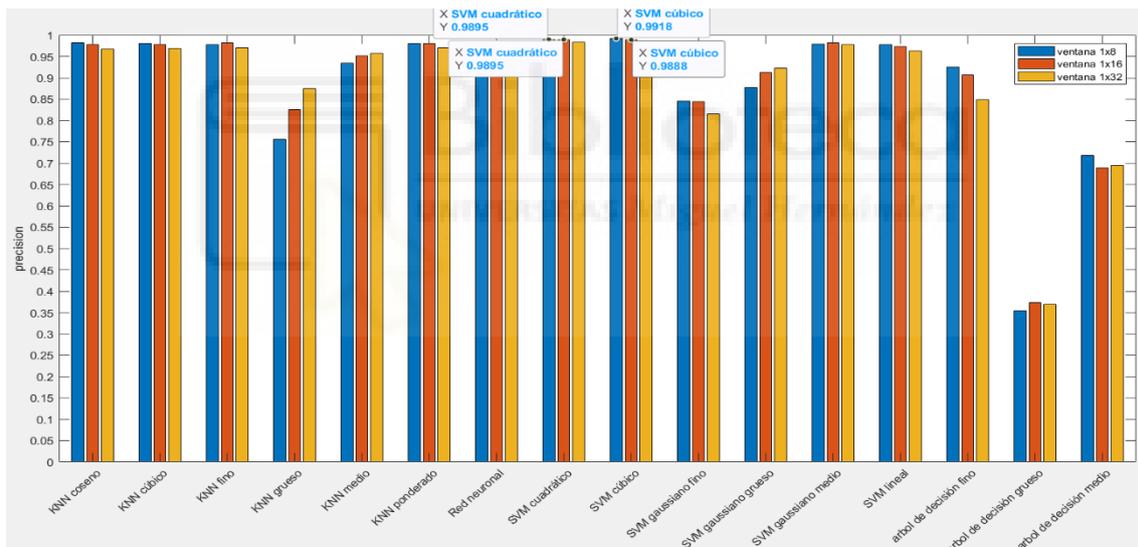
Gráfica 135. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en colores opuestos

Podemos observar en la gráfica 135 que los mejores resultados, de la mayoría de los clasificadores, aparece cuando usamos ventanas de 8x1 y, a medida que este tamaño decrece, también lo hace la precisión. El mejor resultado viene por el clasificador SVM cúbico para ventana de 8x1, sin embargo, el SVM cuadrático para ventana de 8x1 tiene un valor también muy elevado y cercano al anterior.



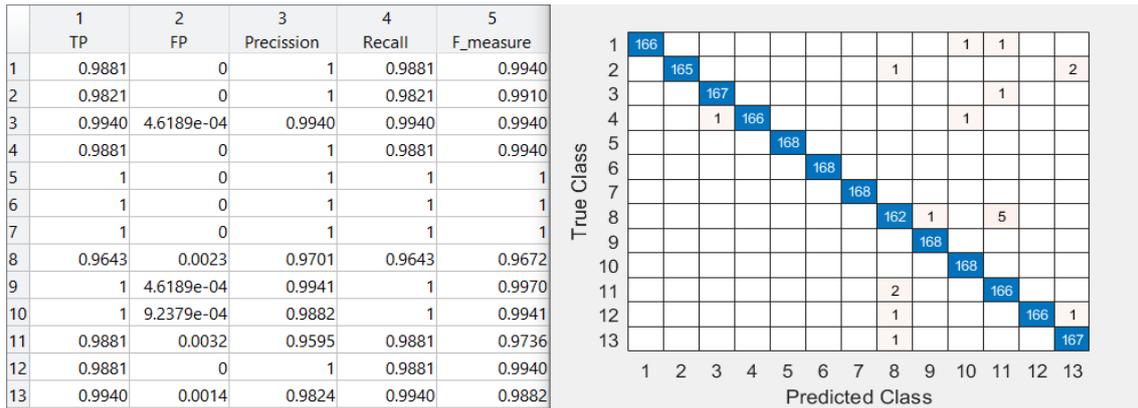
Gráfica 136. Validación del modelo elegido de la gráfica 135

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en colores opuestos para ventanas en filas de la gráfica 136.



Gráfica 137. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en colores opuestos

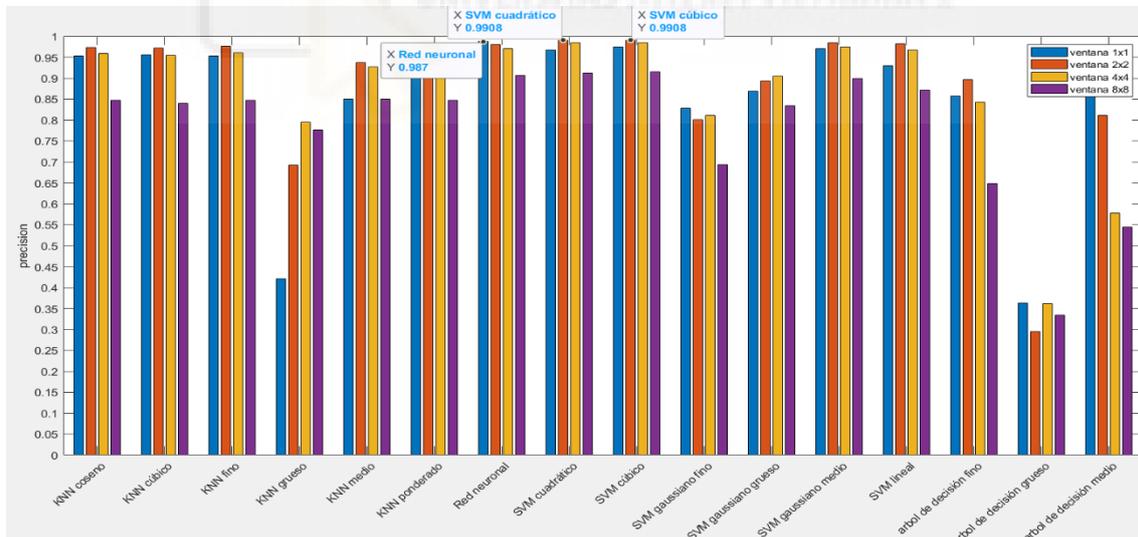
En la gráfica 137 para LBP invariante a rotación con radio 3 en colores opuestos, la ventana de 1x8 es la que provoca los mejores resultados de muchos clasificadores y, conforme la ventana se hace más pequeña, la precisión disminuye. El que mejor resultado ofrece en este caso es el SVM cúbico con ventana de 1x8.



Gráfica 138. Validación del modelo elegido de la gráfica 137

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en colores opuestos para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 138.

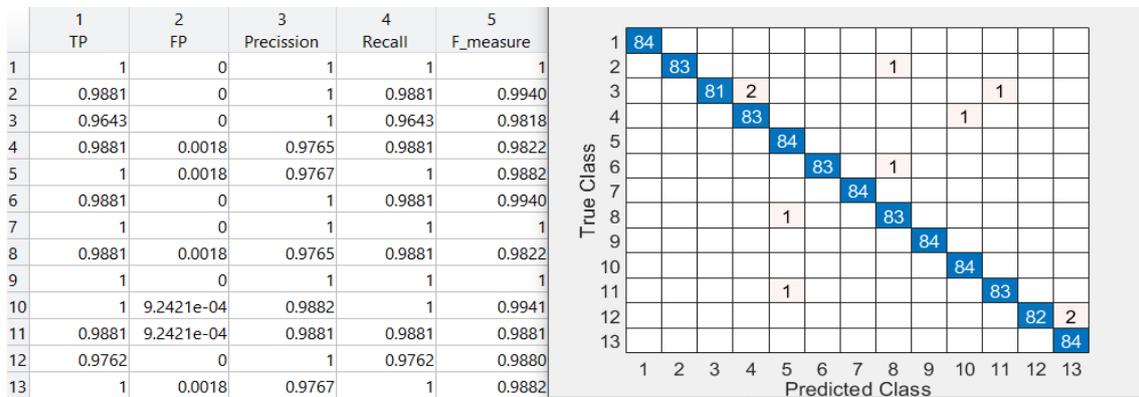
Una vez visto todos los resultados usando LBP invariante a rotación con radio 3 en colores opuestos, el clasificador SVM cúbico es el que mejores resultados ha ofrecido en los tres casos, siendo el mayor de todos para ventana de 8x1.



Gráfica 139. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en colores opuestos

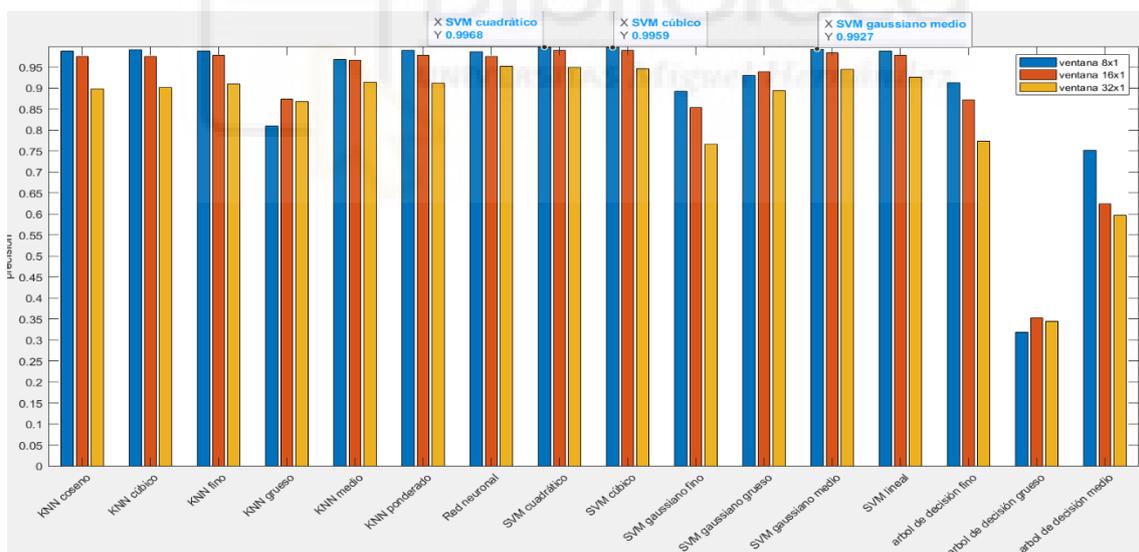
En la gráfica 139 continuando con LBP invariante a rotación con radio 5 en colores opuestos, vemos en la mayoría de los clasificadores es la ventana de

2x2 la que ofrece los mejores resultados. El valor más alto viene por parte de los clasificadores SVM cúbico y SVM cuadrático con ventana de 2x2.



Gráfica 140. Validación del modelo elegido de la gráfica 139

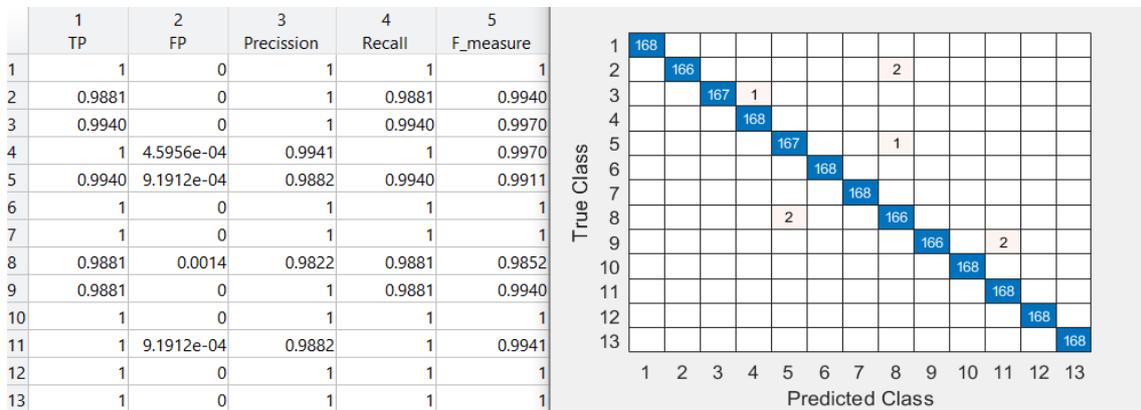
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en colores opuestos para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 140.



Gráfica 141. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en colores opuestos

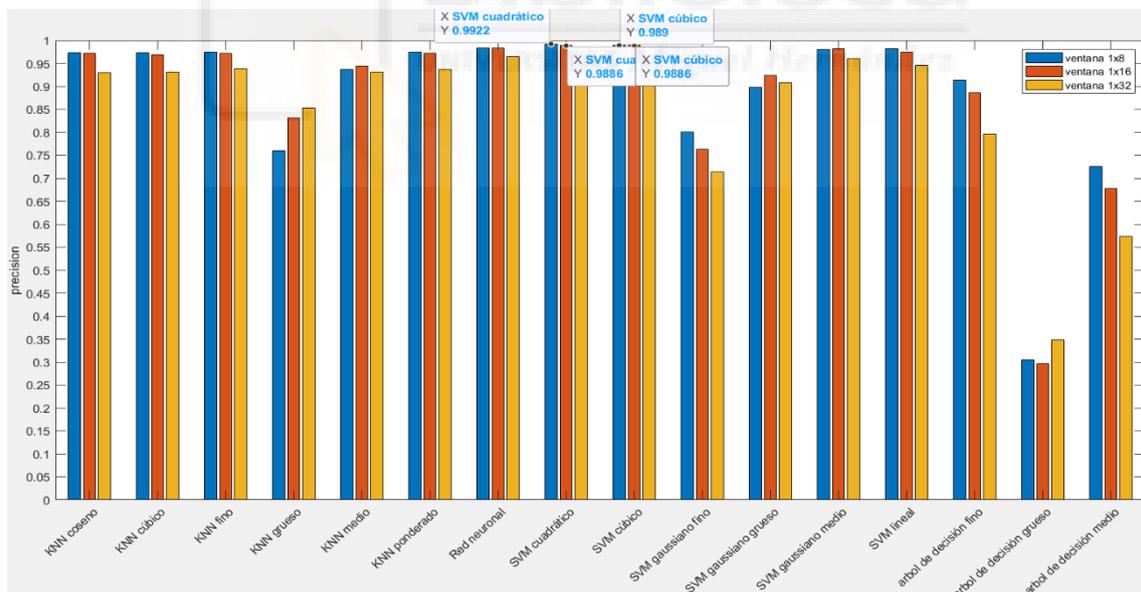
En la gráfica 141 la ventana de 8x1 es la que consigue el mejor resultado en la mayoría de los clasificadores usando LBP invariante a rotación con radio 5 en colores opuestos y, si la ventana cambia su tamaño a uno menor la precisión se ve reducida. El mejor clasificador es el SVM cuadrático para ventana de 8x1,

pero para esta misma ventana el SVM cúbico también proporciona un resultado muy similar.



Gráfica 142. Validación del modelo elegido de la gráfica 141

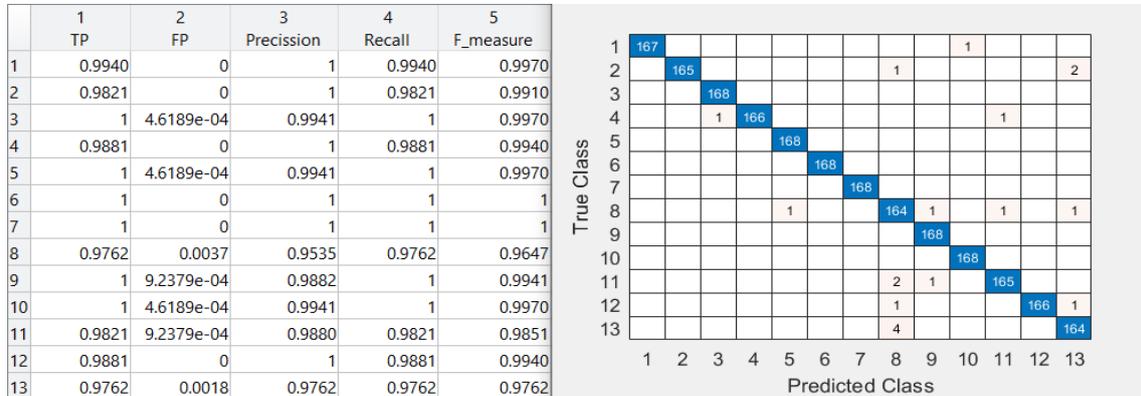
Sacamos del clasificador SVM cuadrático esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en colores opuestos para ventanas en filas de la gráfica 142.



Gráfica 143. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en colores opuestos

En la gráfica 143 el mejor resultado nos lo da el clasificador SVM cuadrático para ventana de 1x8 usando LBP invariante a rotación con radio 5 en colores opuestos. También hay que mencionar que el SVM cúbico tienen un valor

semejante usando el mismo tamaño de ventana. Por último, es apreciable que a medida que la ventana se hace más pequeña la precisión también se reduce en la mayoría de clasificadores.

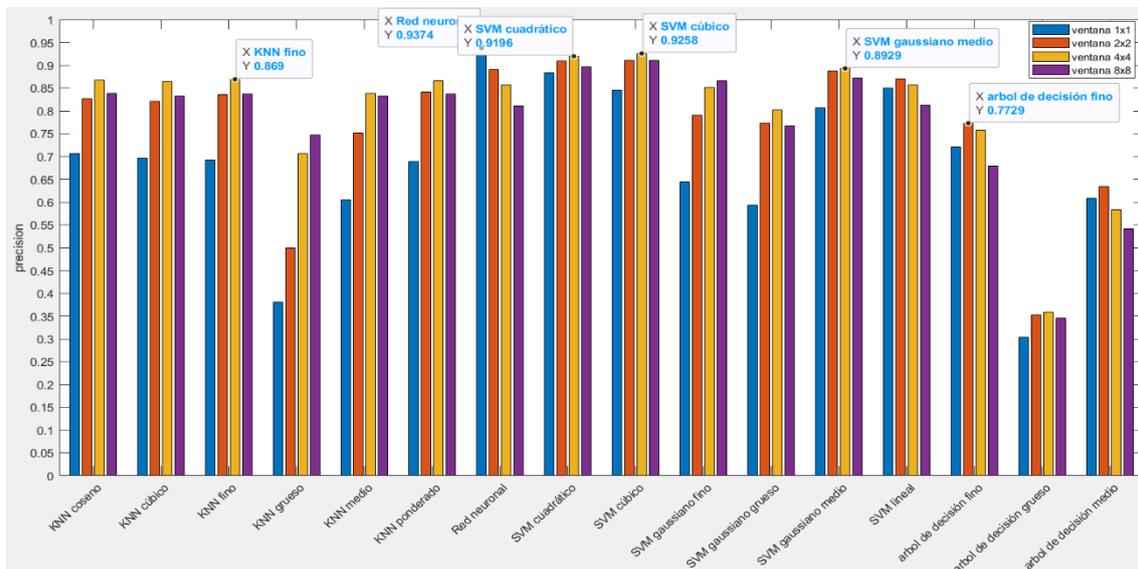


Gráfica 144. Validación del modelo elegido de la gráfica 143

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en colores opuestos para ventanas en columnas, es del clasificador SVM cuadrático de la gráfica 144.

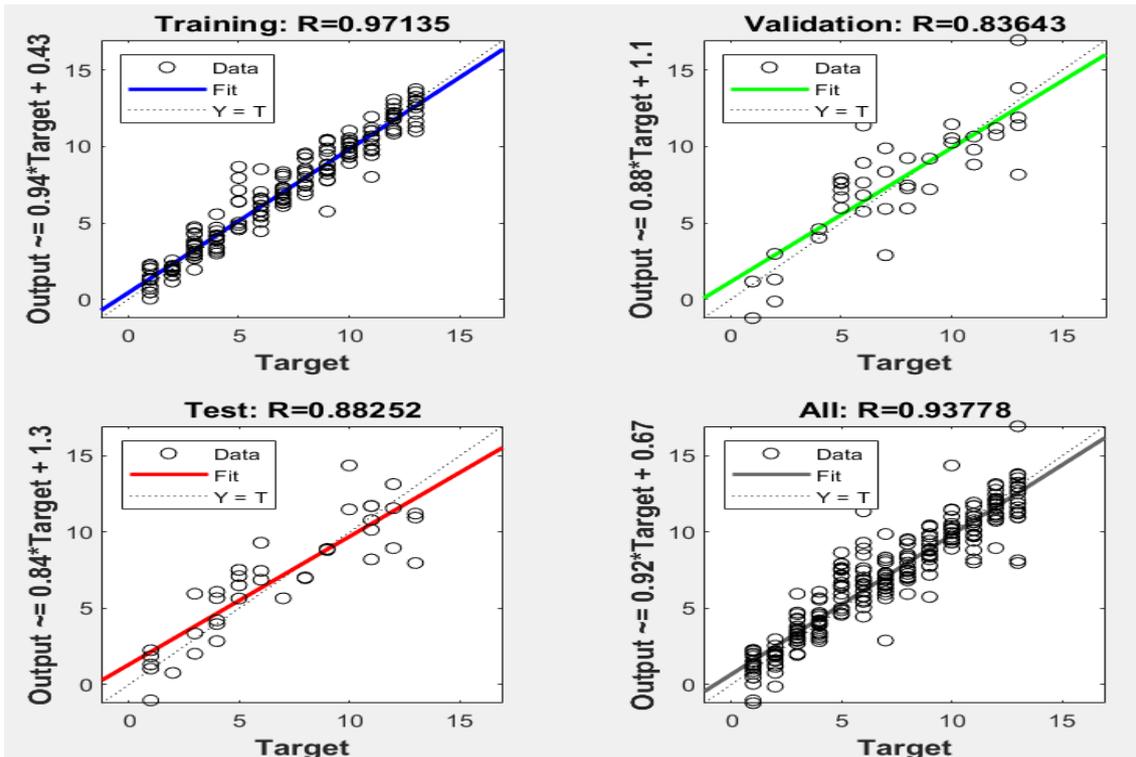
Visto los resultados anteriores, el clasificador SVM cuadrático es el que mejor se comporta usando LBP invariante a rotación con radio 5 en colores opuestos y una ventana de 8x1.

#### 4.1.4 Comparación en HSV con el segundo data set



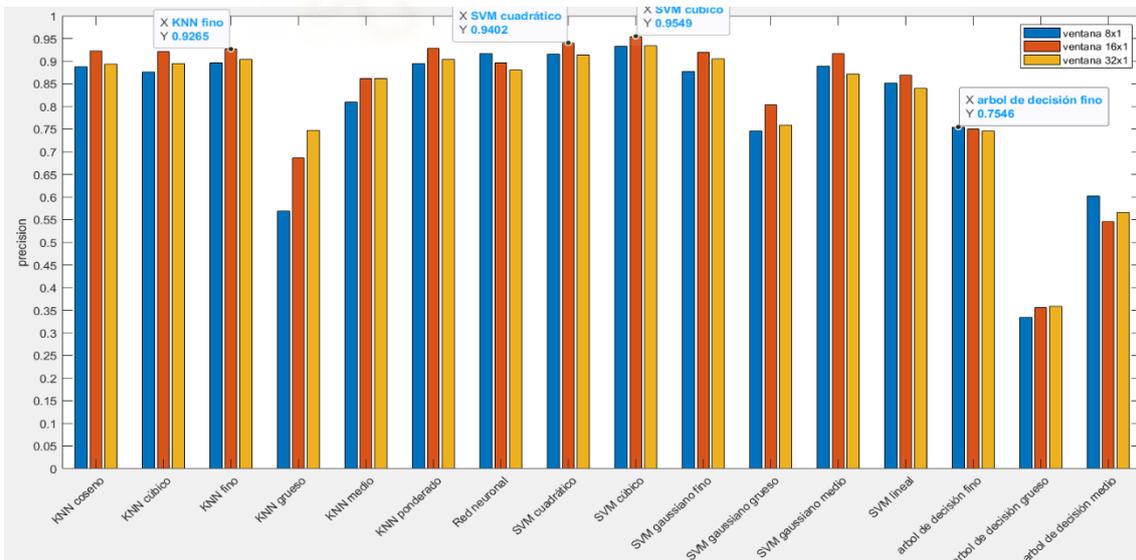
Gráfica 145. Comparación clasificadores para ventanas cuadradas para momentos de histograma en HSV

En la gráfica 145, usando los momentos de histograma en HSV para ventanas cuadradas vemos que el mejor resultado de cada clasificador varía entre la ventana de 2x2 y la de 4x4. También se puede observar que resultado más alto viene por parte del clasificador de la red neuronal con una ventana de 1x1. También cabe destacar que el clasificador SVM cúbico alcanza un valor elevado y cercano al anterior.



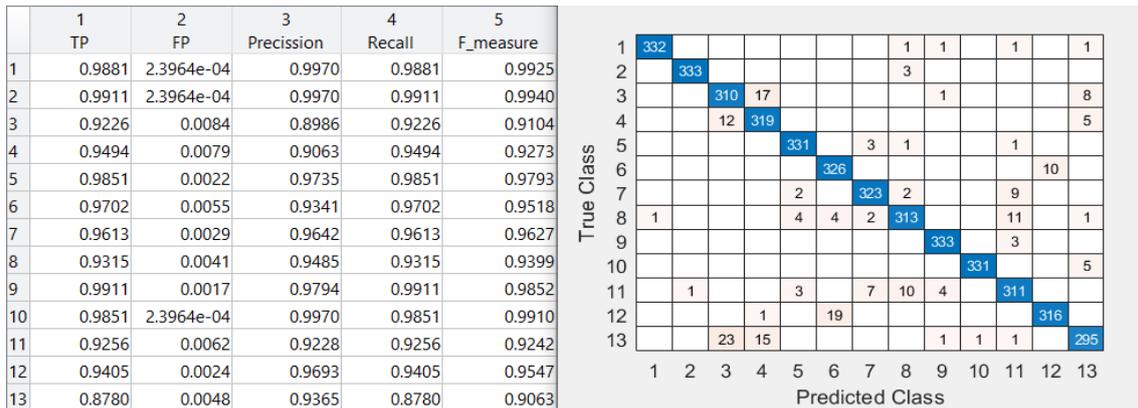
Gráfica 146. Regresión lineal de la red neuronal del modelo de la gráfica 145

En la gráfica 146 vemos como la red neuronal se adaptó a los datos usando momentos de histograma en HSV.



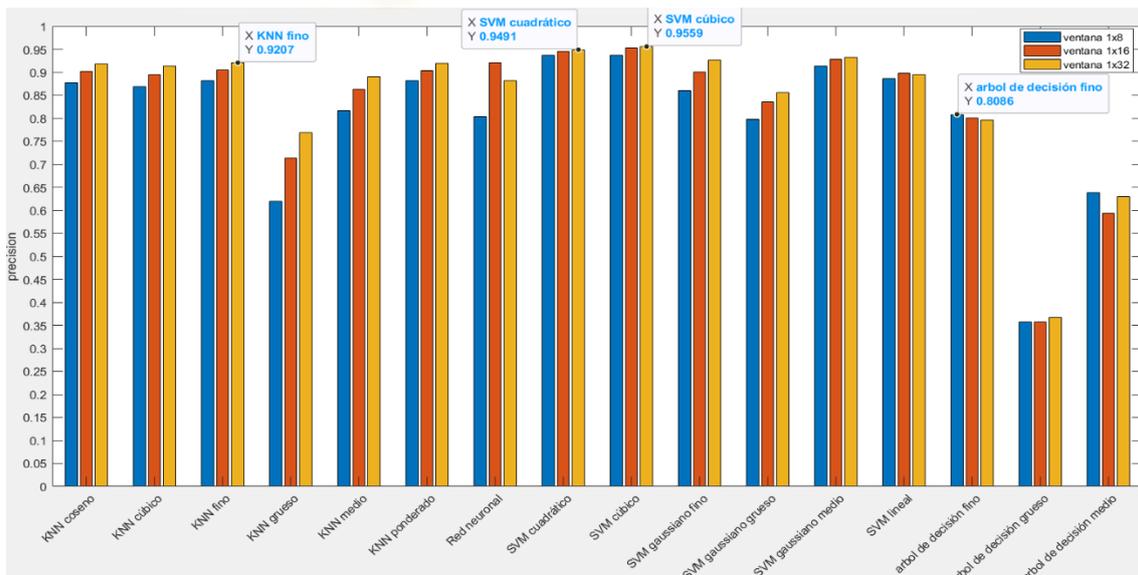
Gráfica 147. Comparación clasificadores para ventanas en filas para momentos de histograma en HSV

En la gráfica 147, siguiendo con el análisis en ventanas en filas, vemos que el clasificador SVM cúbico para ventanas de 16x1 es el que mejor precisión tiene usando momentos de histograma en HSV. También vemos que los mejores resultados de los clasificadores, generalmente, se produce en las ventanas de 16x1.



Gráfica 148. Validación del modelo elegido de la gráfica 147

Usaremos el clasificador con más precisión, el SVM cúbico, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en HSV para ventanas en fila de la gráfica 148.



Gráfica 149. Comparación clasificadores para ventanas en columnas para momentos de histograma en HSV

Generalmente en la gráfica 149, vemos que el clasificador que más precisión tiene, usando momentos de histograma en HSV, es el SVM cúbico para ventanas de 1x32. En la mayoría de los clasificadores, es en esta ventana en la que mejor precisión alcanzan y, además, si disminuimos el tamaño de la ventana, también lo haría la precisión.

	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9955	3.5911e-04	0.9955	0.9955	0.9955
2	0.9792	0.0020	0.9748	0.9792	0.9770
3	0.9286	0.0057	0.9286	0.9286	0.9286
4	0.9598	0.0089	0.8971	0.9598	0.9274
5	0.9673	0.0024	0.9701	0.9673	0.9687
6	0.9717	0.0020	0.9746	0.9717	0.9732
7	0.9747	0.0036	0.9562	0.9747	0.9654
8	0.9018	0.0065	0.9182	0.9018	0.9099
9	0.9940	0.0013	0.9838	0.9940	0.9889
10	0.9926	2.3941e-04	0.9970	0.9926	0.9948
11	0.9137	0.0067	0.9164	0.9137	0.9151
12	0.9777	0.0024	0.9705	0.9777	0.9741
13	0.8750	0.0036	0.9515	0.8750	0.9116

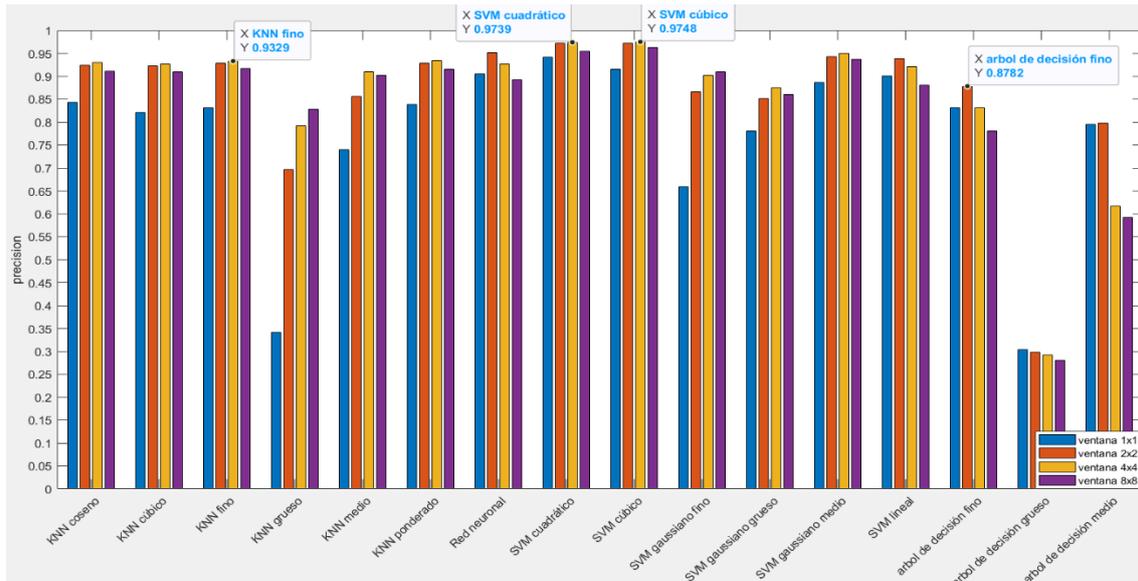
  

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	669							2					1
2		658						10				1	3
3			624	29				1	3			3	12
4			20	645									7
5					650		11	10				1	
6						653		2					17
7		1			5		655	5				6	
8		12	1		6	2	2	606				40	3
9	1		1						668			1	1
10										667			5
11	1	3			9		17	23	4			614	1
12						15							657
13	1	1	26	45				1	4	2	4		588

Gráfica 150. Validación del modelo elegido de la gráfica 149

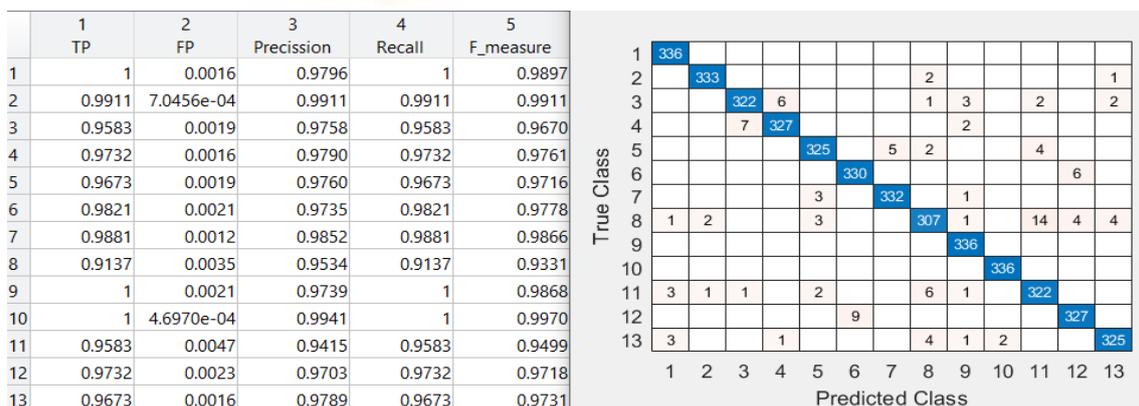
Usaremos el clasificador con más precisión, el SVM cúbico, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en HSV para ventanas en columna de la gráfica 150.

Después de ver todas las gráficas, el clasificador SVM cúbico para ventanas de 1x32 es el que mayor precisión nos da, y en general para los tres tipos de ventana es el que mejor se comporta. El peor resultado en general ha sido en las ventanas cuadradas.



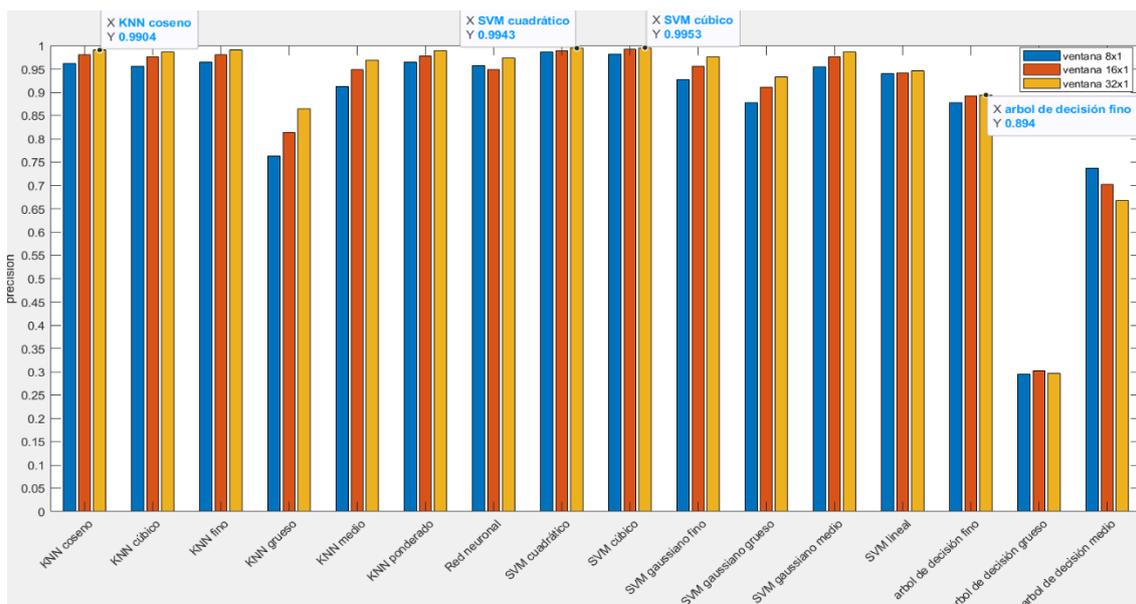
Gráfica 151. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en HSV

Generalmente en la gráfica 151, el mejor resultado varía entre ventana de 2x2 y 4x4, depende del clasificador. Entonces, usando la matriz de coocurrencia en HSV, el clasificador SVM cúbico para la ventana de 4x4 es el que mejor resultado nos ofrece, sin embargo, cabe destacar que para el SVM cuadrático usando ventanas 4x4 el valor es muy próximo al anterior.



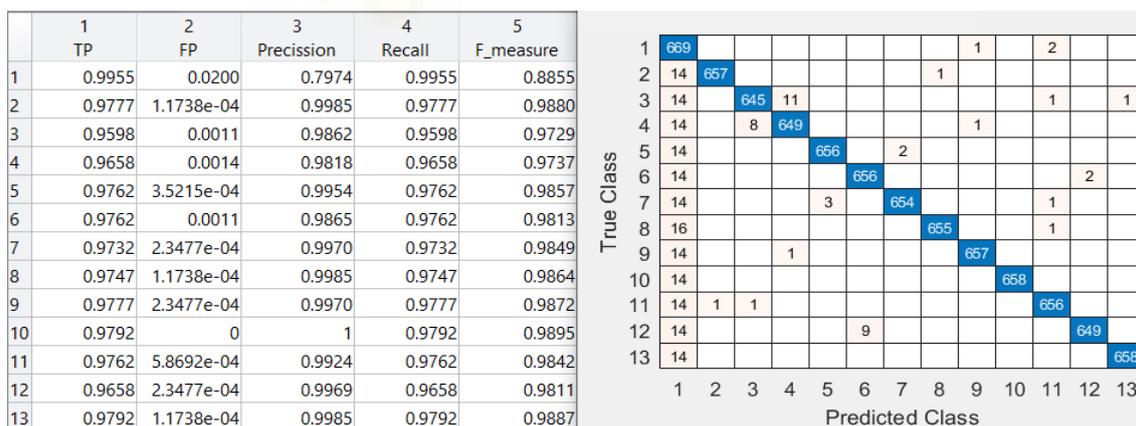
Gráfica 152. Validación del modelo elegido de la gráfica 151

Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en HSV para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 152.



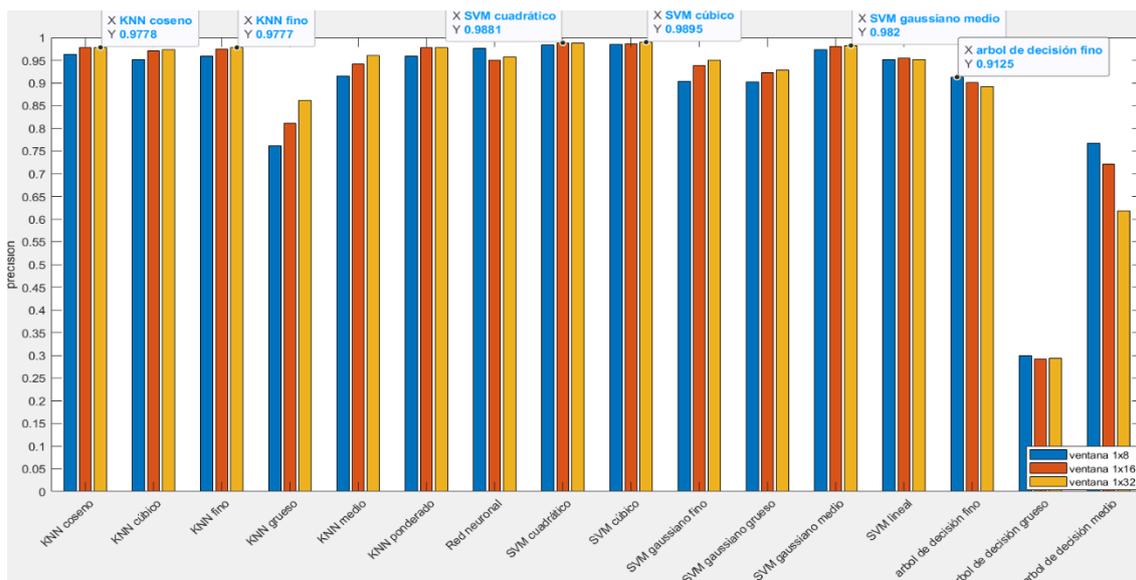
Gráfica 153. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en HSV

Vemos en la gráfica 153 que usando la matriz de coocurrencia en HSV el clasificador SVM cúbico es el que mejor se comporta cuando escogemos la ventana 32x1. También se puede apreciar que los clasificadores, generalmente, ofrecen el mejor resultado para ese tipo de ventana y a medida que el tamaño de la ventana aumenta, la precisión decrece.



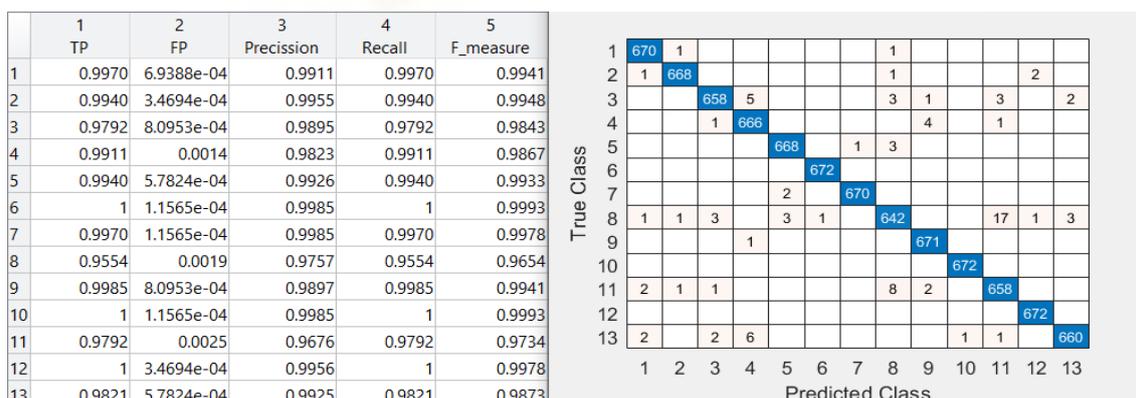
Gráfica 154. Validación del modelo elegido de la gráfica 153

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en HSV para ventanas en filas de la gráfica 154.



Gráfica 155. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en HSV

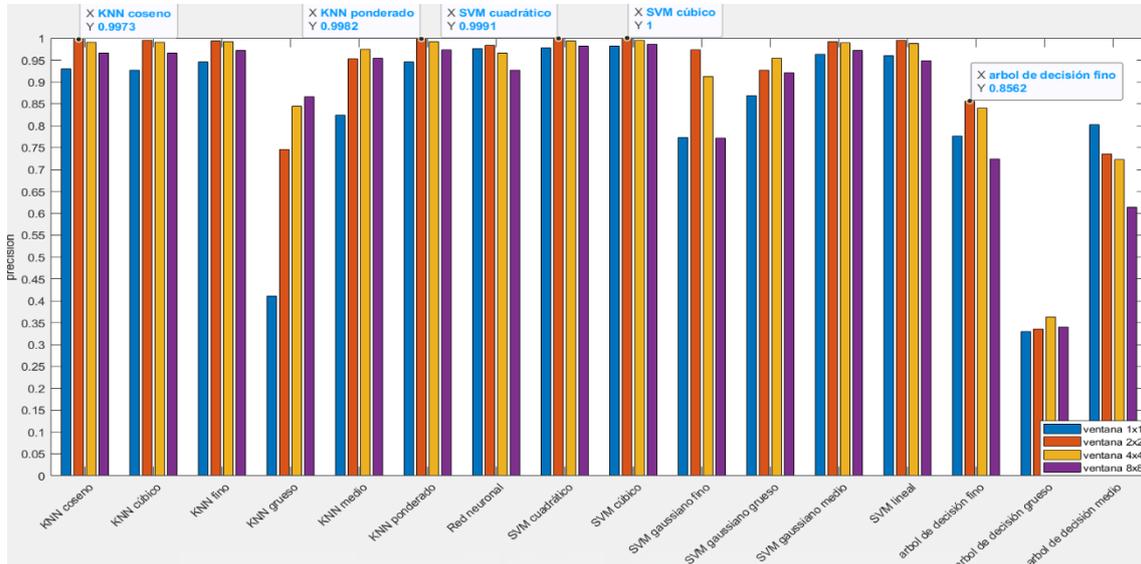
La gráfica 155 muestra el comportamiento de los clasificadores cuando usamos las ventanas en columna con la matriz de coocurrencia en HSV, vemos que el mejor resultado nos lo da el SVM cúbico para ventanas de 1x32 seguido muy de cerca por el resultado del mismo clasificador para ventanas de 1x16 y el SVM cuadrático para ventanas de 1x32.



Gráfica 156. Validación del modelo elegido de la gráfica 155

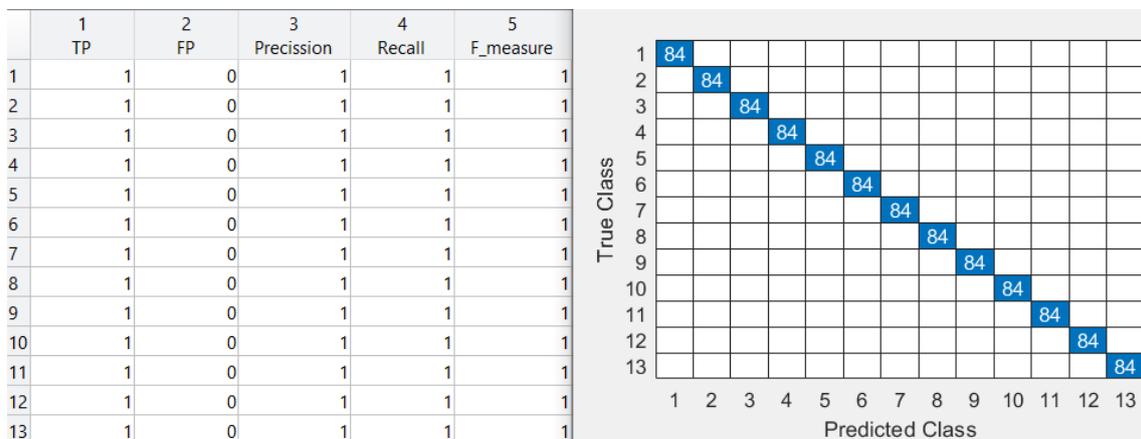
Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en HSV para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 156.

Una vez vistos los resultados anteriores, el mejor clasificador es el SVM cúbico con ventana de 32x1, cabe destacar que este clasificador se comporta muy bien, incluso, en el resto de tipos de ventanas.



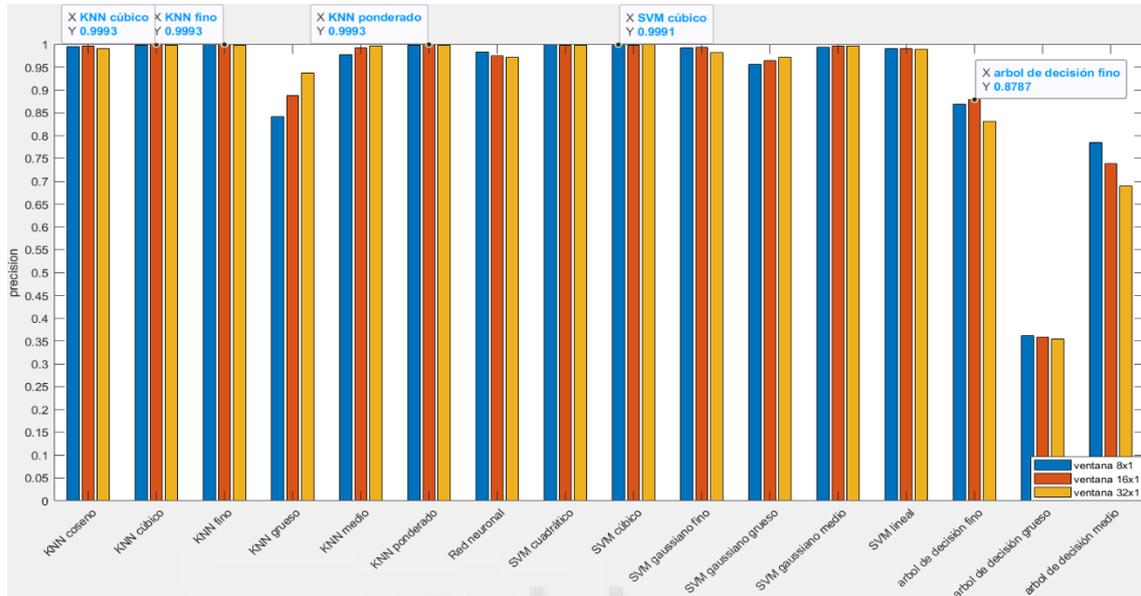
Gráfica 157. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en HSV

En la gráfica 157, usando LBP variante a rotación en HSV vemos que, en la mayoría de los clasificadores, los valores de las ventanas 2x2 y 4x4 son muy similares, siendo en la ventana 2x2 en la que mayor valor alcanzan. El clasificador SVM cúbico es el que mayor precisión tiene usando la ventana de 2x2.



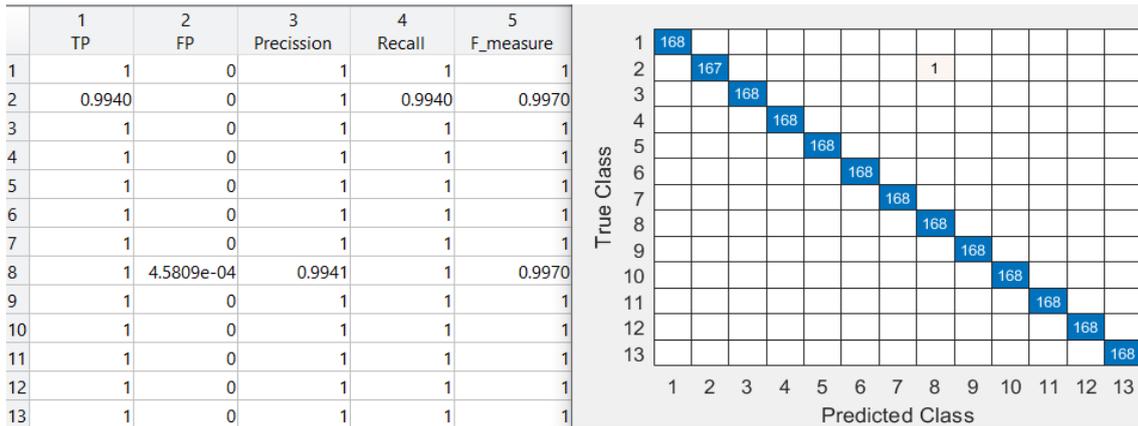
Gráfica 158. Validación del modelo elegido de la gráfica 157

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en HSV para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 158.



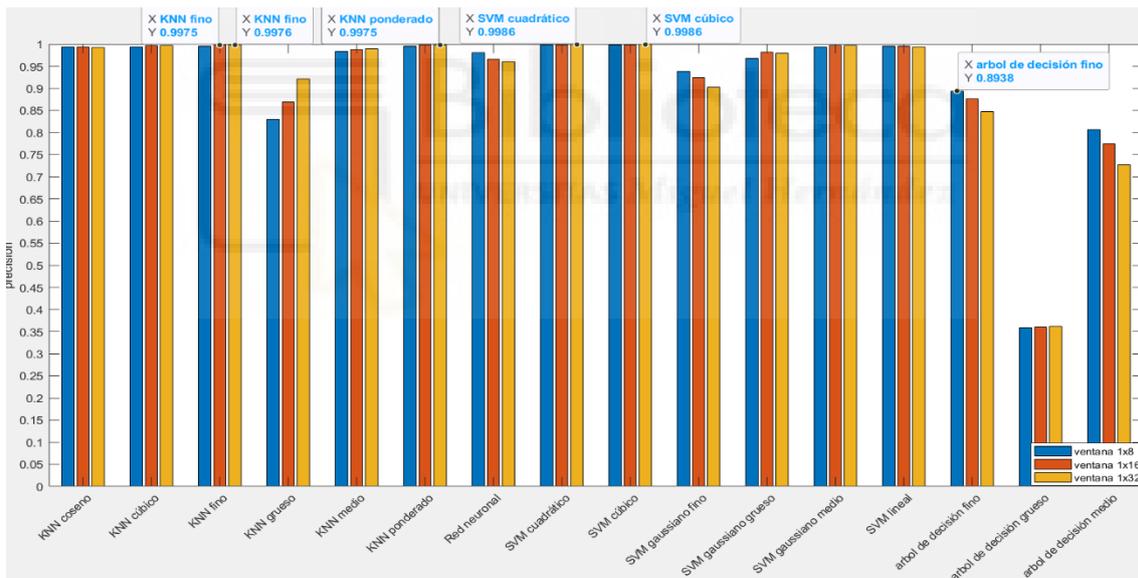
Gráfica 159. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en HSV

En la gráfica 159 los clasificadores no alcanzan su valor máximo en una ventana específica, va cambiando según el clasificador. Tenemos tres clasificadores, que usando LBP variante a rotación con radio 1, alcanzan el valor más alto de la gráfica con ventana de 16x1 y, son el K-NN cúbico, K-NN fino y K-NN ponderado. En general, los resultados obtenidos son elevados en los distintos clasificadores.



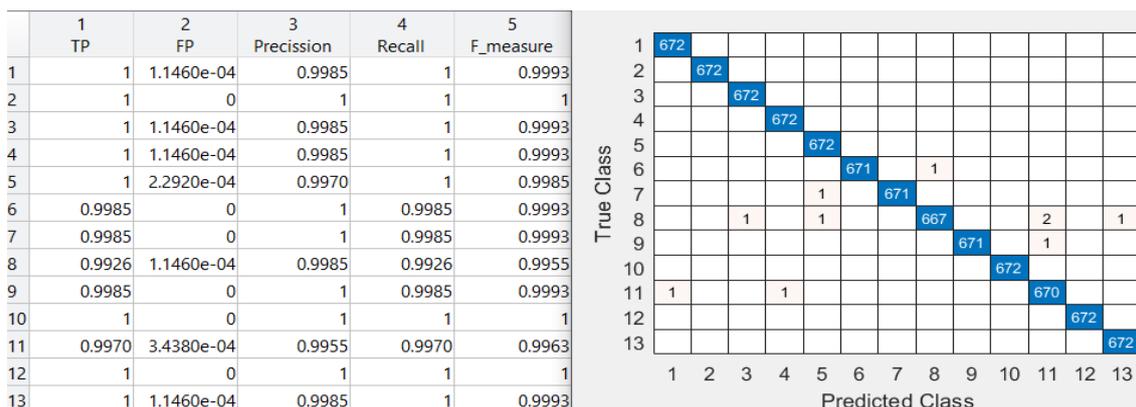
Gráfica 160. Validación del modelo elegido de la gráfica 159

Sacamos del clasificador K-NN ponderado esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en HSV para ventanas en filas de la gráfica 160.



Gráfica 161. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en HSV

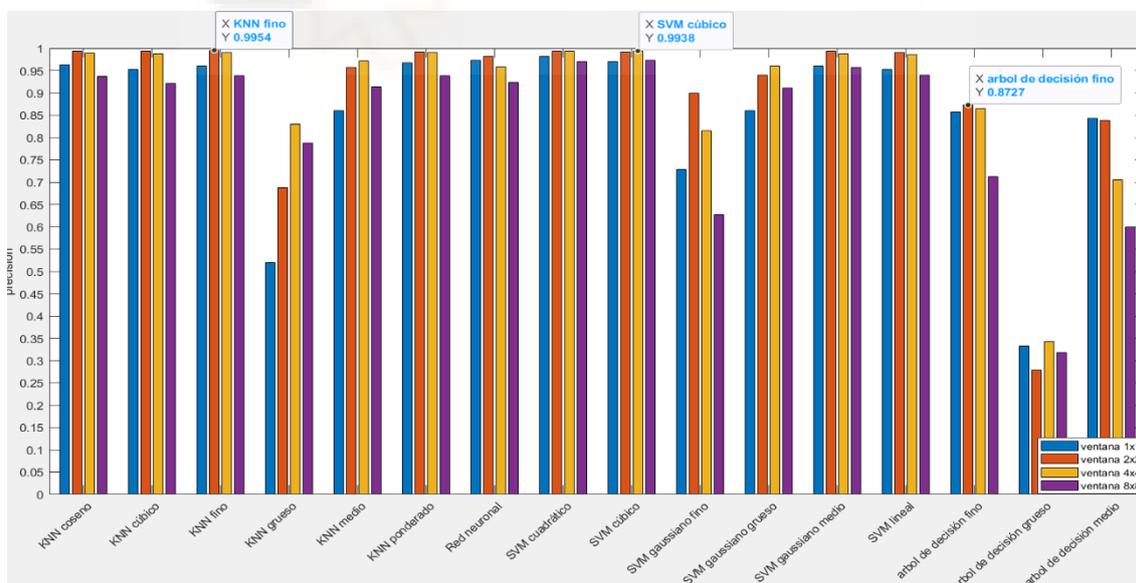
Vemos en la gráfica 161 que al analizar las ventanas en columna para LBP variante a rotación con radio 1 en HSV los valores de un mismo clasificador las diferentes ventanas tienen valores cercanos, hay excepciones. El mejor resultado es alcanzado tanto por el clasificador SVM cuadrático como por el SVM cúbico para ventana de 1x32.



Gráfica 162. Validación del modelo elegido de la gráfica 161

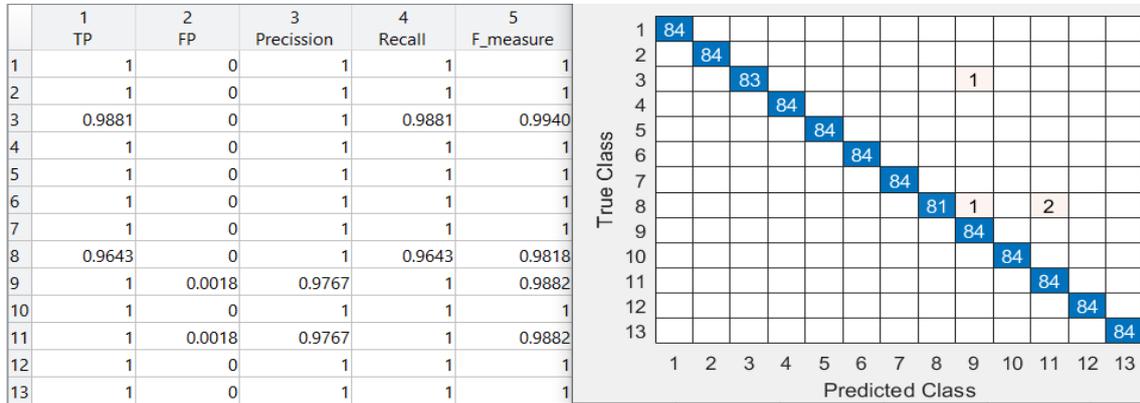
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en HSV para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 162.

Queda claro que el clasificador SVM cúbico es el que, independientemente de la ventana, siempre alcanza un resultado muy bueno respecto al resto de clasificadores. Siendo para la ventana 2x2 el de mayor valor para LBP variante a rotación con radio 1 en HSV.



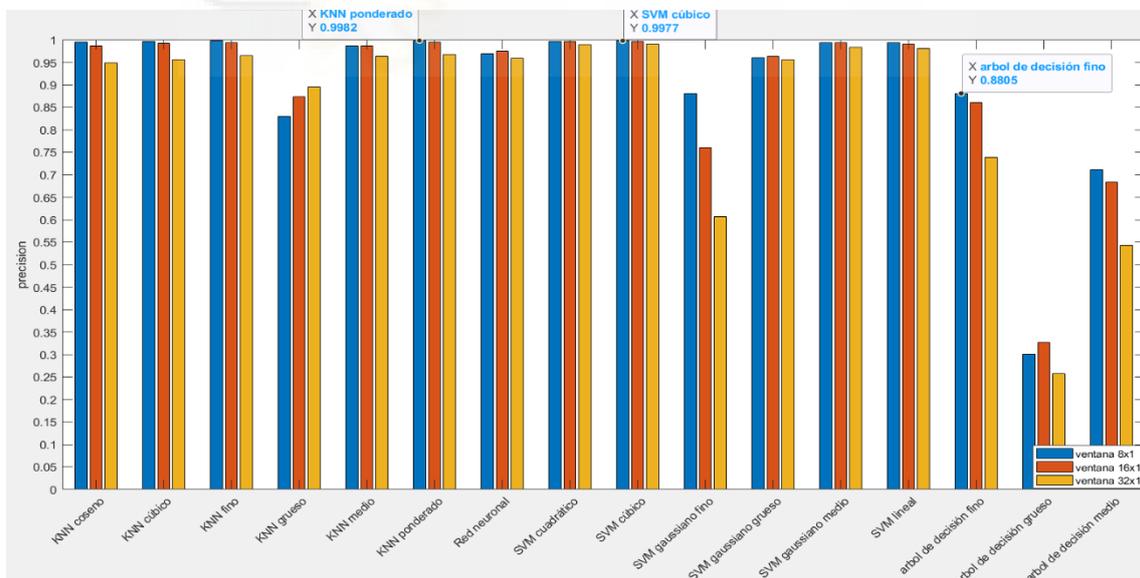
Gráfica 163. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en HSV

En la gráfica 163, usando LBP variante a rotación con radio 3 en HSV los valores más altos en general se encuentran cuando usamos ventanas de 2x2, siendo esta ventana las que logran la mayor precisión con el clasificador K-NN fino, el siguiente valor viene del SVM cúbico con una ventana de 4x4.



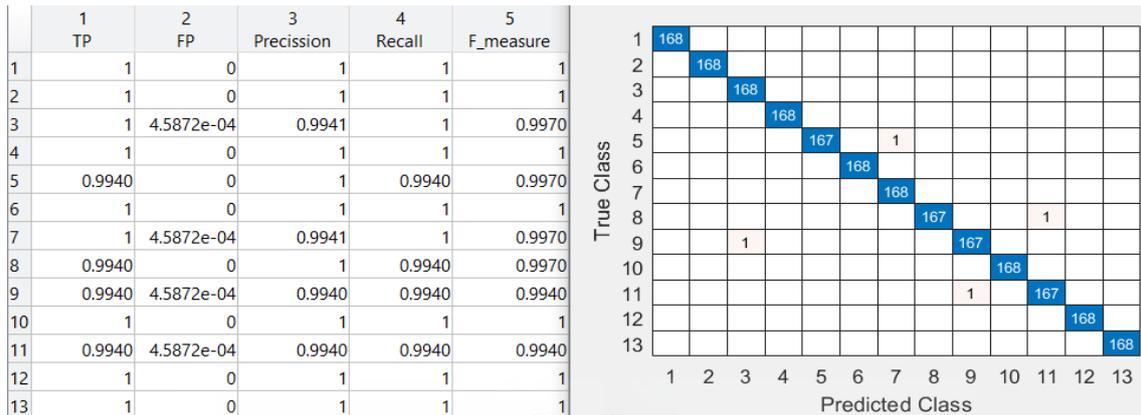
Gráfica 164. Validación del modelo elegido de la gráfica 163

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en HSV para ventanas cuadradas, es del clasificador K-NN fino de la gráfica 164.



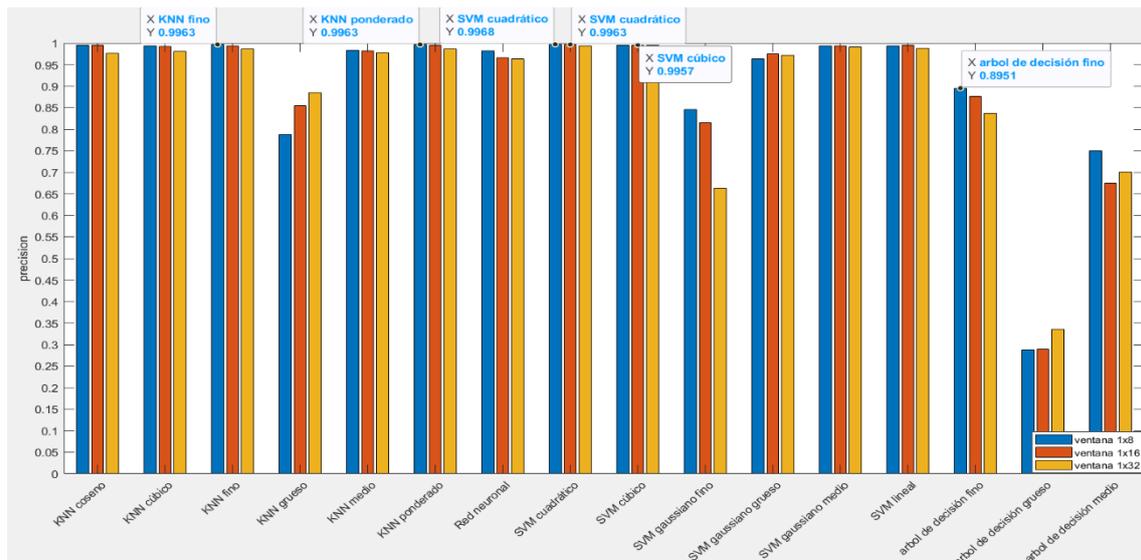
Gráfica 165. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en HSV

Analizando las ventanas en filas para LBP variante a rotación con radio 3 en HSV, vemos en la gráfica 165 que la gran mayoría de los clasificadores estudiados alcanzan su valor más alto para las ventanas de 8x1, siendo el clasificador K-NN ponderado es el que alcanza el valor más alto. Cabe destacar que algunos valores de otros clasificadores, SVM cúbico y SVM cuadrático, están muy cerca del valor del K-NN ponderado.



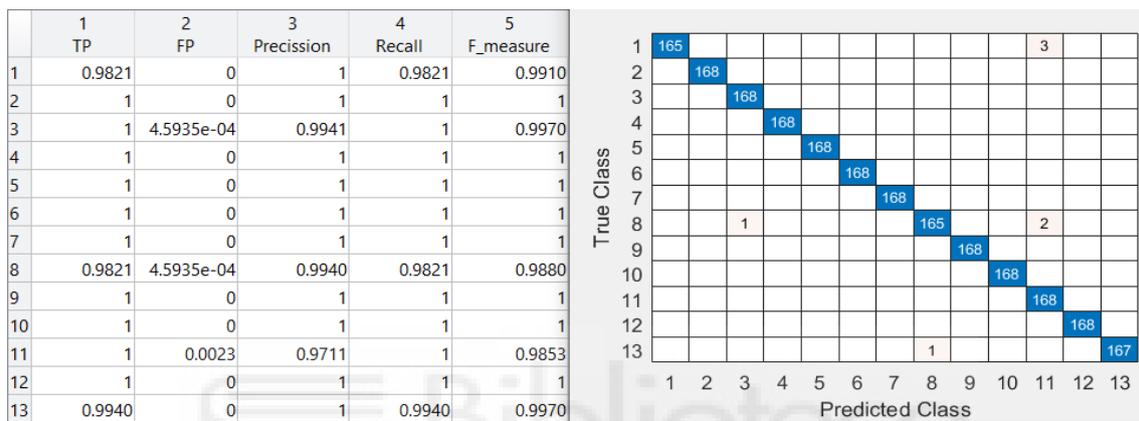
Gráfica 166. Validación del modelo elegido de la gráfica 165

Sacamos del clasificador K-NN ponderado esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en HSV para ventanas en filas de la gráfica 166.



Gráfica 167. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en HSV

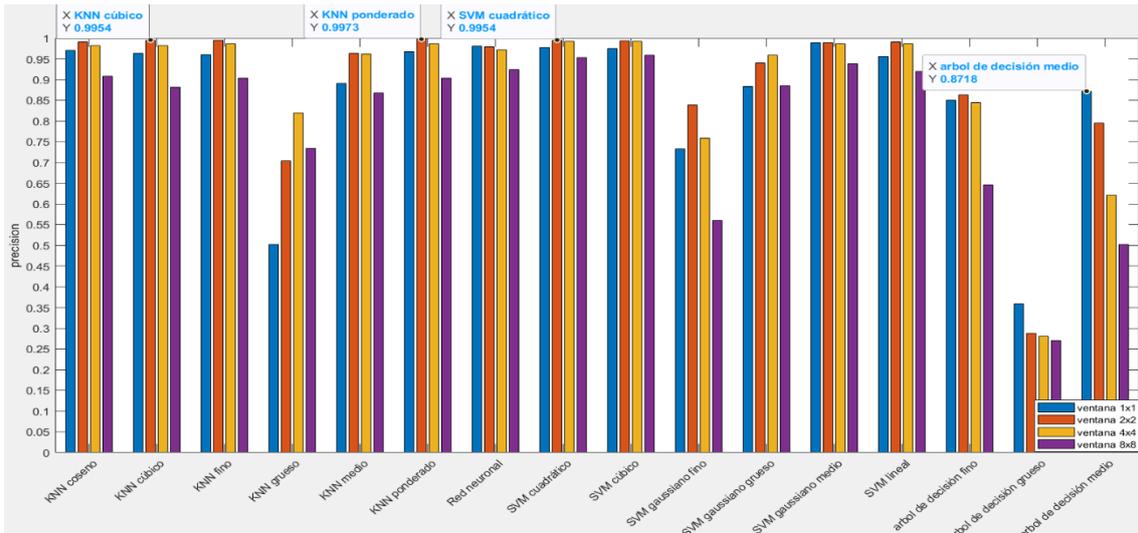
Podemos observar en la gráfica 167 que los resultados para los diferentes tamaños de ventana, usando LBP variante a rotación con radio 3 en HSV, son muy cercanos en la mayoría de clasificadores. Para estas ventanas el clasificador SVM cuadrático es el que mayor valor alcanza, seguido de cerca por el SVM cúbico, KNN- fino y K-NN ponderado con ventana de 1x8. Además, podemos ver que para ventanas de 1x16 los valores de estos mismos clasificadores tampoco distan mucho de los valores de las ventanas de 1x8.



Gráfica 168. Validación del modelo elegido de la gráfica 167

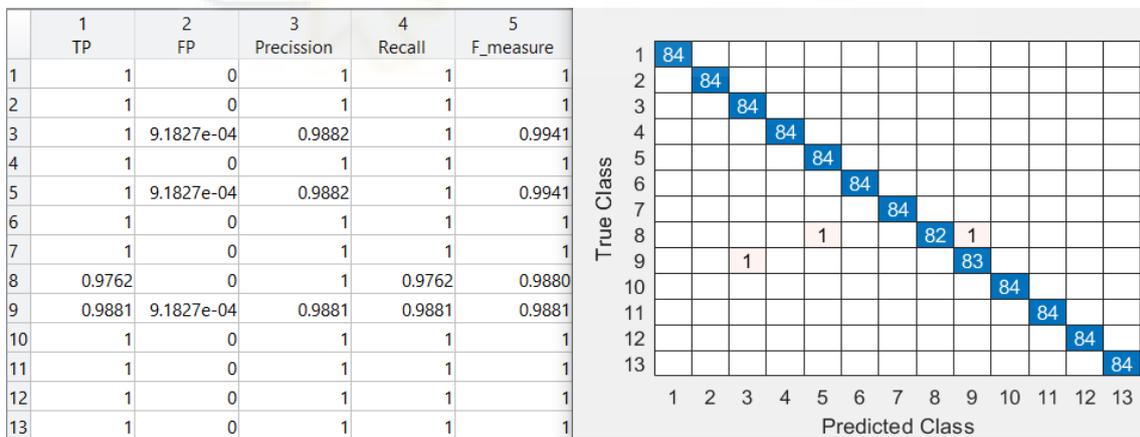
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en HSV para ventanas en columnas, es del clasificador SVM cuadrático de la gráfica 168.

Hemos comprobado que para LBP variante a rotación con radio 3 en HSV el clasificador K-NN ponderado es el que mejor se comporta con una ventana de 8x1, aunque no solo lo hace para un tipo de ventana. Es por eso que se considera este clasificador el mejor para este caso.



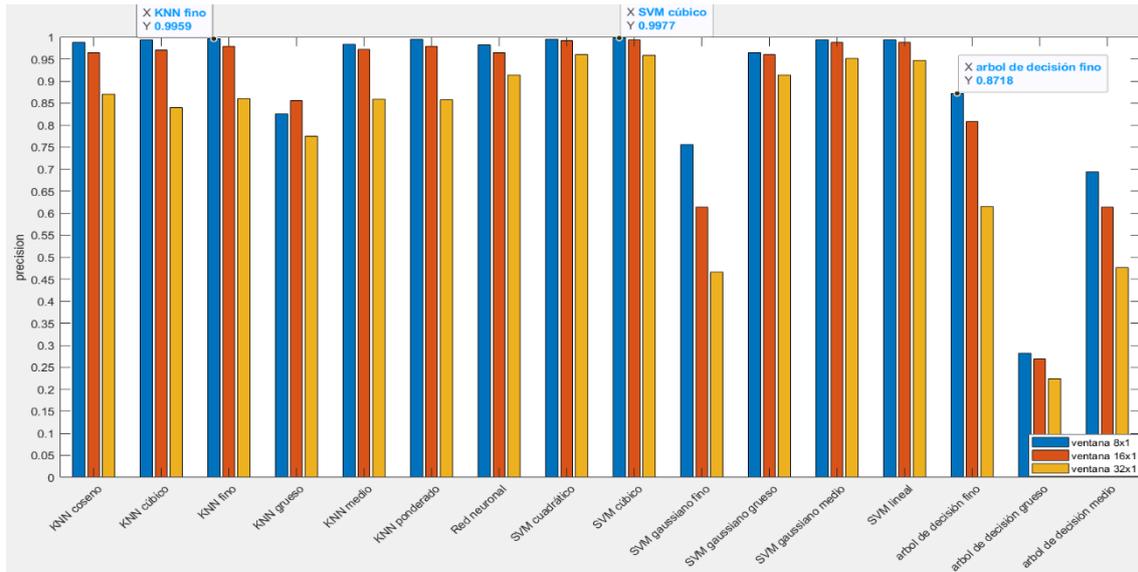
Gráfica 169. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en HSV

Ahora analizaremos la gráfica 169 para ventanas cuadradas el uso de LBP variante a rotación con radio 5 en HSV, el valor más alto está localizado en la ventana 2x2 del clasificador K-NN ponderado. Hay que mencionar, que este valor máximo es muy cercano al valor ofrecido por otros clasificadores usando una ventana de 2x2.



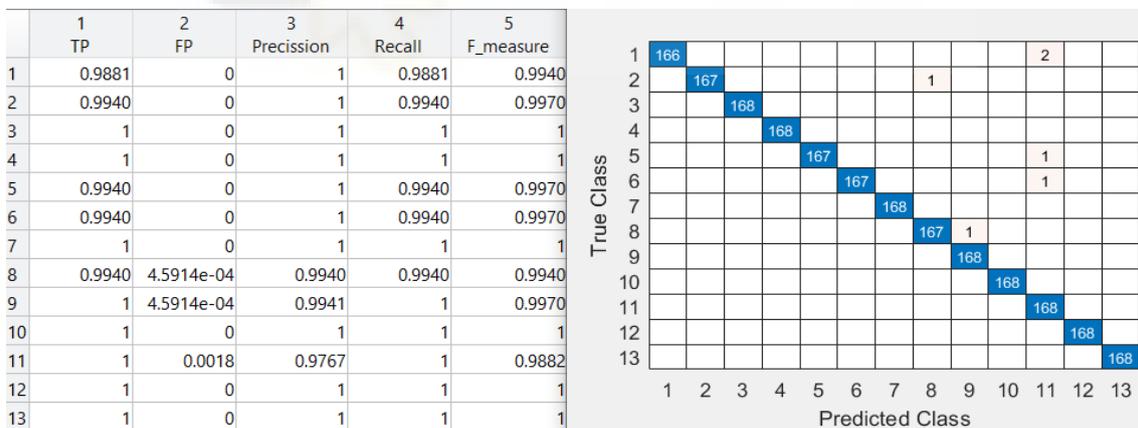
Gráfica 170. Validación del modelo elegido de la gráfica 169

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en HSV para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 170.



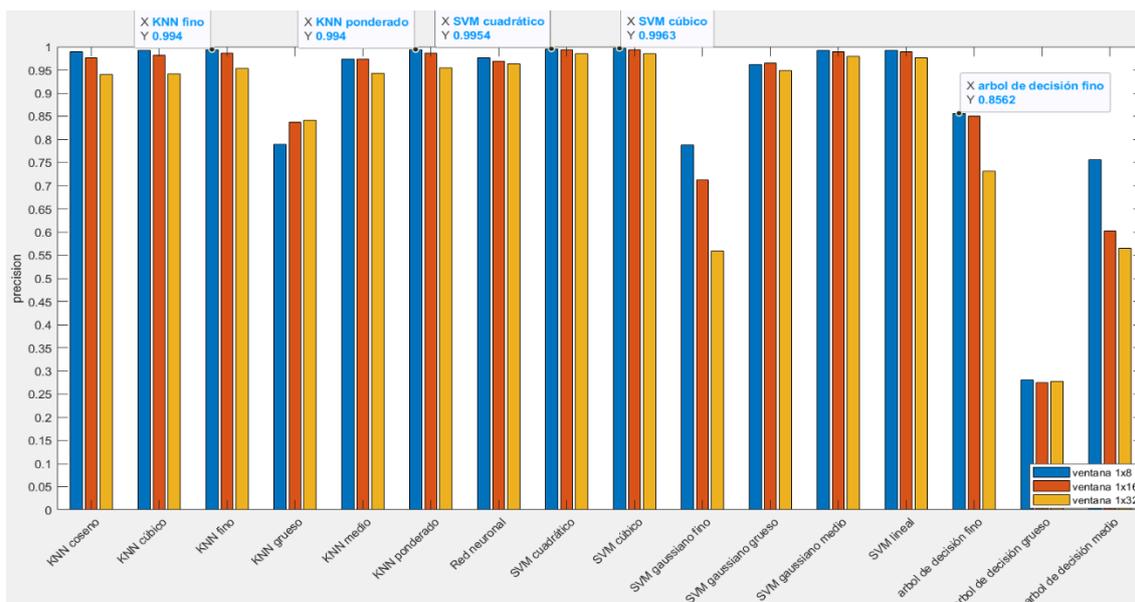
Gráfica 171. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en HSV

En la gráfica 171 el mejor clasificador, usando LBP variante a rotación con radio 5 en HSV con ventanas en fila, es el SVM cúbico para ventanas de 8x1. También, podemos ver como a medida que se disminuye el tamaño de la ventana también disminuye la precisión del clasificador.



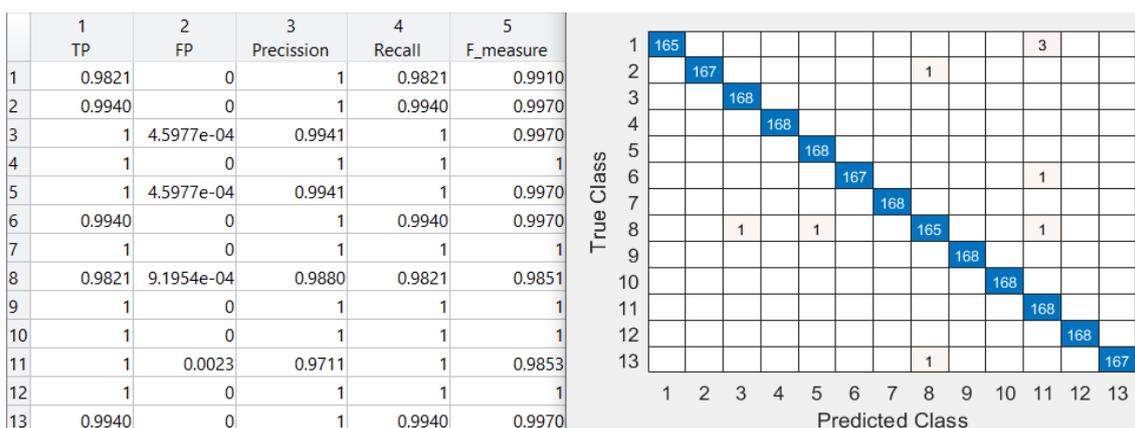
Gráfica 172. Validación del modelo elegido de la gráfica 171

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en HSV para ventanas en filas de la gráfica 172.



Gráfica 173. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en HSV

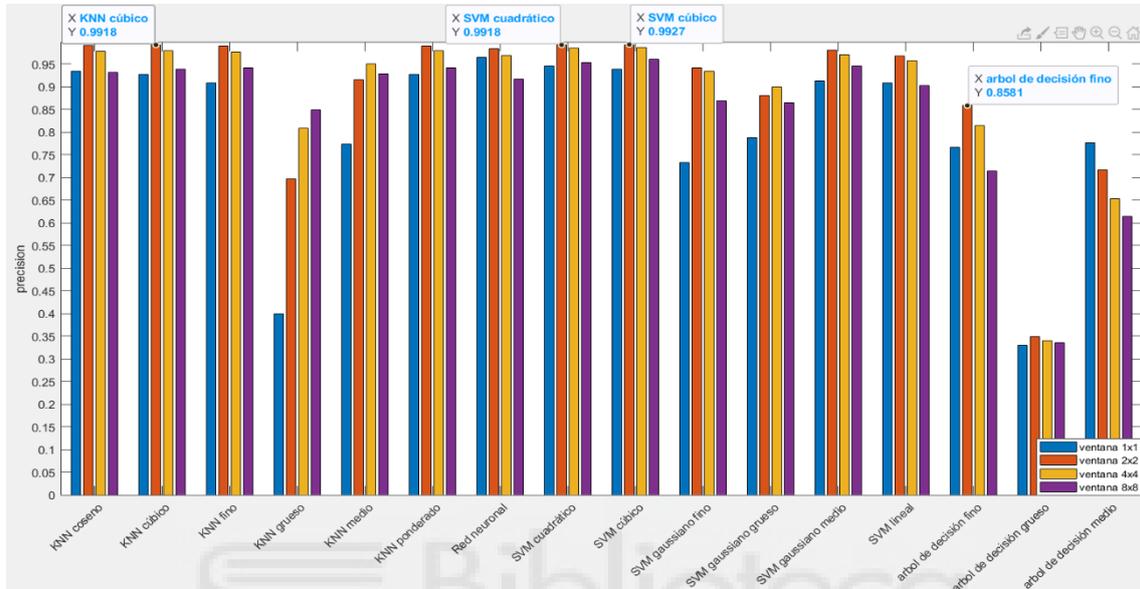
Terminando de analizar el LBP variante a rotación con radio 5 en HSV, vemos en la gráfica 173 que, en general, para ventanas en columnas los clasificadores se comportan mejor para el tamaño de 1x8 y conforme este tamaño disminuye, el resultado empeora. El mejor resultado lo encontramos en el clasificador SVM cúbico para la ventana de 1x8.



Gráfica 174. Validación del modelo elegido de la gráfica 173

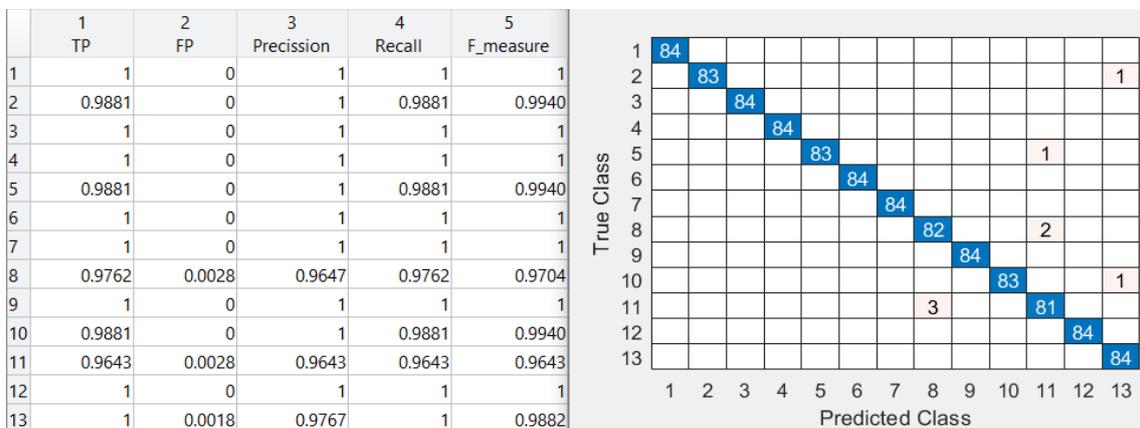
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en HSV para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 174.

Viendo el comportamiento de los clasificadores usando LBP variante a rotación con radio 5 en HSV, que el clasificador SVM cúbico es el que por lo general mejor se comporta, y, específicamente, para la ventana de 8x1 es el resultado más alto.



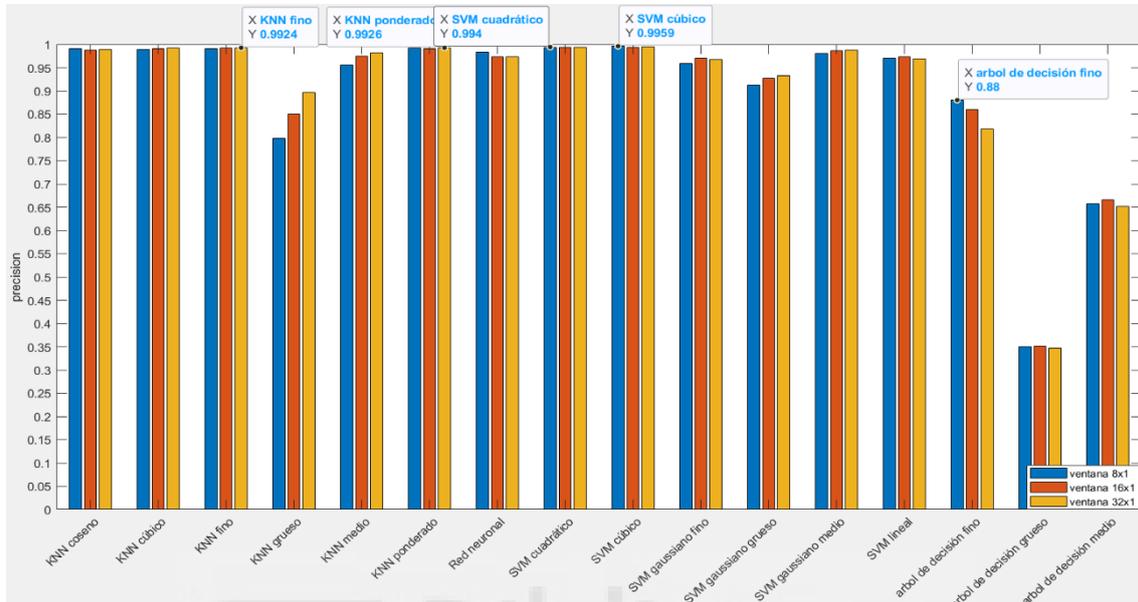
Gráfica 175. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en HSV

Ahora, usando LBP invariante a rotación con radio 1 en HSV, vemos en la gráfica 175 que la mayoría los clasificadores adquieren una mayor precisión cuando se usa la ventana de 2x2, siendo el SVM cúbico el que mayor precisión alcanza, seguido muy de cerca del SVM cuadrático para una ventana de 2x2.



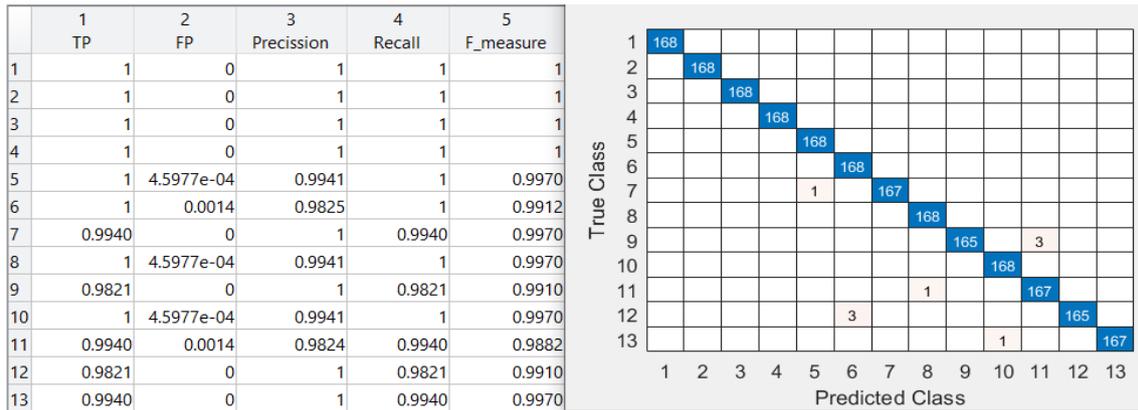
Gráfica 176. Validación del modelo elegido de la gráfica 175

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en HSV para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 176.



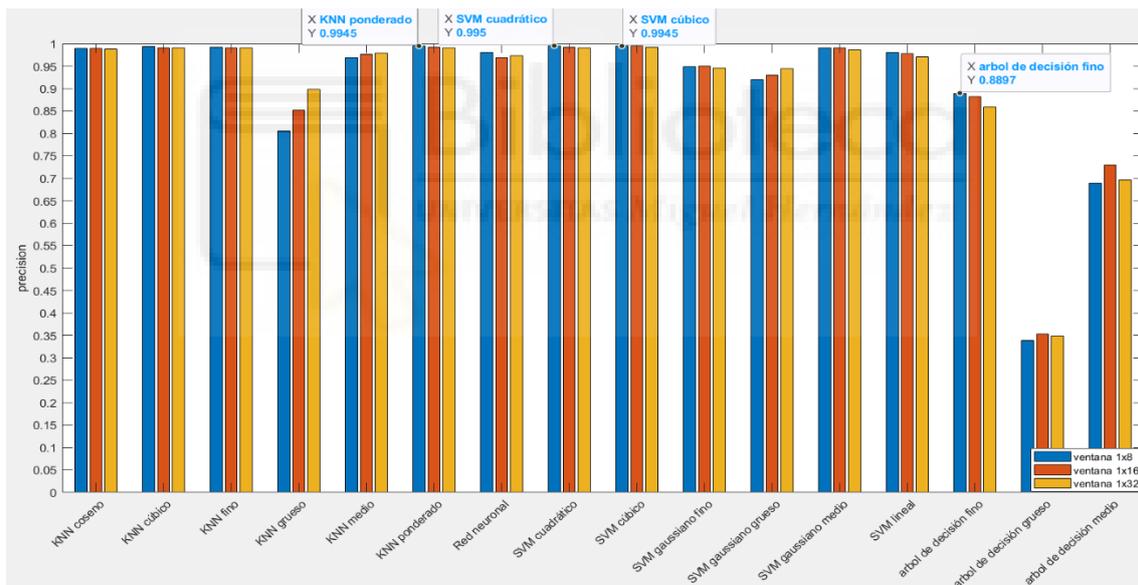
Gráfica 177. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en HSV

En muchos clasificadores vemos en la gráfica 177 que los valores en cada ventana son muy parecidos entre sí. Por eso, el clasificador que, usando LBP invariante a rotación con radio 1 en HSV, tiene la mayor precisión dista muy poco del mismo clasificador, pero para otra ventana. El SVM cúbico para ventana de 8x1 es el de mayor precisión y, seguido muy de cerca, por los valores de otros clasificadores.



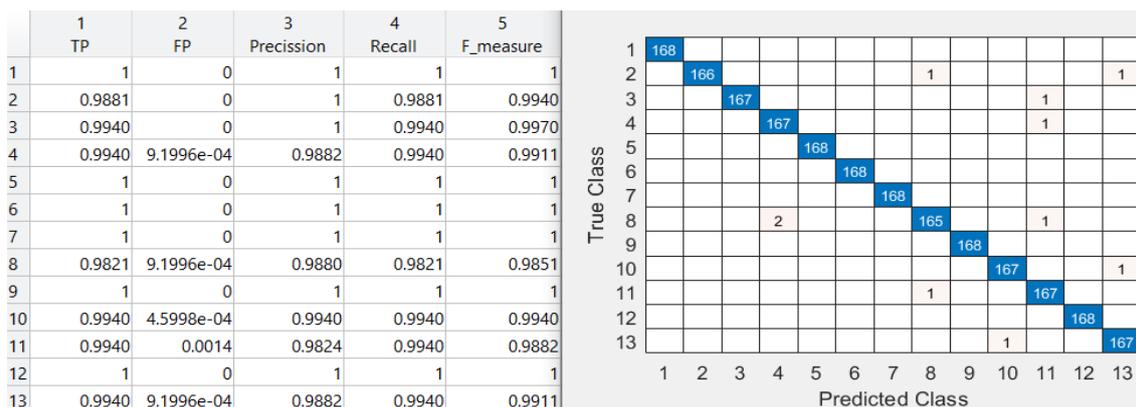
Gráfica 178. Validación del modelo elegido de la gráfica 177

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en HSV para ventanas en filas de la gráfica 178.



Gráfica 179. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en HSV

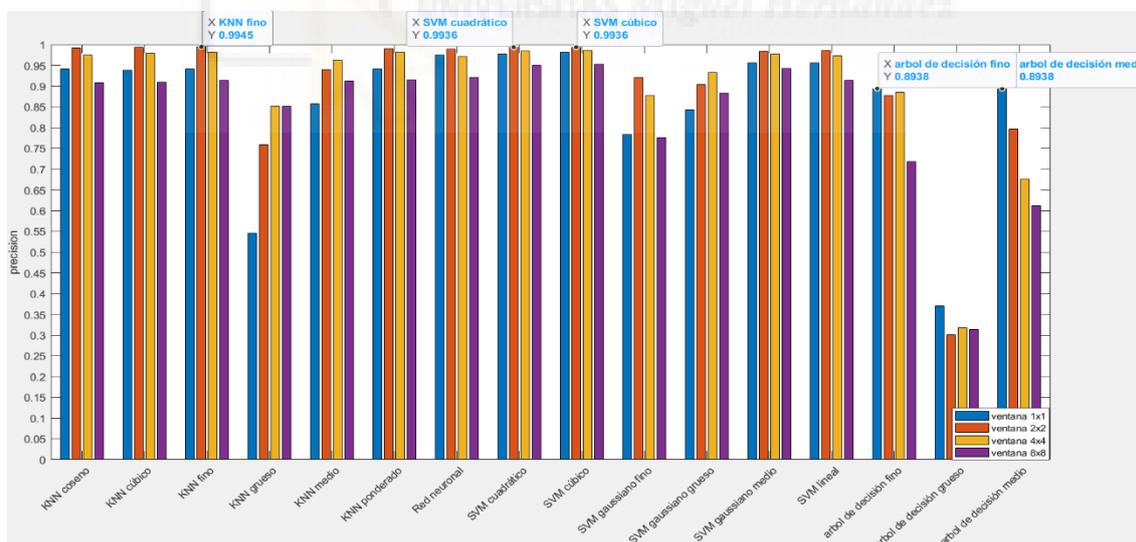
Generalmente en la gráfica 179, los clasificadores tienen unos valores semejantes para los distintos tipos de ventana. Por ello, usando LBP invariante a rotación con radio 1 en HSV, el clasificador SVM cuadrático con ventana de 1x8 es el que mejor resultado proporciona, pero dista muy poco del SVM cúbico con ventana de 1x8.



Gráfica 180. Validación del modelo elegido de la gráfica 179

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en HSV para ventanas en columnas, es del clasificador SVM cuadrático de la gráfica 180.

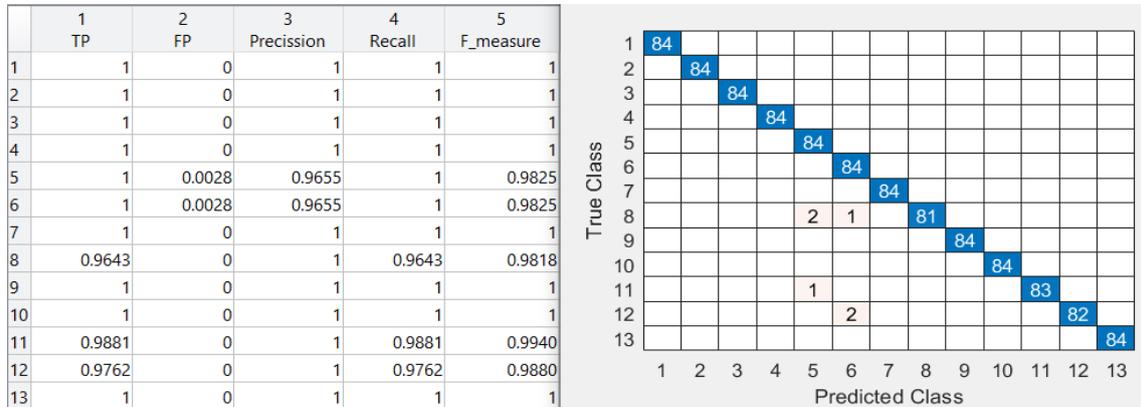
Una vez vistas las tres graficas (gráfica 175, 177 y 179) usando LBP invariante a rotación con radio 1 en HSV el clasificador SVM cúbico para ventanas de 8x1 es el que mejor resultado nos ofrece.



Gráfica 181. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en HSV

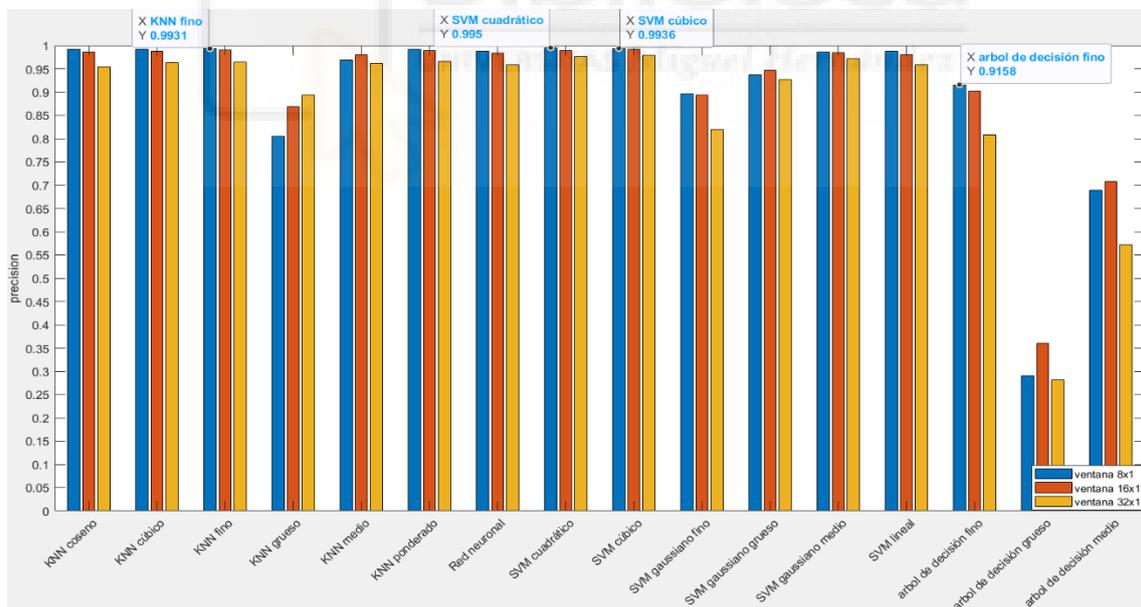
Con LBP invariante a rotación con radio 3 en HSV, el clasificador K-NN fino alcanza la más alta precisión de toda la gráfica para la ventana de 2x2.

Generalmente en la gráfica 181, es en esta ventana en la que la mayoría de los clasificadores tienen mejores resultados, menos para los árboles de decisión.



Gráfica 182. Validación del modelo elegido de la gráfica 181

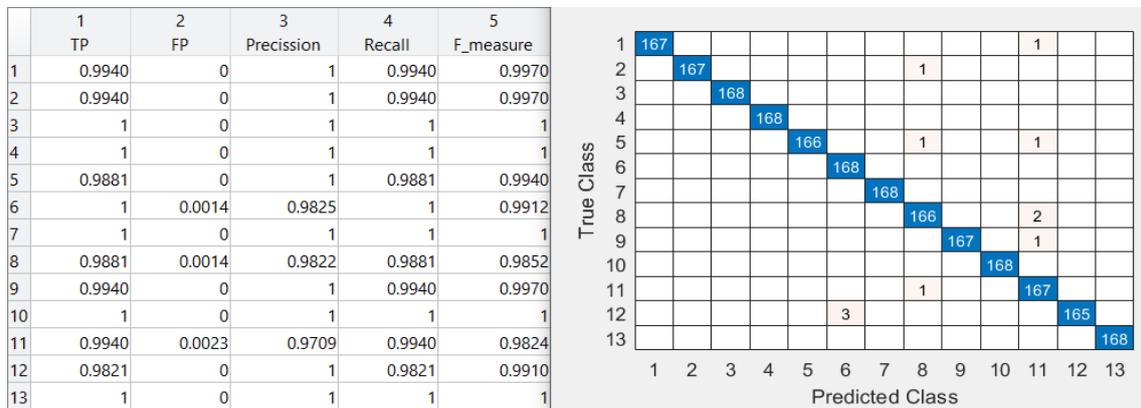
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en HSV para ventanas cuadradas, es del clasificador K-NN fino de la gráfica 182.



Gráfica 183. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en HSV

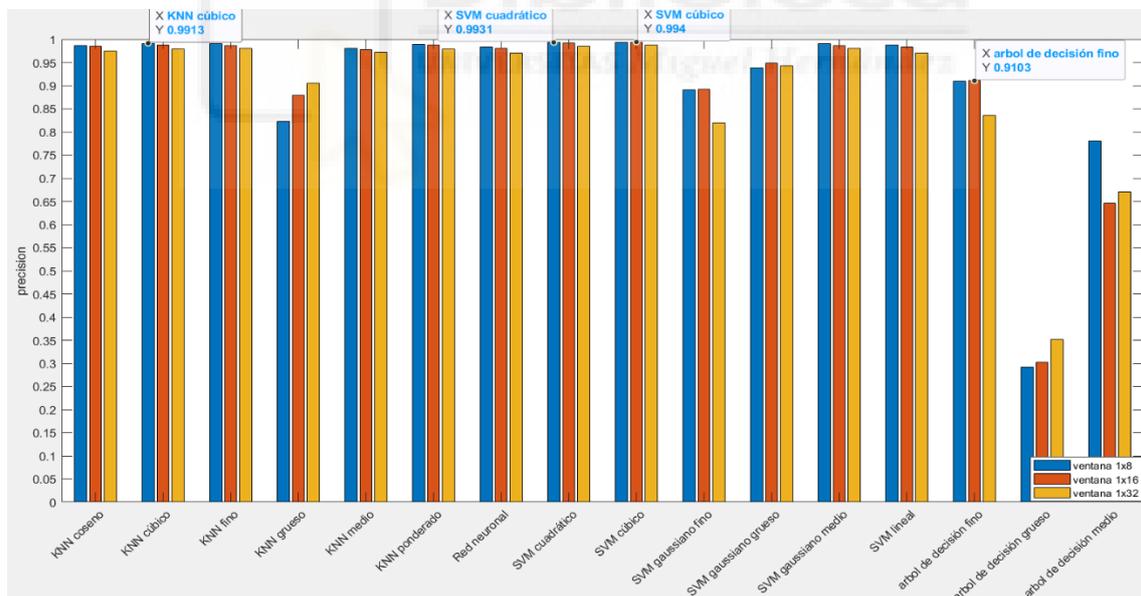
Podemos observar en la gráfica 183 que los mejores resultados, de la mayoría de los clasificadores, aparece cuando usamos ventanas de 8x1 y, a medida que este tamaño decrece, también lo hace la precisión. El mejor resultado viene por

el clasificador SVM cuadrático para ventana de 8x1, sin embargo, el SVM cúbico para ventana de 8x1 tiene un valor también muy elevado y cercano al anterior.



Gráfica 184. Validación del modelo elegido de la gráfica 183

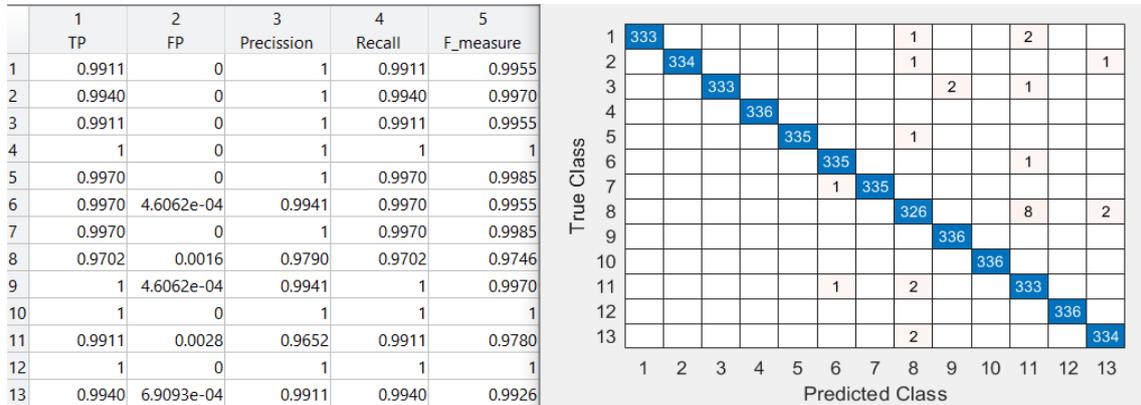
Sacamos del clasificador SVM cuadrático esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en HSV para ventanas en filas de la gráfica 184.



Gráfica 185. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en HSV

En la gráfica 185 para LBP invariante a rotación con radio 3 en HSV, la ventana de 1x8 es la que provoca, generalmente, los mejores resultados de muchos clasificadores y, conforme la ventana se hace más pequeña, la precisión

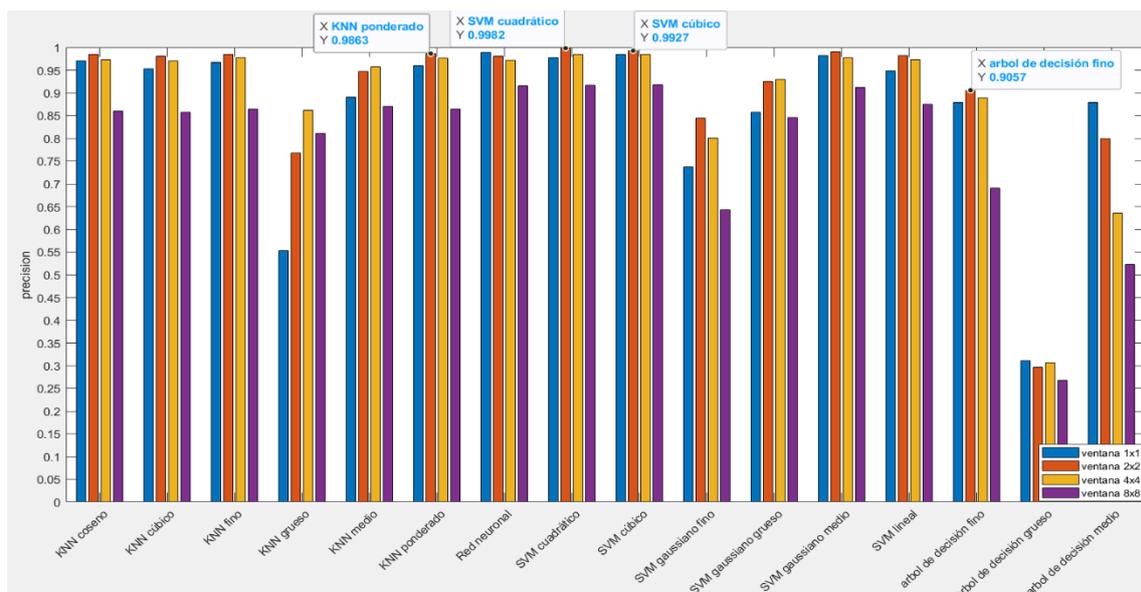
disminuye. El que mejor resultado ofrece en este caso es el SVM cúbico con ventana de 1x16.



Gráfica 186. Validación del modelo elegido de la gráfica 185

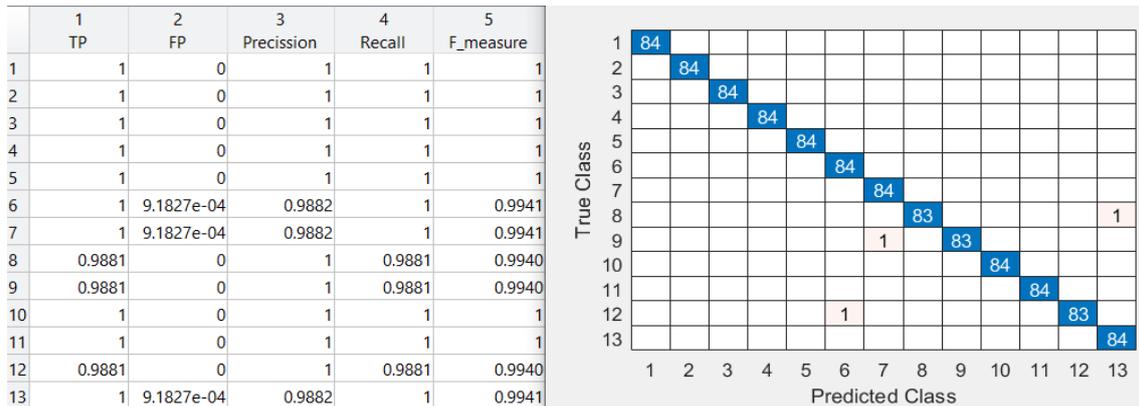
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en HSV para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 186.

Una vez visto todos los resultados usando LBP invariante a rotación con radio 3 en HSV, el clasificador SVM cuadrático es el que mejores resultados ha ofrecido en los tres casos, siendo el mayor de todos para ventana de 8x1.



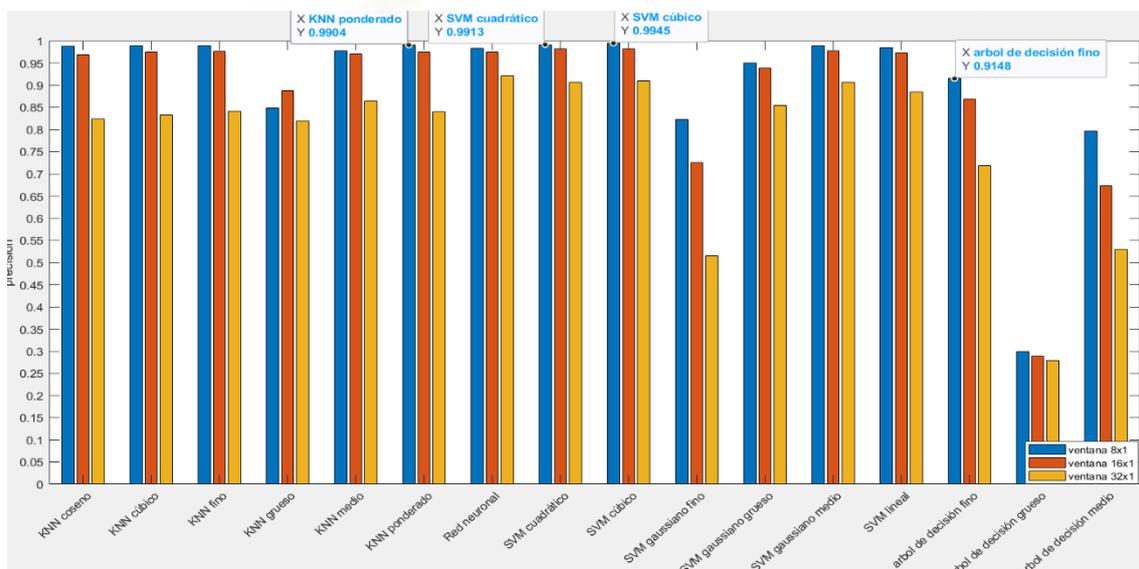
Gráfica 187. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en HSV

Continuando con LBP invariante a rotación con radio 5 en HSV, vemos en la gráfica 187 que en la mayoría de los clasificadores es la ventana de 2x2 la que ofrece los mejores resultados. El valor más alto viene por parte del clasificador SVM cuadrático con ventana de 2x2, y el siguiente es con la misma ventana el K-NN ponderado.



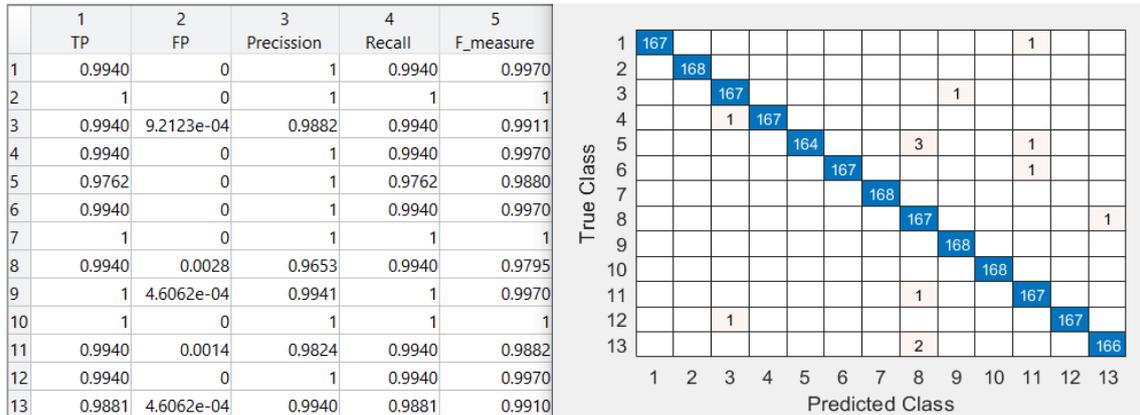
Gráfica 188. Validación del modelo elegido de la gráfica 187

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en HSV para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 188.



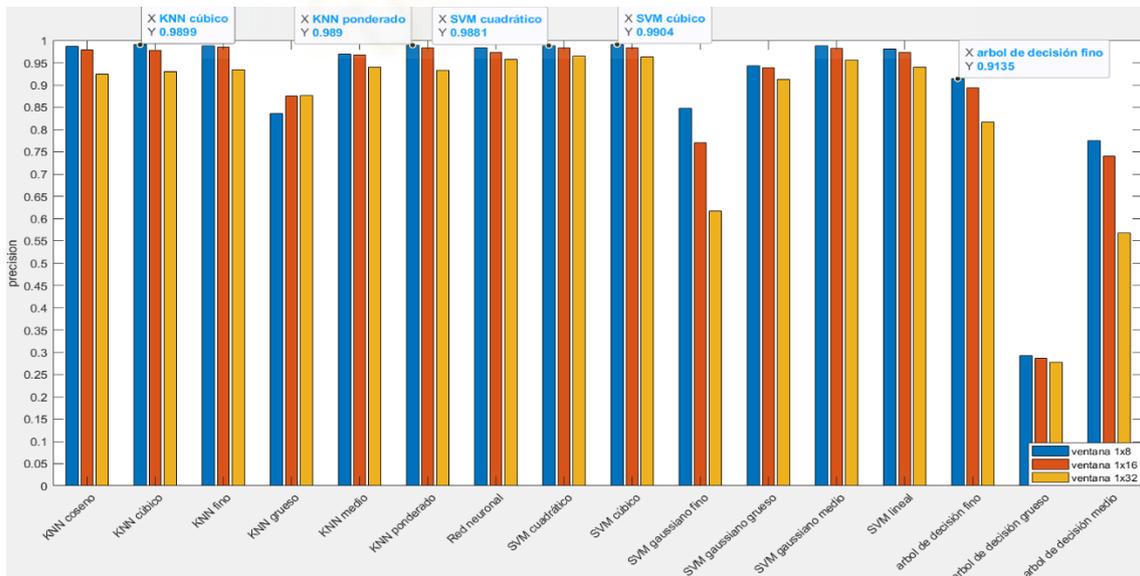
Gráfica 189. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en HSV

En la gráfica 189 la ventana de 8x1 es la que consigue el mejor resultado en la mayoría de los clasificadores usando LBP invariante a rotación con radio 5 en HSV y, si la ventana cambia su tamaño a uno menor la precisión se ve reducida. El mejor clasificador es el SVM cúbico para ventana de 8x1.



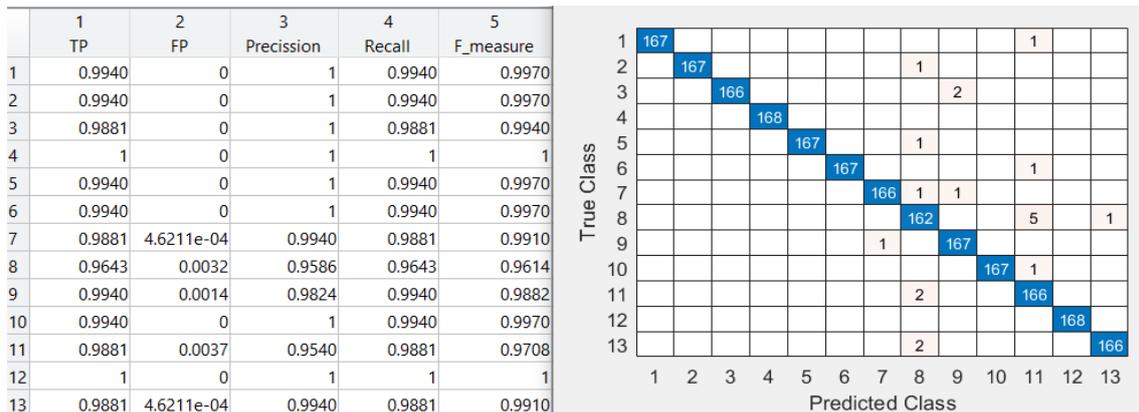
Gráfica 190. Validación del modelo elegido de la gráfica 189

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en HSV para ventanas en filas de la gráfica 190.



Gráfica 191. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en HSV

En la gráfica 191 el mejor resultado nos lo da el clasificador SVM cuadrático para ventana de 1x8 usando LBP invariante a rotación con radio 5 en HSV. Es apreciable que a medida que la ventana se hace más pequeña la precisión también se reduce en la mayoría de clasificadores y que la distancia del valor máximo obtenido con los siguientes no es muy amplia.

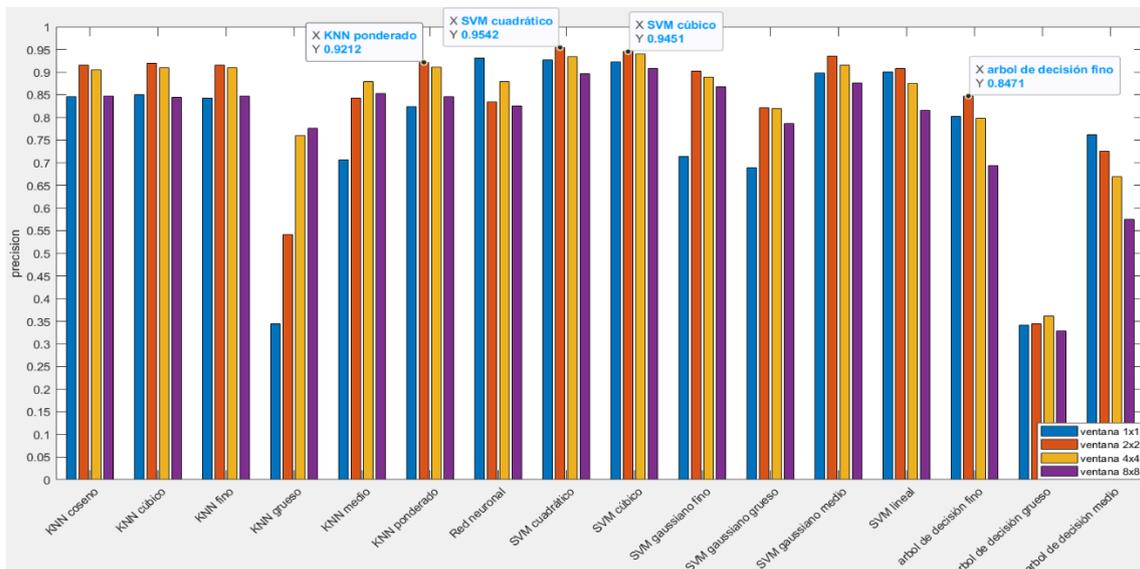


Gráfica 192. Validación del modelo elegido de la gráfica 191

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en HSV para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 192.

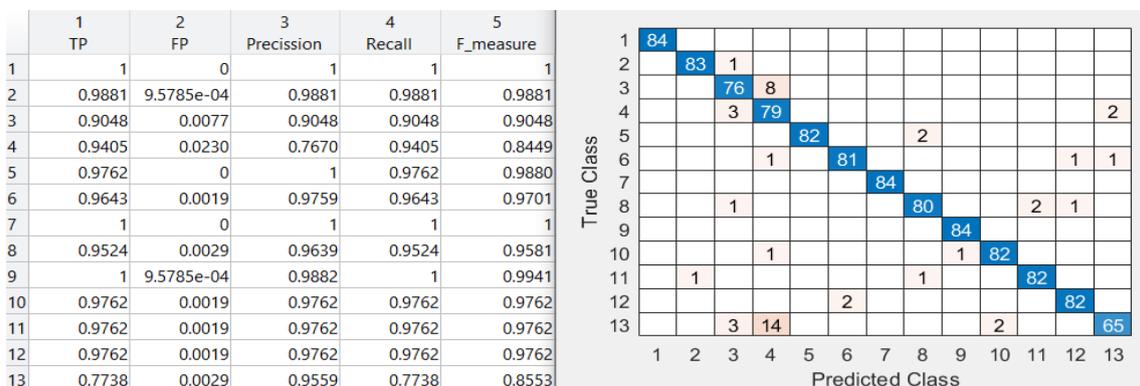
Visto los resultados anteriores, el clasificador SVM cuadrático es el que mejor se comporta usando LBP invariante a rotación con radio 5 en HSV y una ventana de 2x2.

### 4.1.5 Comparación en LAB con el segundo data set



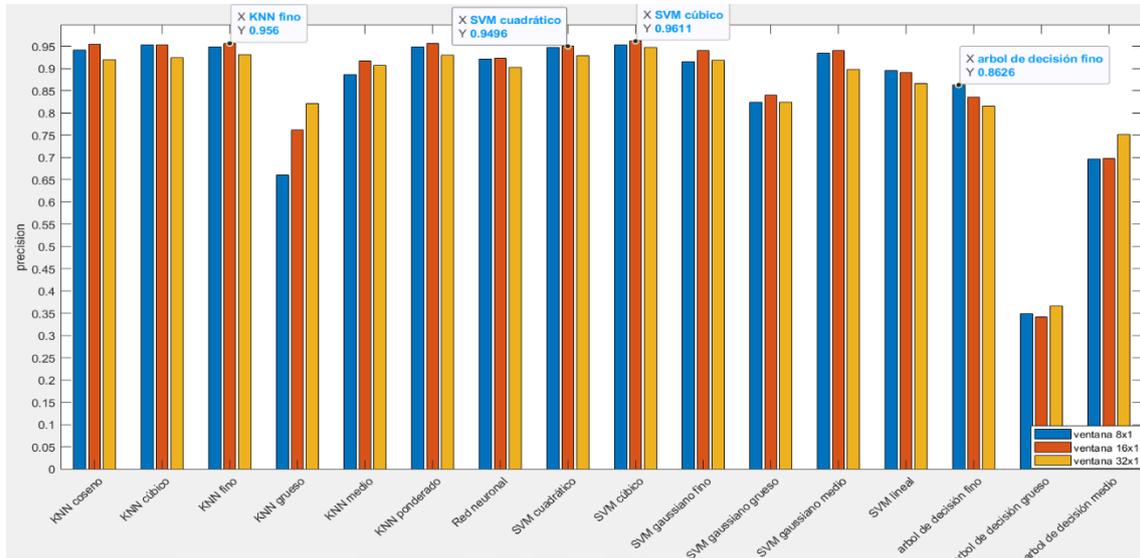
Gráfica 193. Comparación clasificadores para ventanas cuadradas para momentos de histograma en LAB

En la gráfica 193, usando los momentos de histograma en LAB para ventanas cuadradas vemos que el mejor resultado de cada clasificador suele darse para la ventana de 2x2 en la mayoría de clasificadores. También se puede observar que resultado más alto viene por parte del clasificador SVM cuadrático para ventana de 2x2. También cabe destacar que el clasificador SVM cúbico alcanza un valor elevado y cercano al anterior.



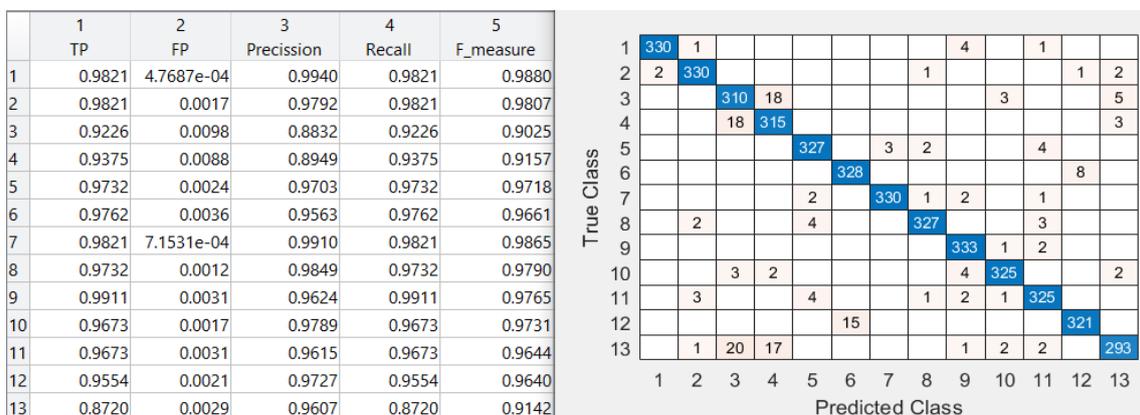
Gráfica 194. Validación del modelo elegido de la gráfica 193

Esta representación de la matriz de confusión y las tasas de acierto y error, para los momentos de histograma en LAB para ventanas cuadradas, es del clasificador SVM cuadrático de la gráfica 194.



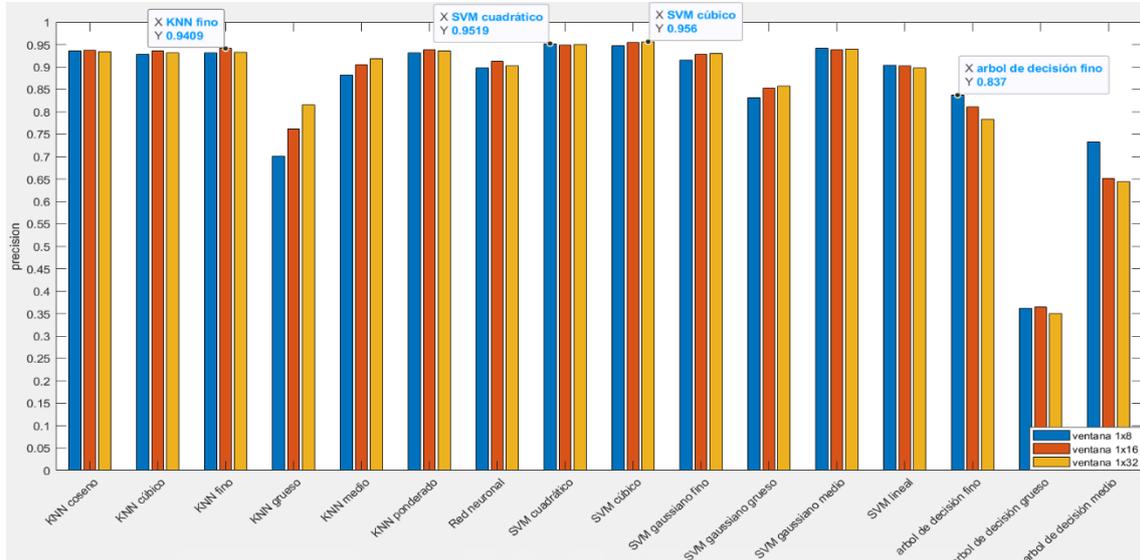
Gráfica 195. Comparación clasificadores para ventanas en filas para momentos de histograma en LAB

En la gráfica 195, siguiendo con el análisis en ventanas en filas, vemos que el clasificador SVM cúbico para ventanas de 16x1 es el que mejor precisión tiene usando momentos de histograma en LAB. También vemos que los mejores resultados de los clasificadores, generalmente, se produce en las ventanas de 16x1.



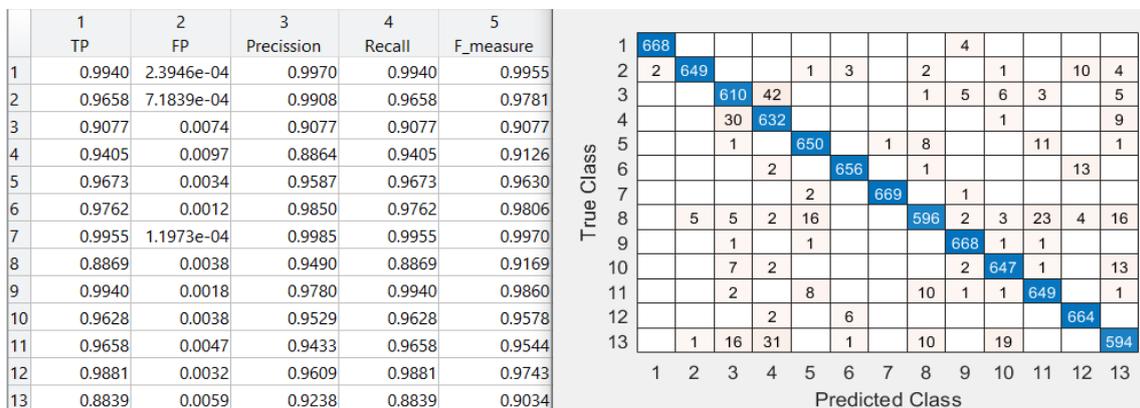
Gráfica 196. Validación del modelo elegido de la gráfica 195

Usaremos el clasificador con más precisión, el SVM cúbico, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en LAB para ventanas en fila de la gráfica 196.



Gráfica 197. Comparación clasificadores para ventanas en columnas para momentos de histograma en LAB

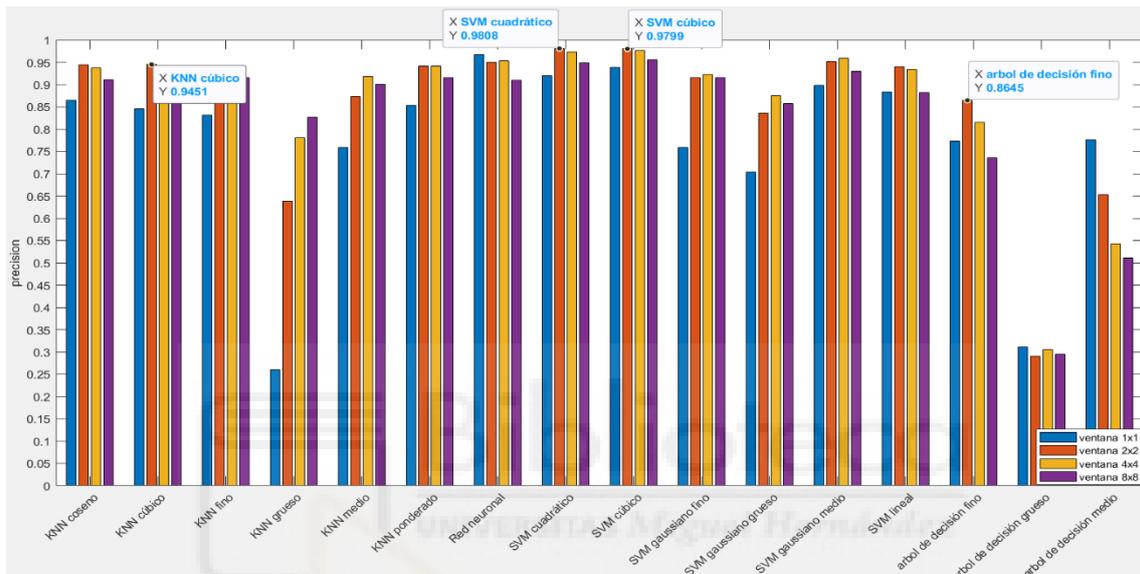
Generalmente en la gráfica 197, vemos que el clasificador que más precisión tiene, usando momentos de histograma en LAB, es el SVM cúbico para ventana de 1x32 y, el siguiente valor más alto vienen dado por el SVM cuadrático para ventana de 1x8. Que los dos resultados más altos se den para distintos tipos de ventana, refleja que no hay ninguna que sea mejor para distintos clasificadores.



Gráfica 198. Validación del modelo elegido de la gráfica 197

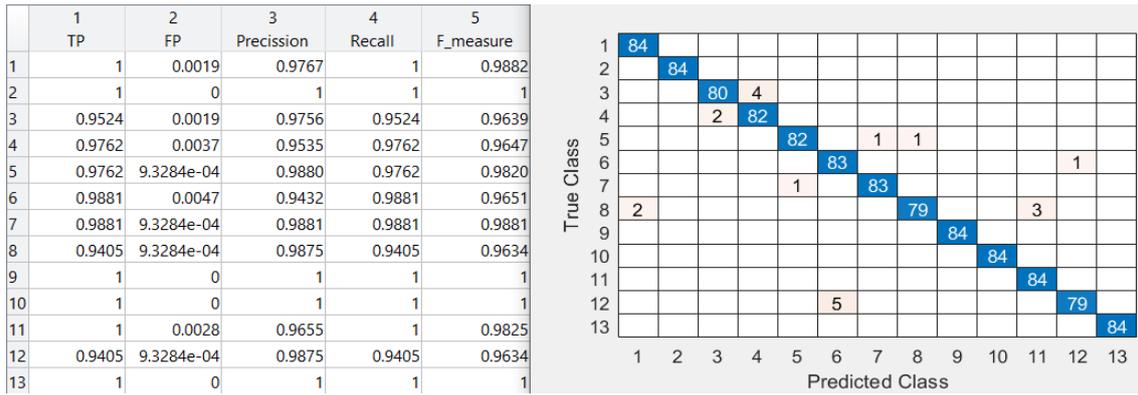
Usaremos el clasificador con más precisión, el SVM cúbico, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en LAB para ventanas en columna de la gráfica 198.

Después de ver todas las gráficas, el clasificador SVM cúbico para ventanas de 16x1 es el que mayor precisión nos da, y en general para los tres tipos de ventana es el que mejor se comporta.



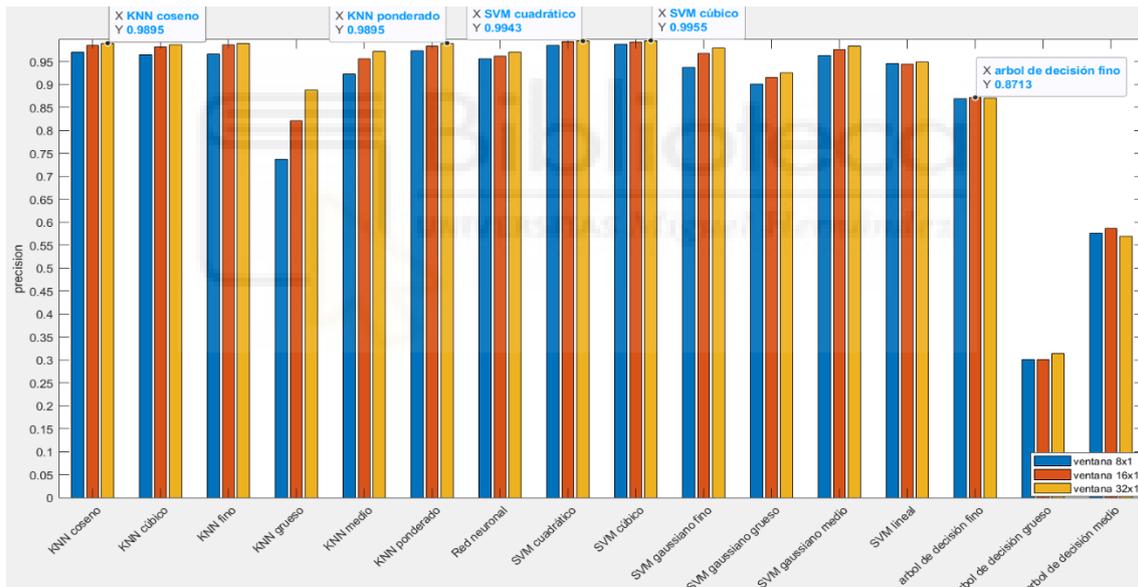
Gráfica 199. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en LAB

Generalmente en la gráfica 199, el mejor resultado varía entre ventana de 2x2 y 4x4, depende del clasificador. Entonces, usando la matriz de coocurrencia en LAB, el clasificador SVM cuadrático para la ventana de 2x2 es el que mejor resultado nos ofrece, sin embargo, cabe destacar que para el SVM cúbico usando ventanas 2x2, el valor es muy próximo al anterior.



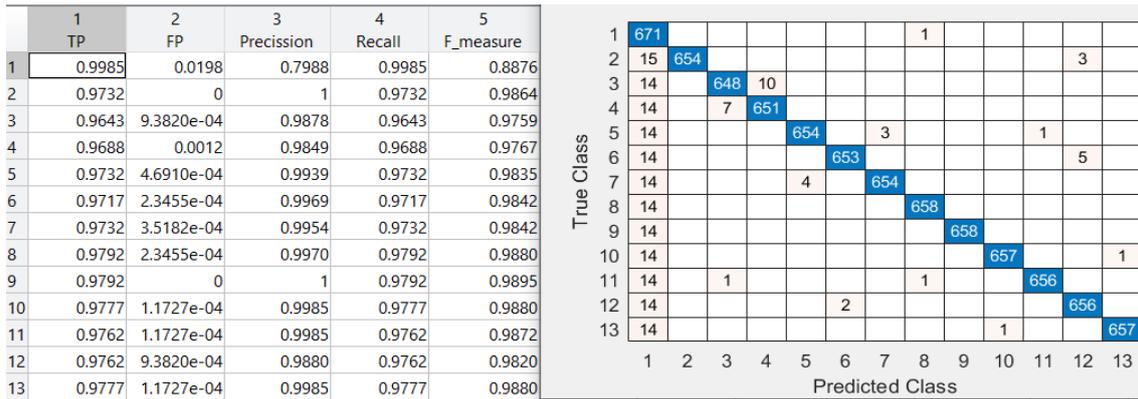
Gráfica 200. Validación del modelo elegido de la gráfica 199

Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en LAB para ventanas cuadradas, es del clasificador SVM cuadrático de la gráfica 200.



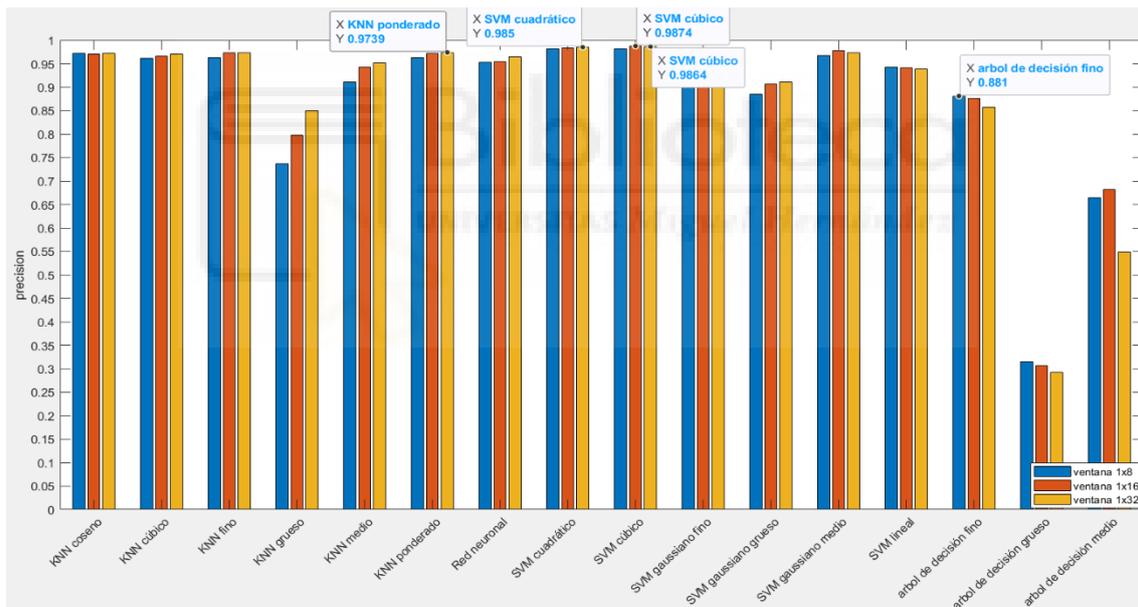
Gráfica 201. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en LAB

Vemos en la gráfica 201 que usando la matriz de coocurrencia en LAB el clasificador SVM cúbico es el que mejor se comporta cuando escogemos la ventana 32x1 y, con muy poca diferencia, el siguiente es el clasificador SVM cuadrático con la misma ventana. También se puede apreciar que los clasificadores, generalmente, ofrecen el mejor resultado para ese tipo de ventana y a medida que el tamaño de la ventana aumenta, la precisión decrece.



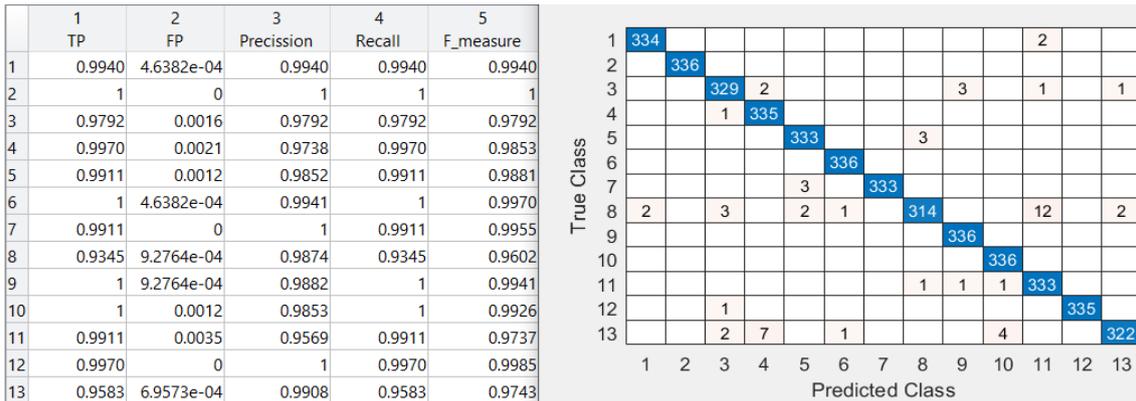
Gráfica 202. Validación del modelo elegido de la gráfica 201

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en LAB para ventanas en filas de la gráfica 202.



Gráfica 203. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en LAB

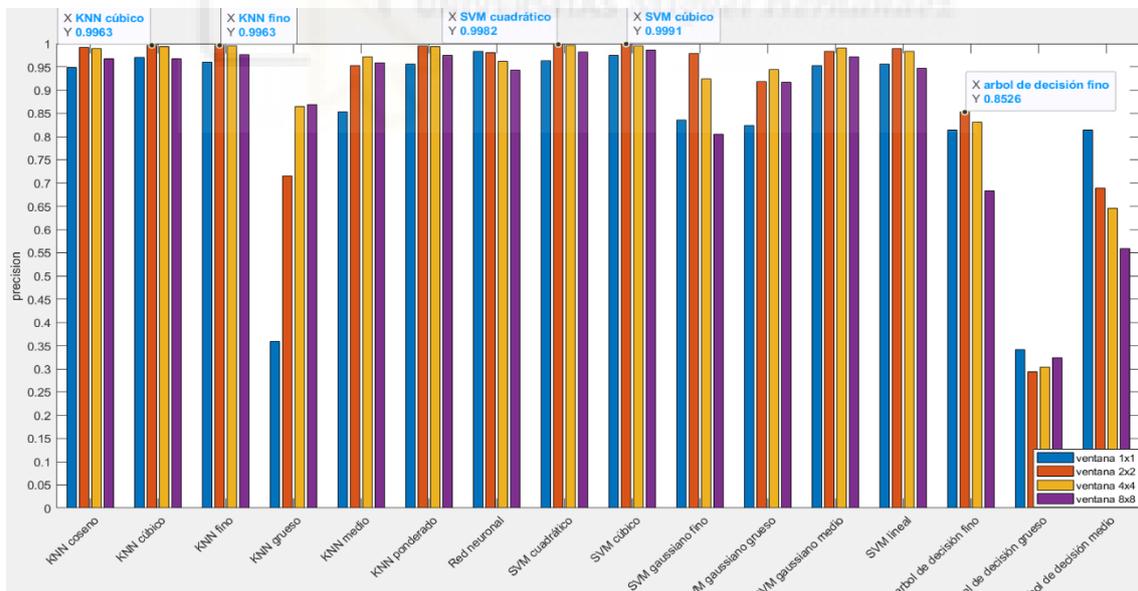
La gráfica 203 muestra el comportamiento de los clasificadores cuando usamos las ventanas en columna con la matriz de coocurrencia en LAB, vemos que el mejor resultado nos lo da el SVM cúbico para ventanas de 1x16 seguido muy de cerca por el resultado del mismo clasificador para ventanas de 1x32 y el SVM cuadrático para ventanas de 1x32.



Gráfica 204. Validación del modelo elegido de la gráfica 203

Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en LAB para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 204.

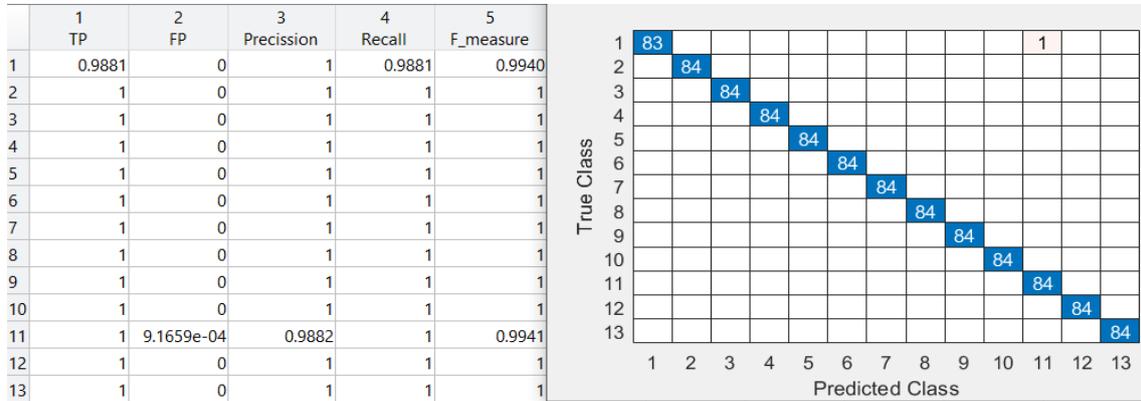
Una vez vistos los resultados anteriores, el mejor clasificador es el SVM cúbico con ventana de 32x1, cabe destacar que este clasificador se comporta muy bien, incluso, en el resto de tipos de ventanas.



Gráfica 205. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en LAB

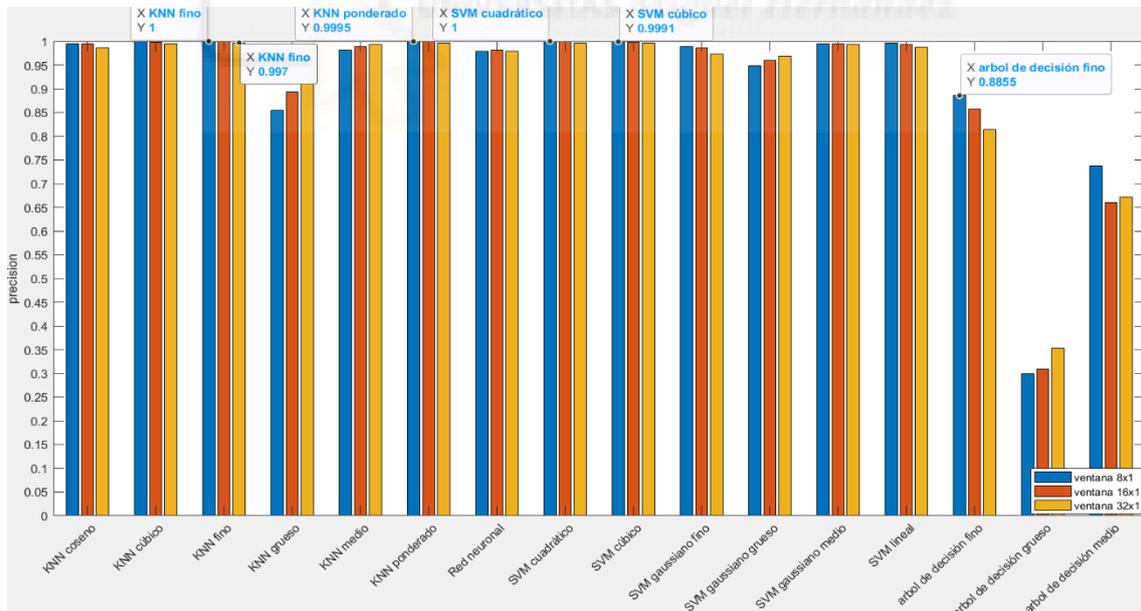
En la gráfica 205, usando LBP variante a rotación en LAB vemos que, en la mayoría de los clasificadores, los valores de las ventanas 2x2 y 4x4 son muy

similares, siendo en la ventana 2x2 en la que mayor valor alcanzan. El clasificador SVM cúbico es el que mayor precisión tiene usando la ventana de 2x2 y, para el mismo tamaño de ventana, el SVM cuadrático es el siguiente.



Gráfica 206. Validación del modelo elegido de la gráfica 205

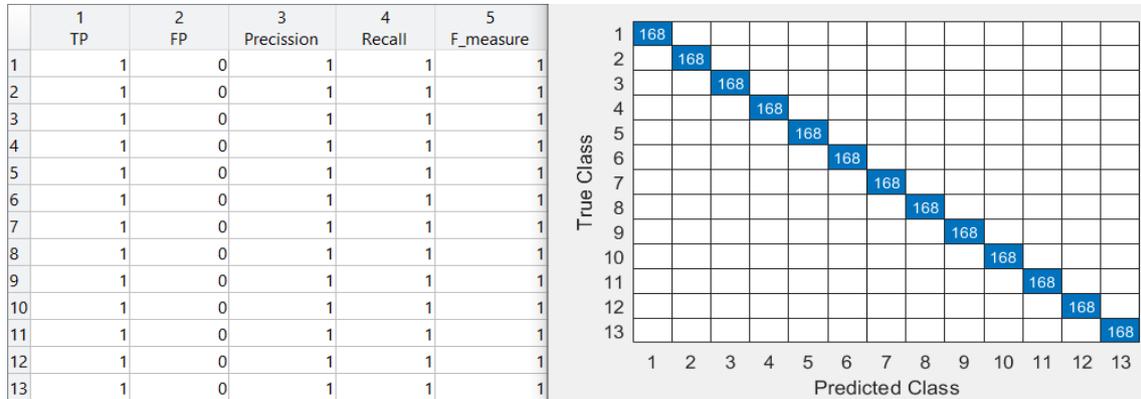
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en LAB para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 206.



Gráfica 207. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en LAB

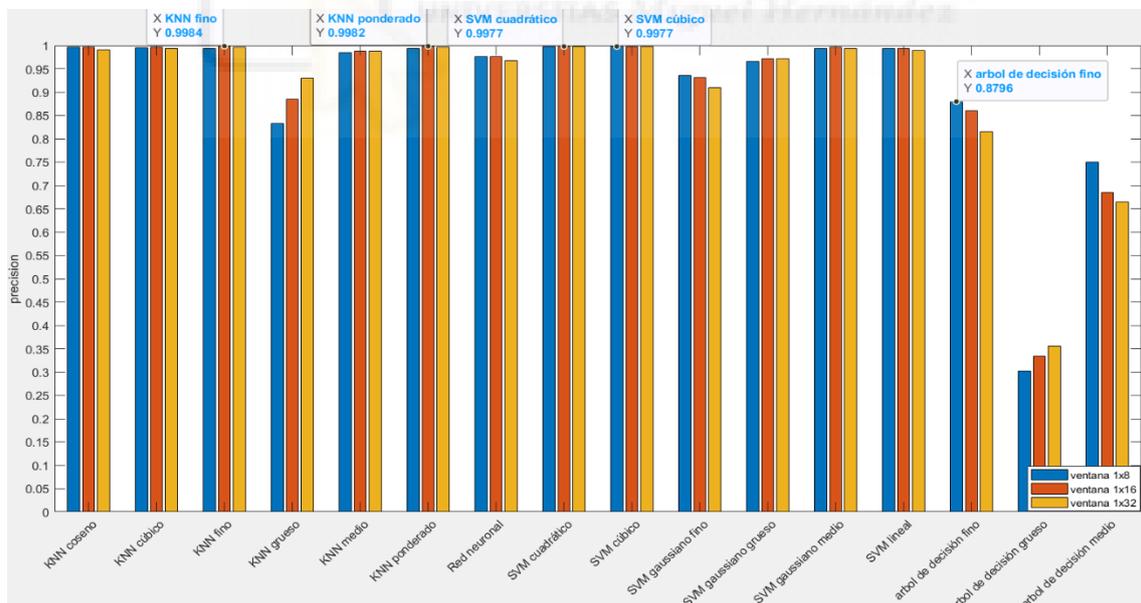
En la gráfica 207 los clasificadores no alcanzan su valor máximo en una ventana específica, va cambiando según el clasificador. Tenemos dos clasificadores, que

usando LBP variante a rotación con radio 1, alcanzan el valor más alto de la gráfica con ventana de 8x1 y, son el K-NN fino y el SVM cuadrático. En general, los resultados obtenidos son elevados en los distintos clasificadores.



Gráfica 208. Validación del modelo elegido de la gráfica 207

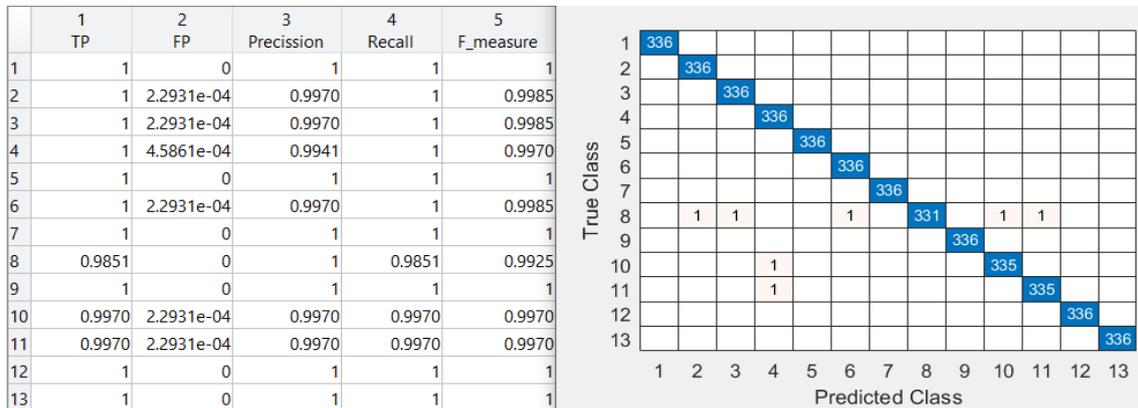
Sacamos del clasificador K-NN fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en LAB para ventanas en filas de la gráfica 208.



Gráfica 209. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en LAB

Vemos en la gráfica 209 que al analizar las ventanas en columna para LBP variante a rotación con radio 1 en LAB los valores de un mismo clasificador las

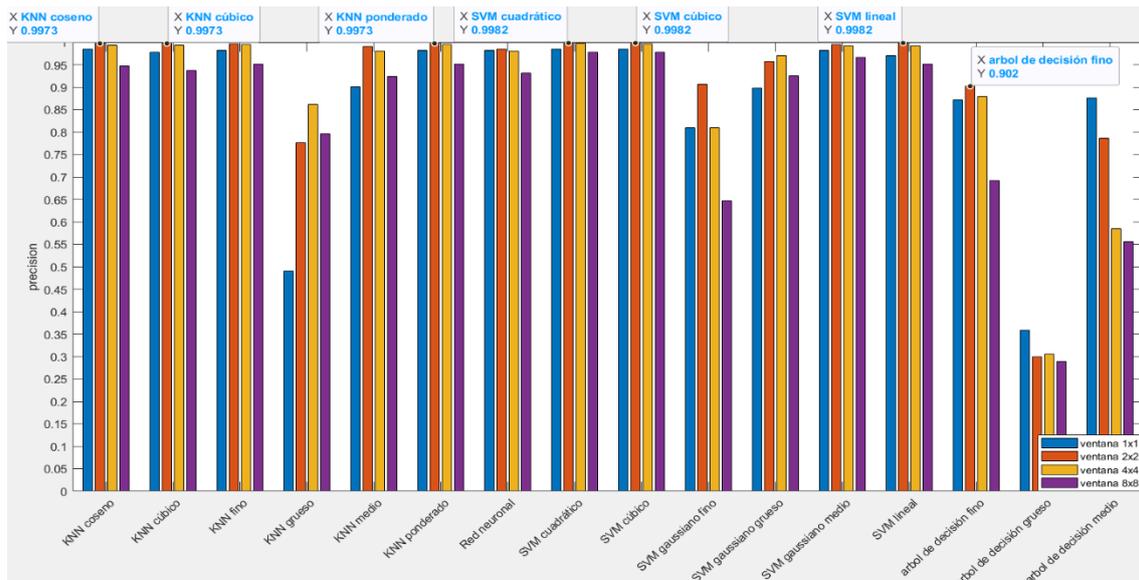
diferentes ventanas tienen valores cercanos, hay excepciones. El mejor resultado es alcanzado por el clasificador K-NN fino para ventana de 1x16. Los clasificadores K-NN ponderado, SVM cúbico y SVM cuadrático tienen valores muy cercanos al del K-NN fino.



Gráfica 210. Validación del modelo elegido de la gráfica 209

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en LAB para ventanas en columnas, es del clasificador K-NN fino de la gráfica 210.

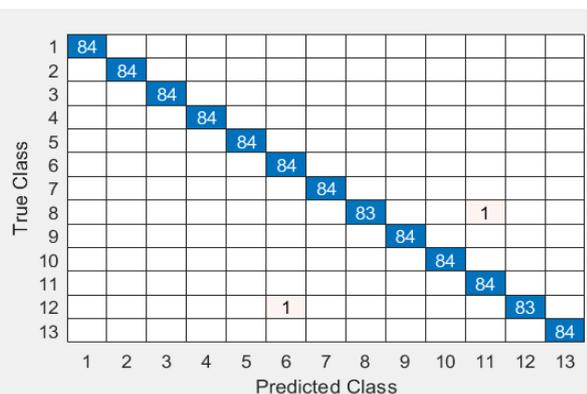
Queda claro que los clasificadores SVM cuadrático y K-NN fino son los que, independientemente de la ventana, siempre alcanza un resultado muy bueno respecto al resto de clasificadores. Siendo para la ventana 8x1 el de mayor valor para LBP variante a rotación con radio 1 en LAB.



Gráfica 211. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en LAB

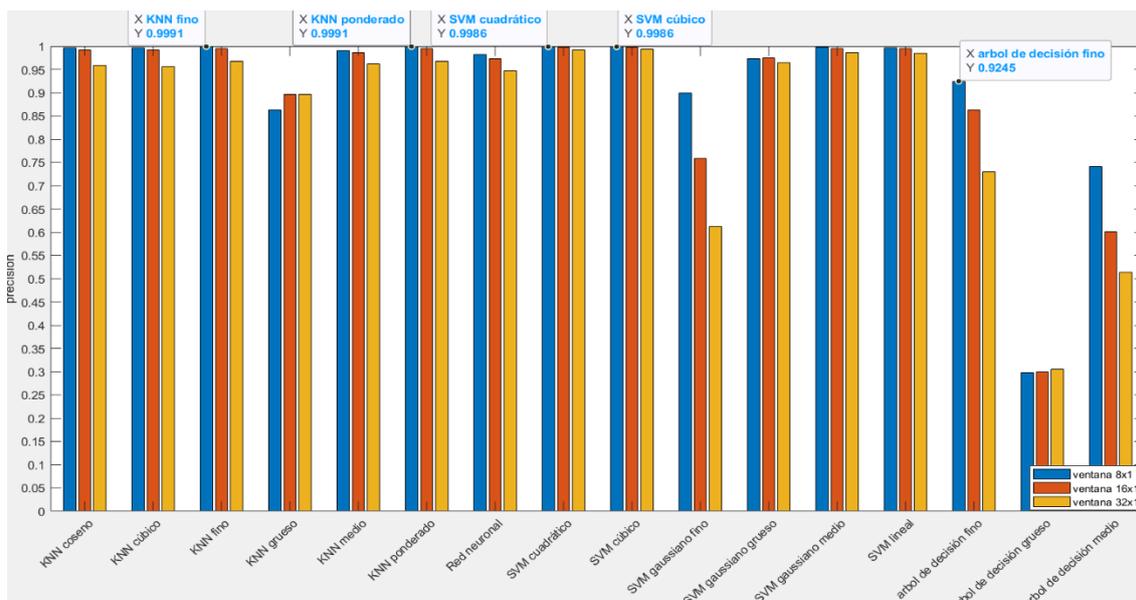
En la gráfica 211, usando LBP variante a rotación con radio 3 en LAB los valores más altos en general se encuentran cuando usamos ventanas de 2x2, siendo esta ventana las que logran la mayor precisión con los clasificadores SVM cuadrático, SVM lineal y SVM cúbico, el siguiente valor viene de los K-NN coseno, ponderado y cúbico con una ventana de 2x2.

	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	1	0	1	1	1
2	1	0	1	1	1
3	1	0	1	1	1
4	1	0	1	1	1
5	1	0	1	1	1
6	1	9.1743e-04	0.9882	1	0.9941
7	1	0	1	1	1
8	0.9881	0	1	0.9881	0.9940
9	1	0	1	1	1
10	1	0	1	1	1
11	1	9.1743e-04	0.9882	1	0.9941
12	0.9881	0	1	0.9881	0.9940
13	1	0	1	1	1



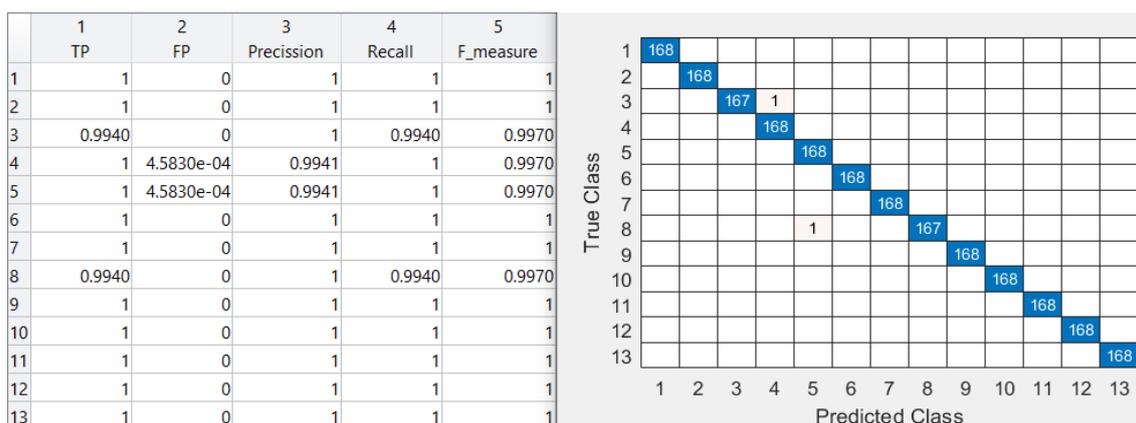
Gráfica 212. Validación del modelo elegido de la gráfica 211

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en LAB para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 212.



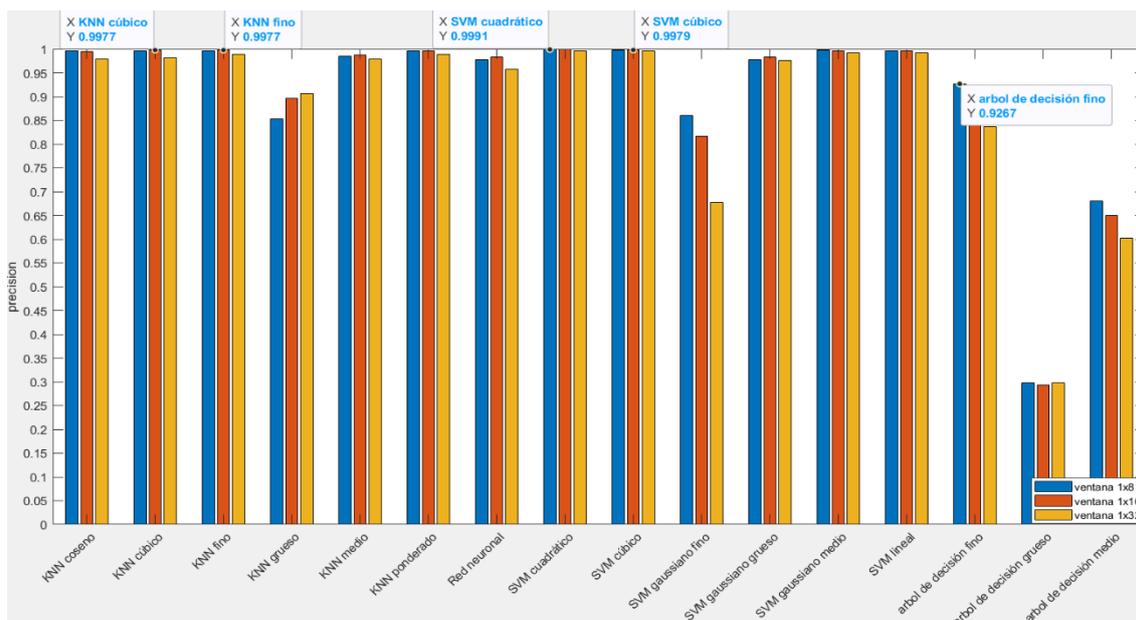
Gráfica 213. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en LAB

Analizando las ventanas en filas para LBP variante a rotación con radio 3 en LAB, vemos en la gráfica 213 que la gran mayoría de los clasificadores estudiados alcanzan su valor más alto para las ventanas de 8x1, siendo el clasificador K-NN ponderado y K-NN fino son los que alcanza el valor más alto. Cabe destacar que algunos valores de otros clasificadores, SVM cúbico y SVM cuadrático, están muy cerca del valor anterior.



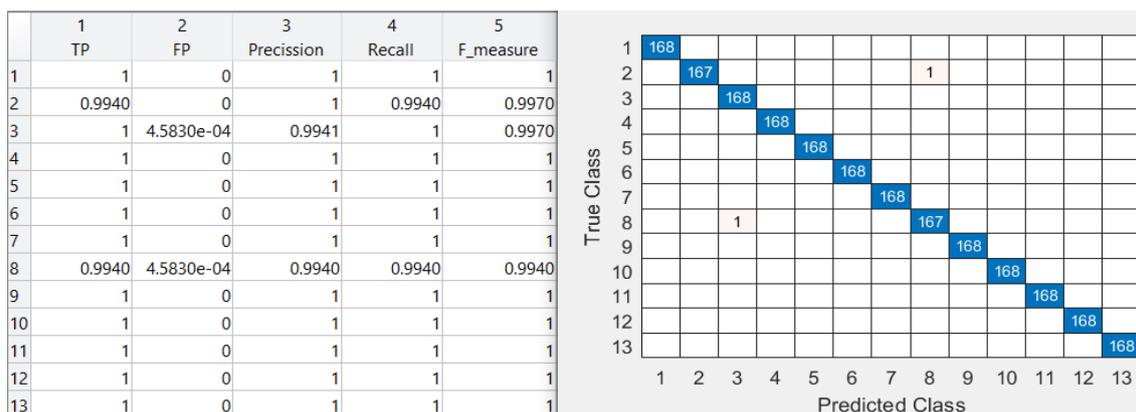
Gráfica 214. Validación del modelo elegido de la gráfica 213

Sacamos del clasificador K-NN fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en LAB para ventanas en filas de la gráfica 214.



Gráfica 215. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en LAB

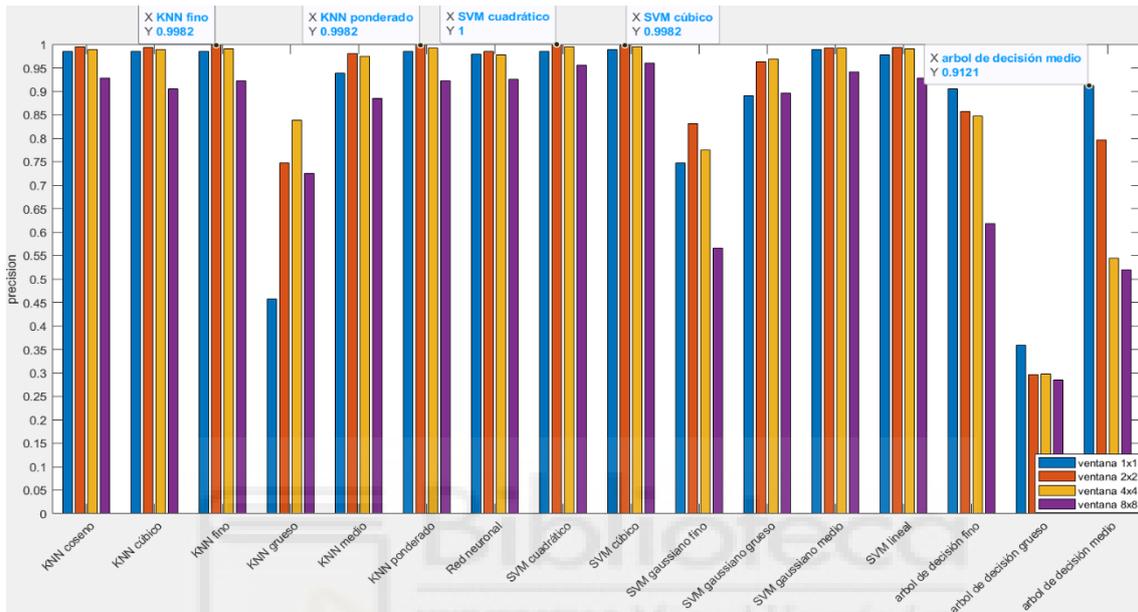
Podemos observar en la gráfica 215 que los resultados para los diferentes tamaños de ventana, usando LBP variante a rotación con radio 3 en LAB, son muy cercanos en la mayoría de clasificadores. Para la ventana de 1x8 el clasificador SVM cuadrático es el que mayor valor alcanza, seguido de cerca por el SVM cúbico, KNN- fino y K-NN ponderado con ventana de 1x16.



Gráfica 216. Validación del modelo elegido de la gráfica 215

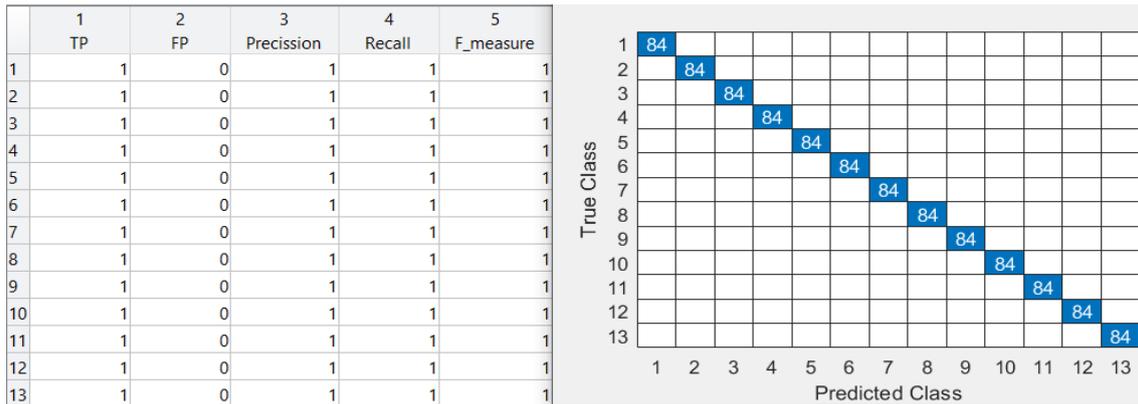
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en LAB para ventanas en columnas, es del clasificador SVM cuadrático de la gráfica 216.

Hemos comprobado que para LBP variante a rotación con radio 3 en LAB tenemos un triple empate en cuanto al mejor clasificador, los tres aparte de alcanzar el valor más elevado en alguna ocasión, también se comportan bien en el resto de tipos de ventana. Estos clasificadores son K-NN fino con ventana 8x1, K-NN ponderado con ventana 8x1 y SVM cuadrático con ventana 1x8.



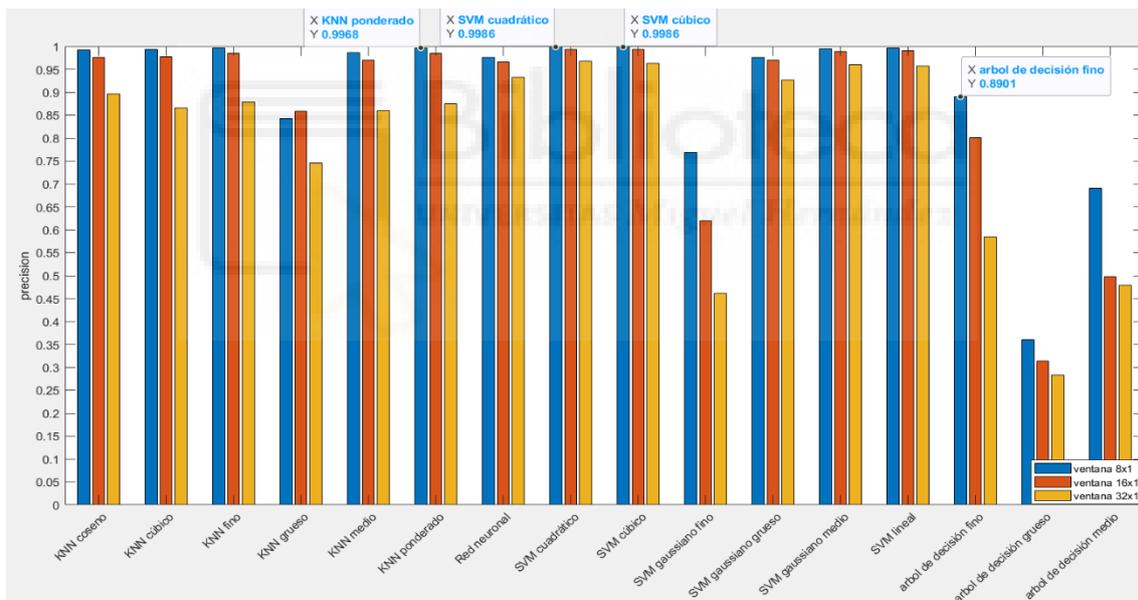
Gráfica 217. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en LAB

Ahora analizaremos en la gráfica 217 para ventanas cuadradas el uso de LBP variante a rotación con radio 5 en LAB, el valor más alto está localizado en la ventana 2x2 del clasificador SVM cuadrático. Hay que mencionar, que este valor máximo es muy cercano al valor ofrecido por otros clasificadores usando una ventana de 2x2, ya que en esta ventana se suelen encontrar los valores más altos de los distintos clasificadores.



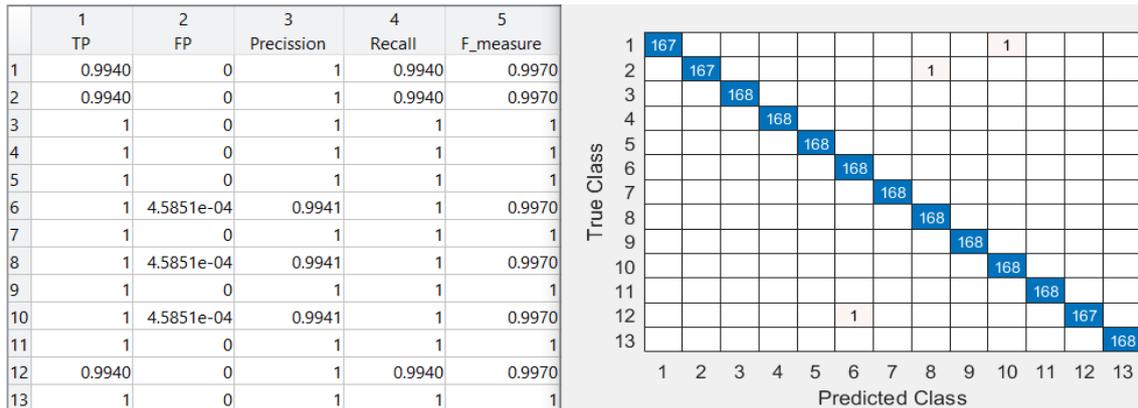
Gráfica 218. Validación del modelo elegido de la gráfica 217

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en LAB para ventanas cuadradas, es del clasificador SVM cuadrático de la gráfica 218.



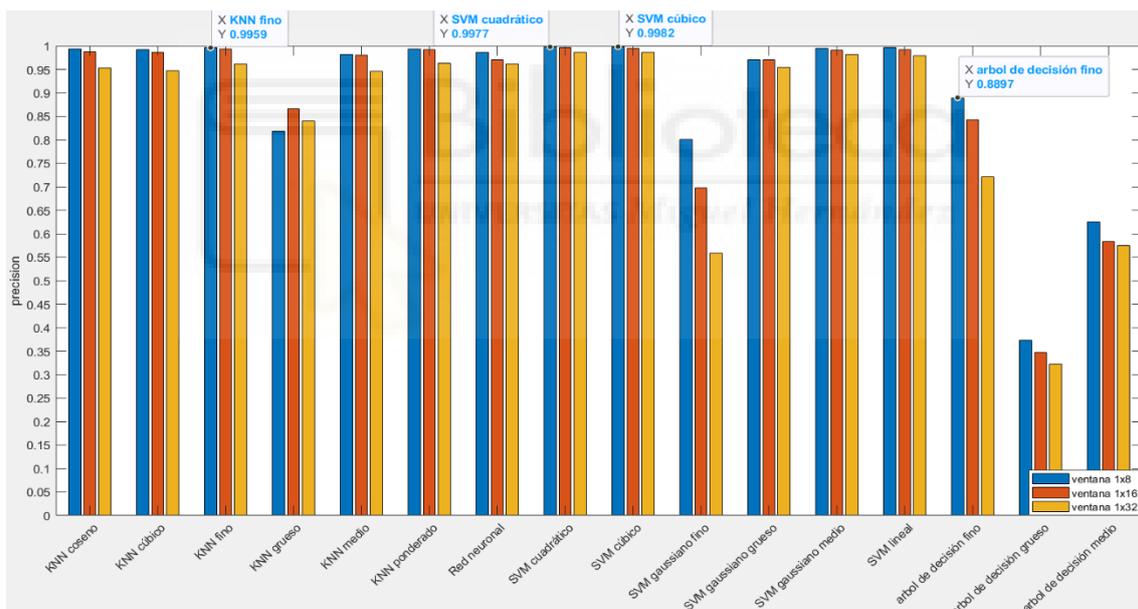
Gráfica 219. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en LAB

En la gráfica 219 los mejores clasificadores, usando LBP variante a rotación con radio 5 en LAB con ventanas en fila, son el SVM cúbico y el SVM cuadrático para ventanas de 8x1. También, podemos ver como a medida que se disminuye el tamaño de la ventana también disminuye la precisión del clasificador.



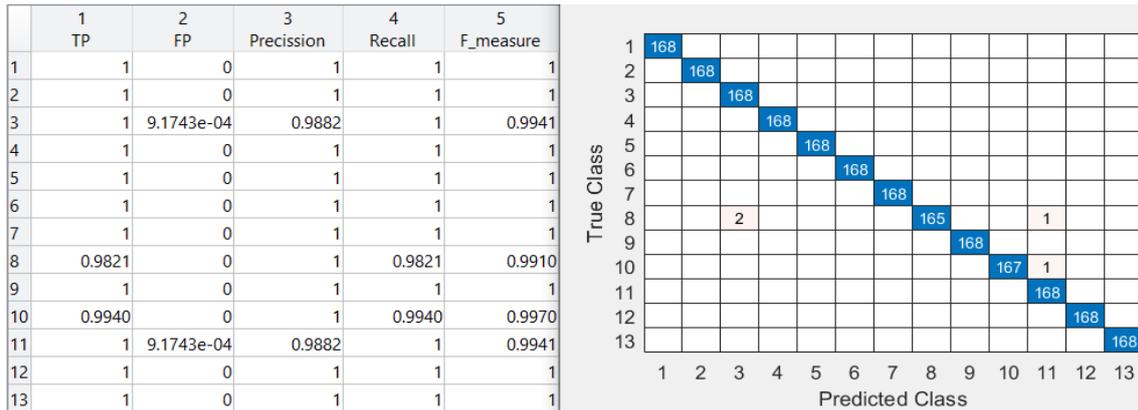
Gráfica 220. Validación del modelo elegido de la gráfica 219

Sacamos del clasificador SVM cuadrático esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en LAB para ventanas en filas de la gráfica 220.



Gráfica 221. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en LAB

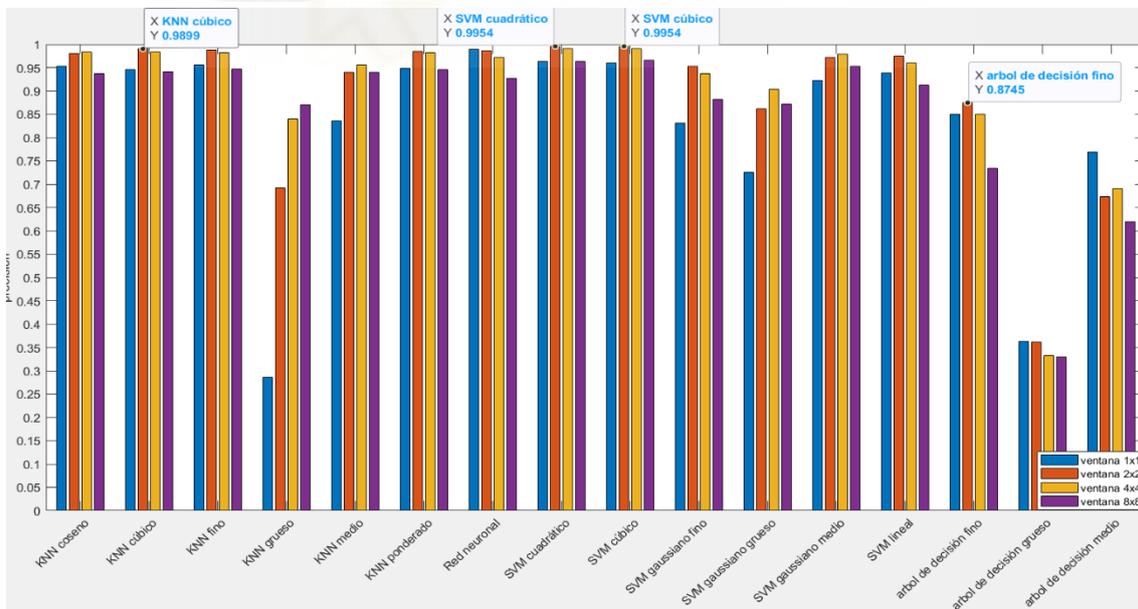
Terminando de analizar el LBP variante a rotación con radio 5 en LAB, vemos en la gráfica 221 que, en general, para ventanas en columnas los clasificadores se comportan mejor para el tamaño de 1x8 y conforme este tamaño disminuye, el resultado empeora. El mejor resultado lo encontramos en el clasificador SVM cúbico para la ventana de 1x8.



Gráfica 222. Validación del modelo elegido de la gráfica 221

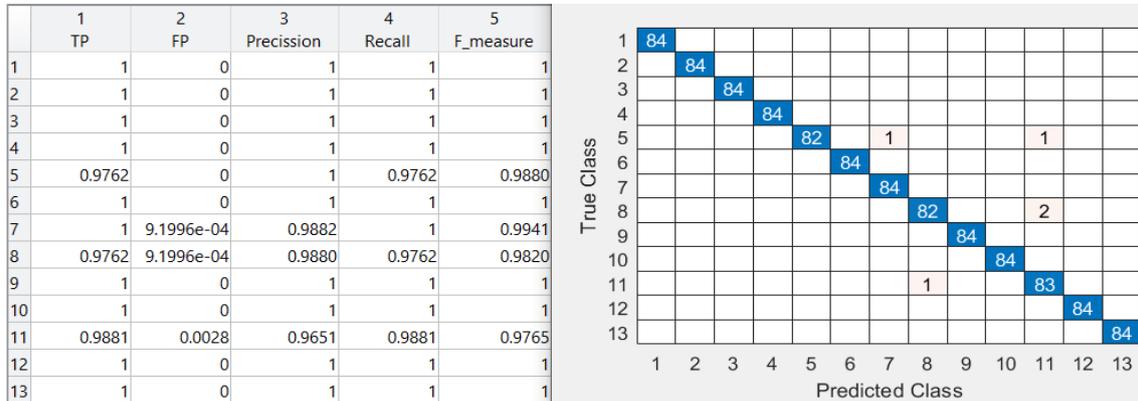
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en LAB para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 222.

Viendo el comportamiento de los clasificadores usando LBP variante a rotación con radio 5 en LAB, que el clasificador SVM cuadrático es el que por lo general mejor se comporta, y, específicamente, para la ventana de 2x2 es el resultado más alto.



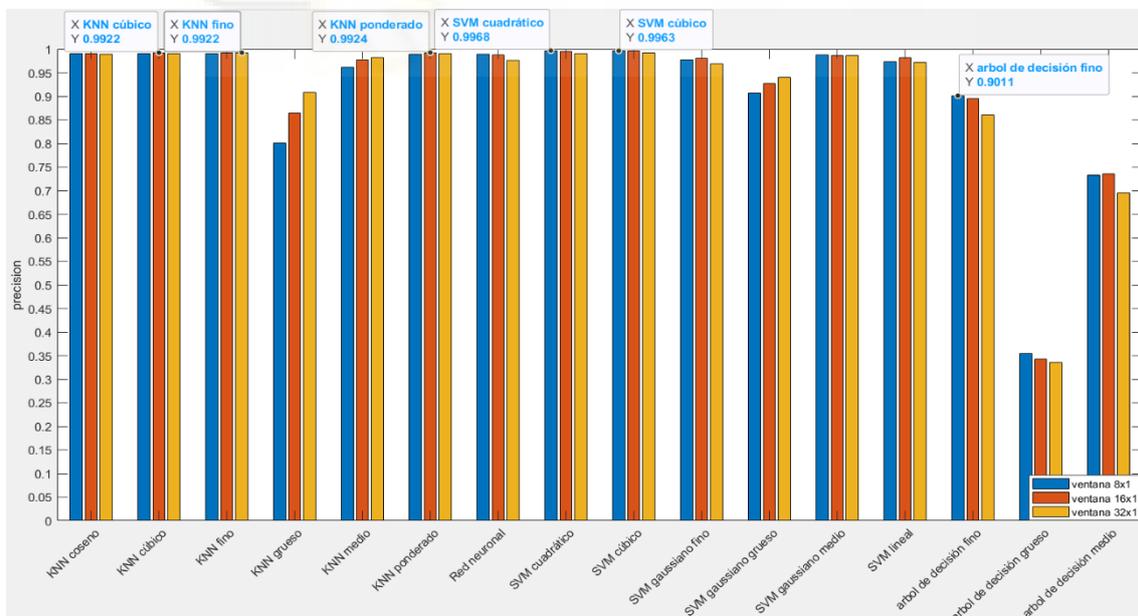
Gráfica 223. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en LAB

Ahora, usando LBP invariante a rotación con radio 1 en LAB, vemos en la gráfica 223 que la mayoría los clasificadores adquieren una mayor precisión cuando se usa la ventana de 2x2, siendo el SVM cúbico y el SVM cuadrático son los que mayor precisión alcanzan.



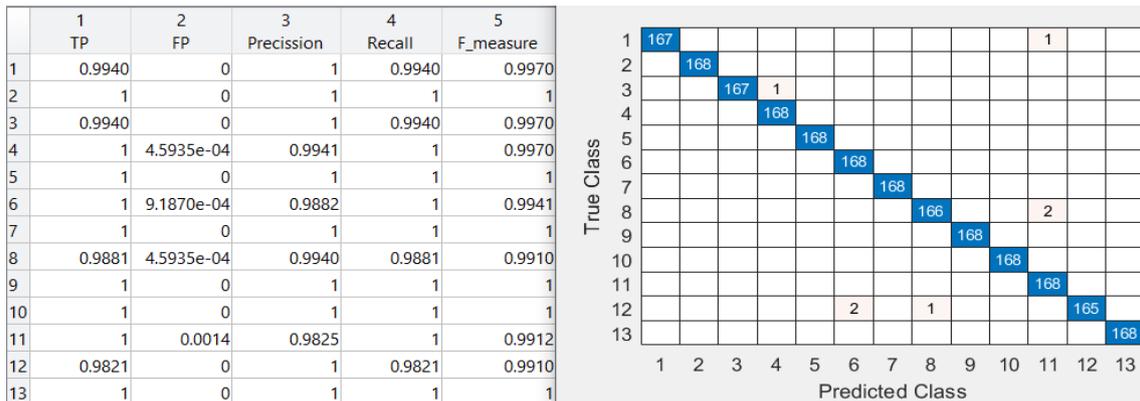
Gráfica 224. Validación del modelo elegido de la gráfica 223

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en LAB para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 224.



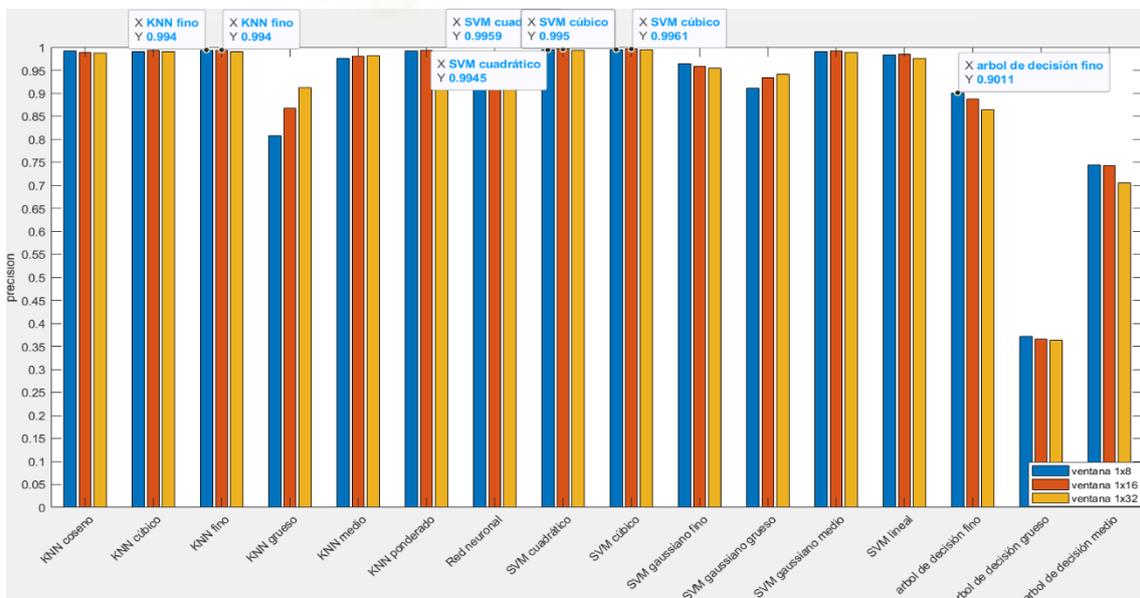
Gráfica 225. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en LAB

En muchos clasificadores vemos en la gráfica 225 que los valores en cada ventana son muy parecidos entre sí. Entonces, el clasificador que, usando LBP invariante a rotación con radio 1 en LAB, tiene la mayor precisión es el SVM cuadrático con ventana 8x1, pero este valor dista muy poco del obtenido por el SVM cúbico para la misma ventana.



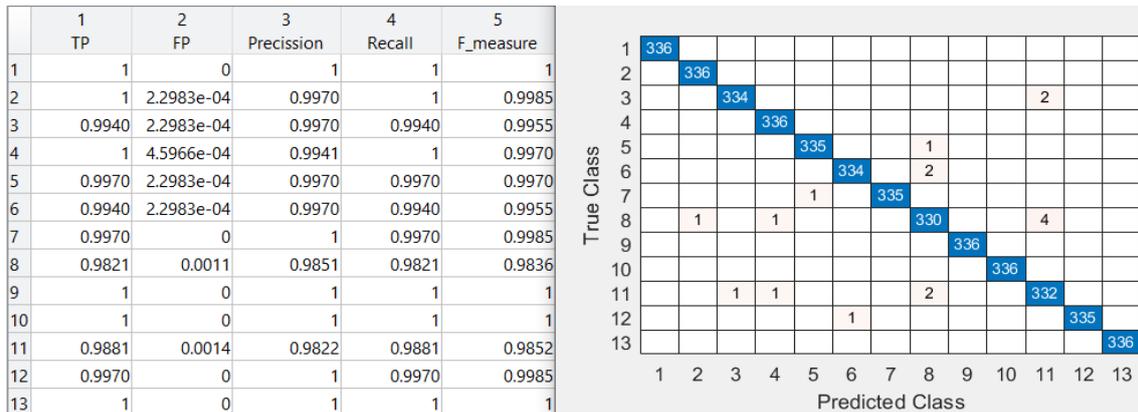
Gráfica 226. Validación del modelo elegido de la gráfica 225

Sacamos del clasificador SVM cuadrático esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en LAB para ventanas en filas de la gráfica 226.



Gráfica 227. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en LAB

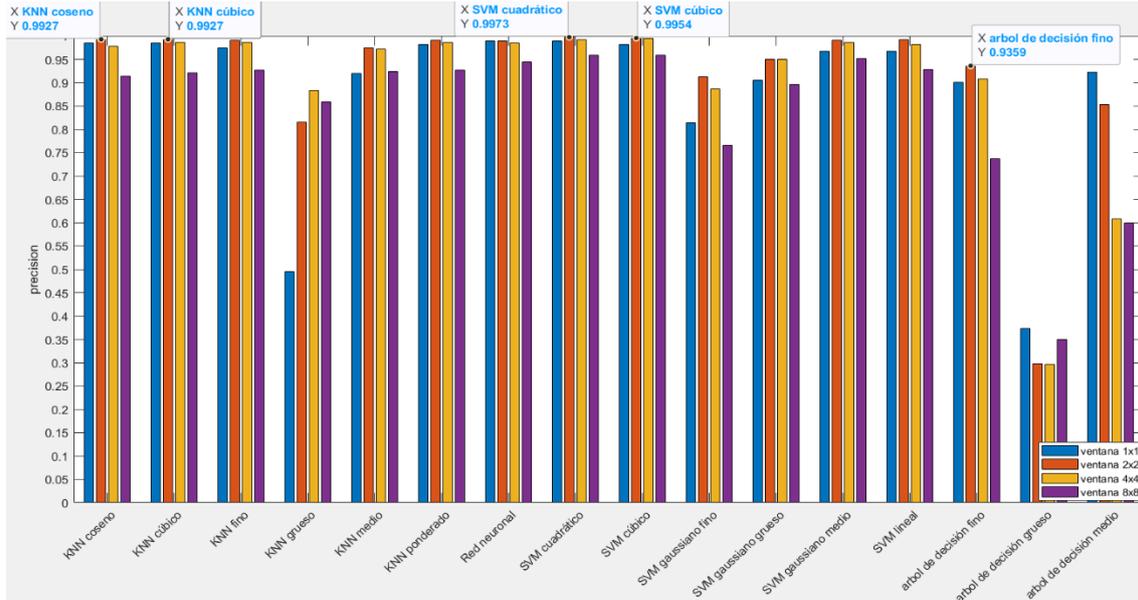
Generalmente en la gráfica 227, los clasificadores tienen unos valores semejantes para los distintos tipos de ventana. Por ello, usando LBP invariante a rotación con radio 1 en LAB, el clasificador SVM cúbico con ventana de 1x16 es el que mejor resultado proporciona, pero dista muy poco del SVM cuadrático con ventana de 1x16.



Gráfica 228. Validación del modelo elegido de la gráfica 227

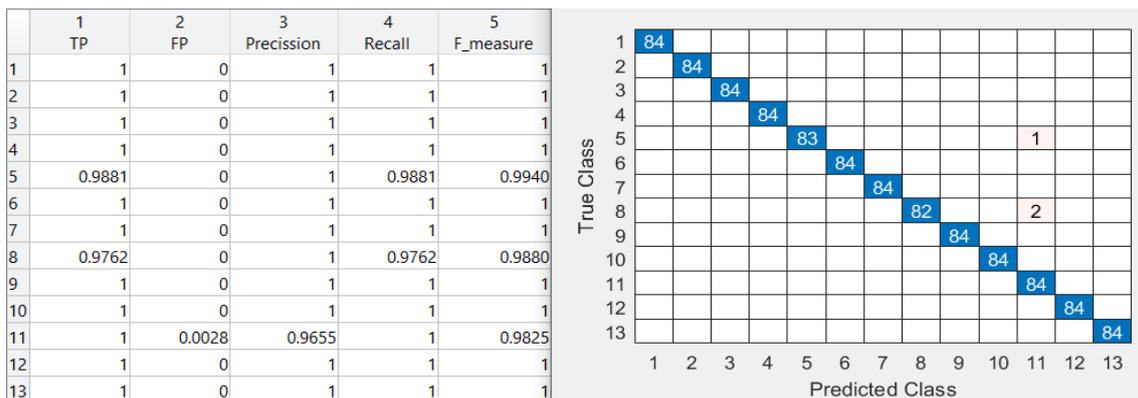
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en LAB para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 228.

Una vez vistas las tres graficas (gráfica 223, 225 y 227) usando LBP invariante a rotación con radio 1 en LAB el clasificador SVM cuadrático para ventanas de 8x1 es el que mejor resultado nos ofrece.



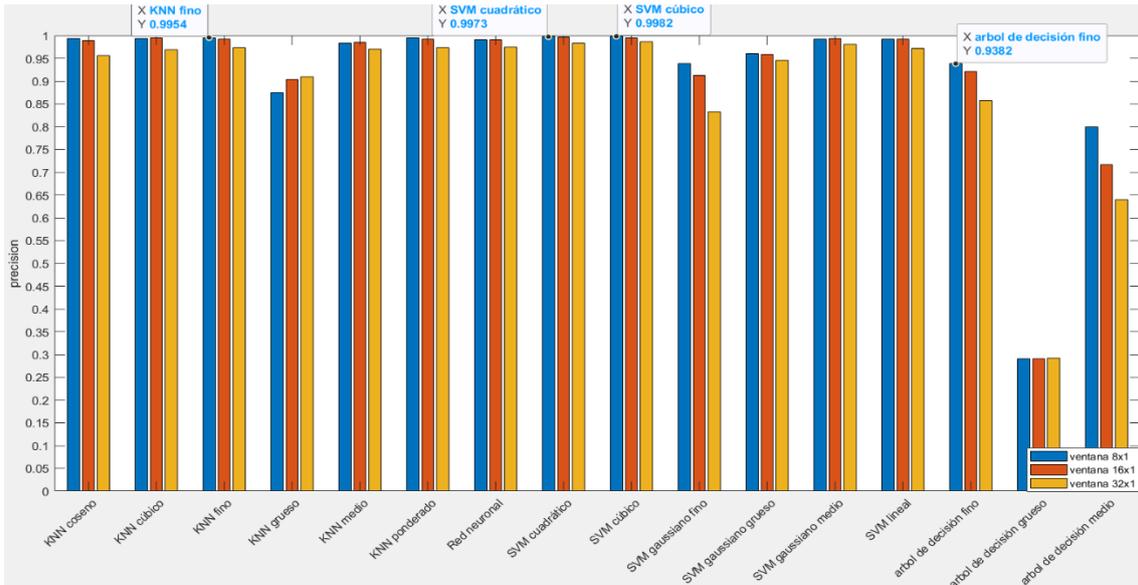
Gráfica 229. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en LAB

Con LBP invariante a rotación con radio 3 en LAB, el clasificador SVM cuadrático alcanza la más alta precisión de toda la gráfica para la ventana de 2x2. Generalmente en la gráfica 229, es en esta ventana en la que la mayoría de los clasificadores tienen mejores resultados, menos para los árboles de decisión grueso y medio.



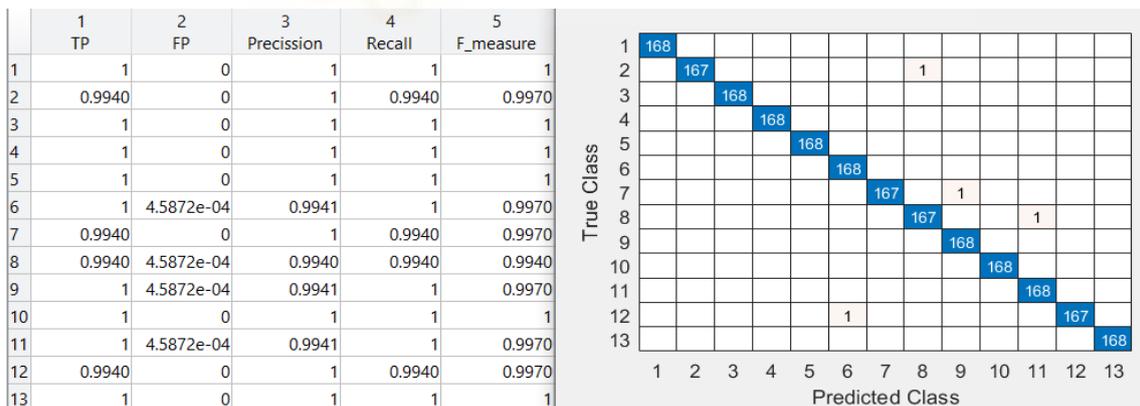
Gráfica 230. Validación del modelo elegido de la gráfica 229

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en LAB para ventanas cuadradas, es del clasificador SVM cuadrático de la gráfica 230.



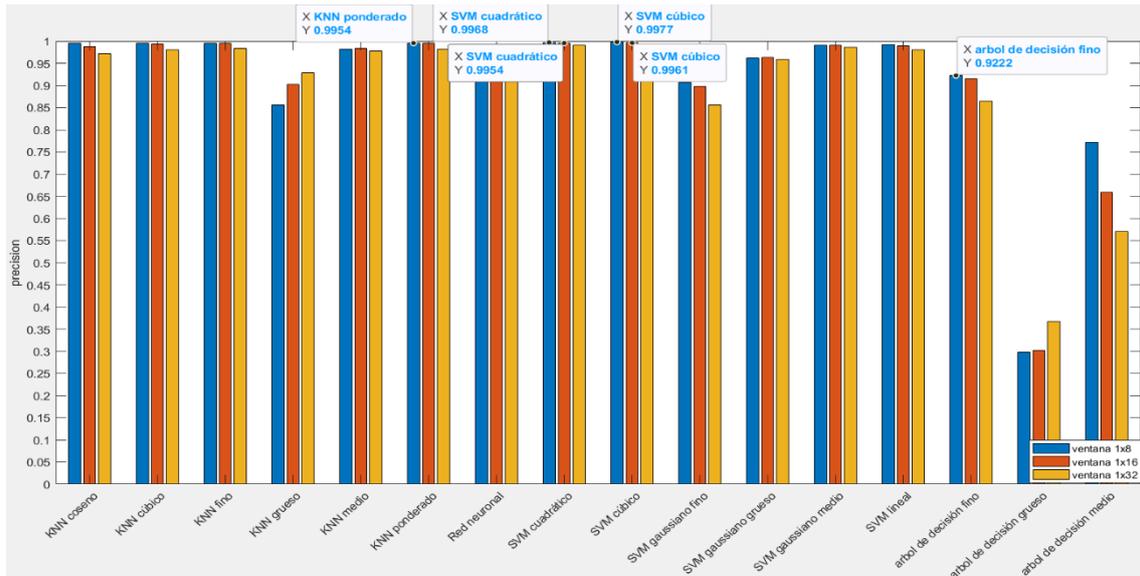
Gráfica 231. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en LAB

Podemos observar en la gráfica 231 que los mejores resultados, de la mayoría de los clasificadores, aparece cuando usamos ventanas de 8x1 y, a medida que este tamaño decrece, también lo hace la precisión. El mejor resultado viene por el clasificador SVM cúbico para ventana de 8x1, sin embargo, el SVM cuadrático para ventana de 8x1 tiene un valor también muy elevado y cercano al anterior.



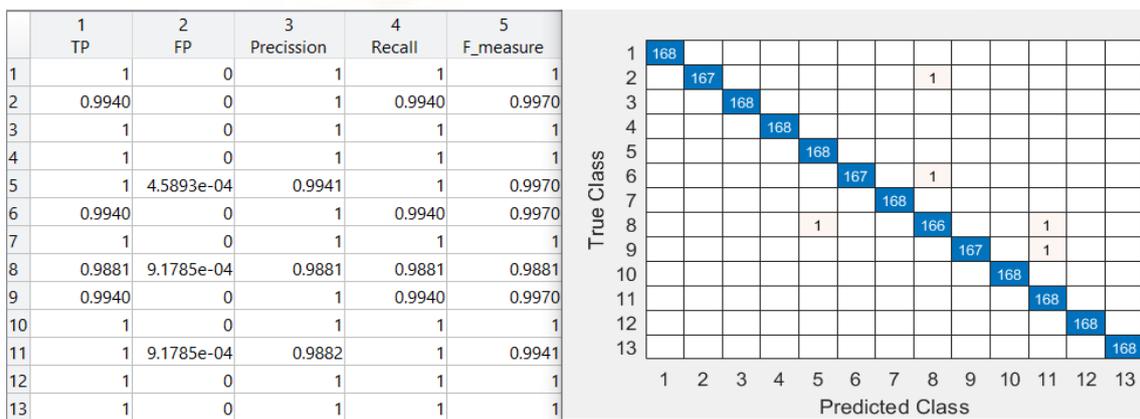
Gráfica 232. Validación del modelo elegido de la gráfica 231

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en LAB para ventanas en filas de la gráfica 232.



Gráfica 233. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en LAB

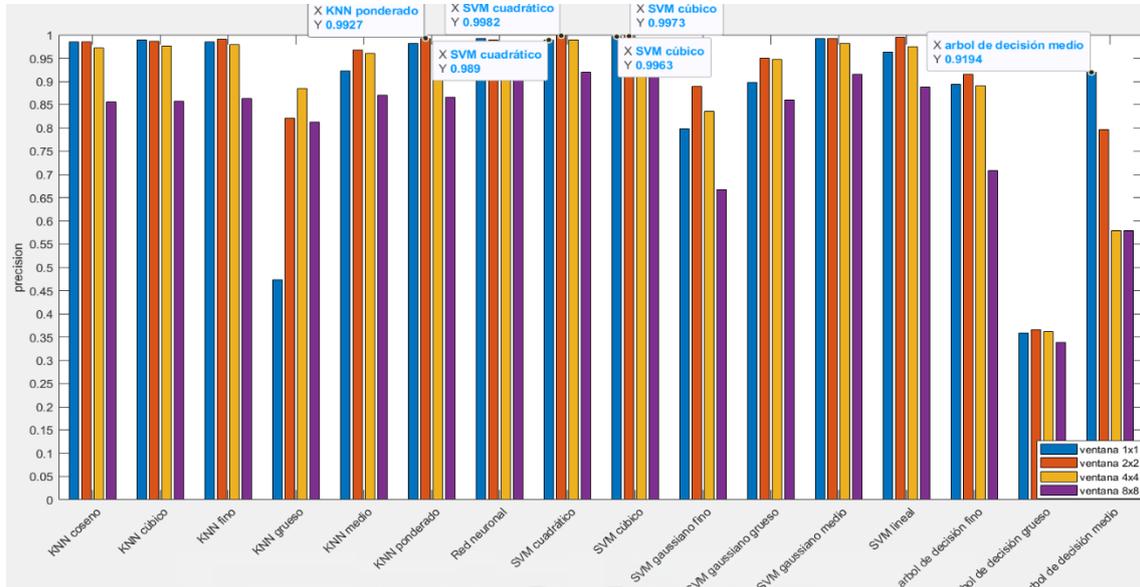
En la gráfica 223 para LBP invariante a rotación con radio 3 en LAB, la ventana de 1x8 es la que provoca, generalmente, los mejores resultados de muchos clasificadores y, conforme la ventana se hace más pequeña, la precisión disminuye. El que mejor resultado ofrece en este caso es el SVM cúbico con ventana de 1x8.



Gráfica 234. Validación del modelo elegido de la gráfica 233

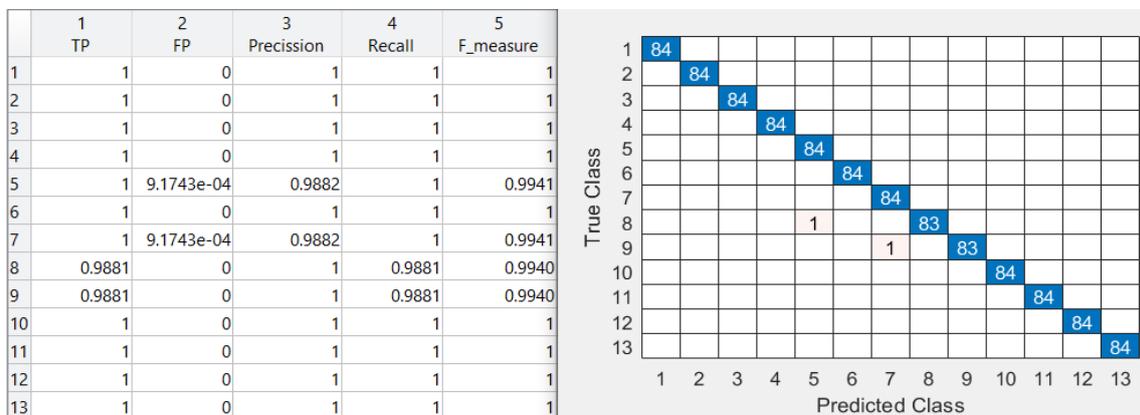
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en LAB para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 234.

Una vez visto todos los resultados usando LBP invariante a rotación con radio 3 en LAB, el clasificador SVM cúbico es el que mejores resultados ha ofrecido en los tres casos, siendo el mayor de todos para ventana de 8x1.



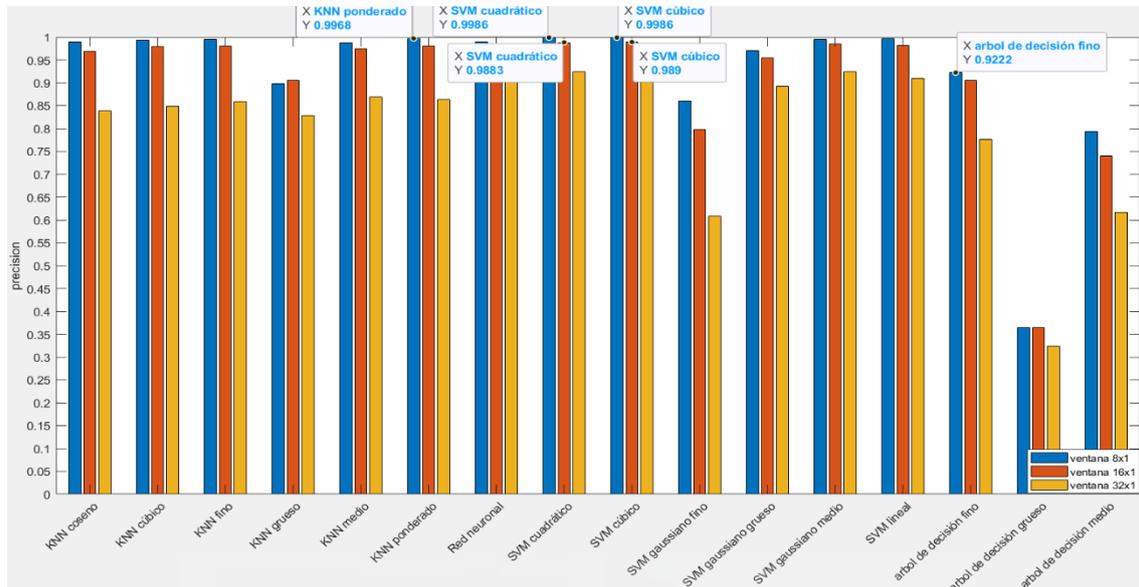
Gráfica 235. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en LAB

En la gráfica 235, continuando con LBP invariante a rotación con radio 5 en LAB, vemos en la mayoría de los clasificadores es la ventana de 2x2 la que ofrece los mejores resultados. El valor más alto viene por parte del clasificador SVM cuadrático con ventana de 2x2, y el siguiente es con la misma ventana el SVM cúbico.



Gráfica 236. Validación del modelo elegido de la gráfica 235

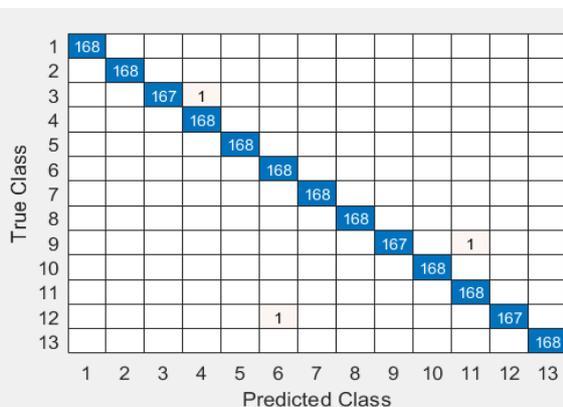
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en LAB para ventanas cuadradas, es del clasificador SVM cuadrático de la gráfica 236.



Gráfica 237. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en LAB

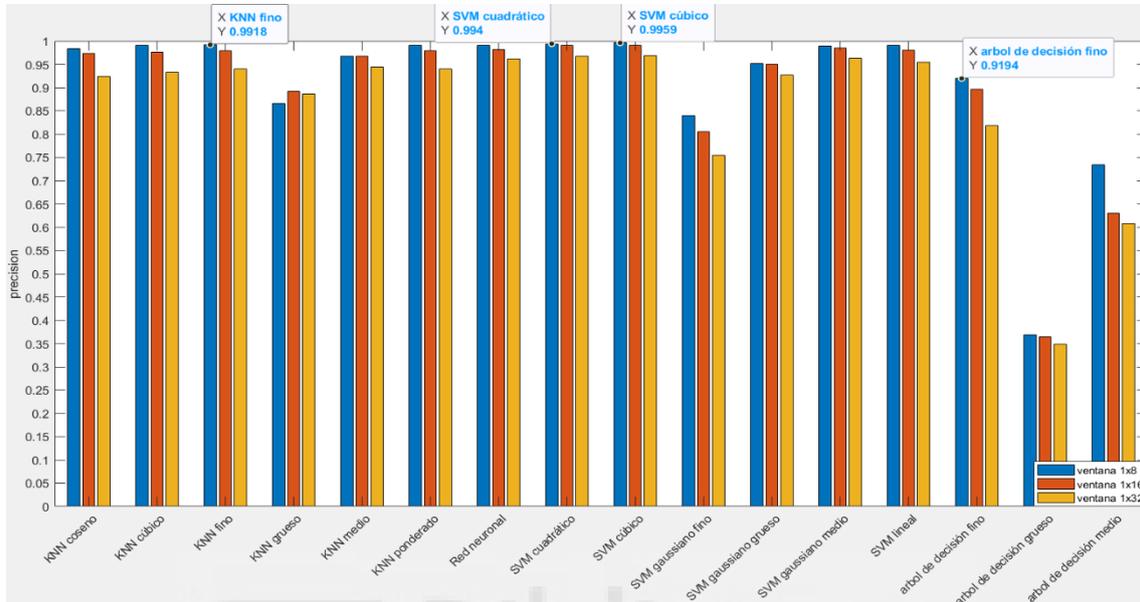
En la gráfica 237 la ventana de 8x1 es la que consigue el mejor resultado en la mayoría de los clasificadores usando LBP invariante a rotación con radio 5 en LAB y, si la ventana cambia su tamaño a uno menor la precisión se ve reducida. Los mejores clasificadores son el SVM cúbico y el SVM cuadrático para ventana de 8x1.

	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	1	0	1	1	1
2	1	0	1	1	1
3	0.9940	0	1	0.9940	0.9970
4	1	4.5851e-04	0.9941	1	0.9970
5	1	0	1	1	1
6	1	4.5851e-04	0.9941	1	0.9970
7	1	0	1	1	1
8	1	0	1	1	1
9	0.9940	0	1	0.9940	0.9970
10	1	0	1	1	1
11	1	4.5851e-04	0.9941	1	0.9970
12	0.9940	0	1	0.9940	0.9970
13	1	0	1	1	1



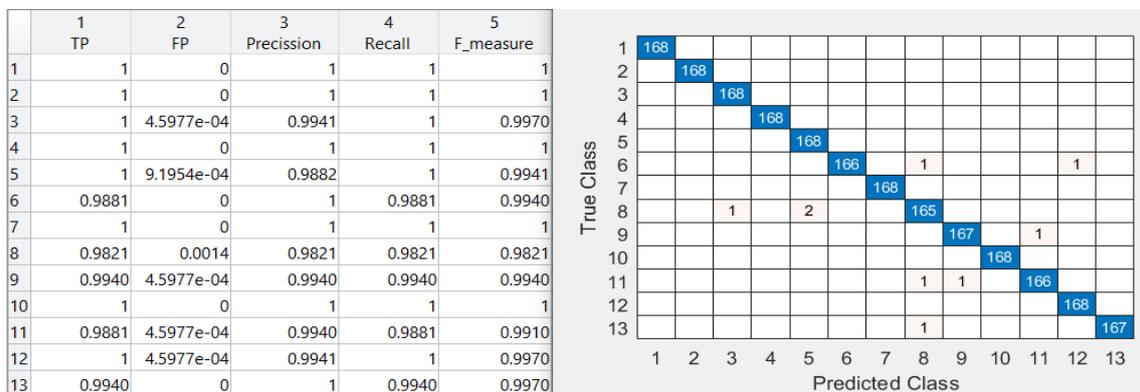
Gráfica 238. Validación del modelo elegido de la gráfica 237

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en LAB para ventanas en filas de la gráfica 238.



Gráfica 239. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en LAB

En la gráfica 239 el mejor resultado nos lo da el clasificador SVM cúbico para ventana de 1x8 usando LBP invariante a rotación con radio 5 en LAB. Es apreciable que a medida que la ventana se hace más pequeña la precisión también se reduce en la mayoría de clasificadores.



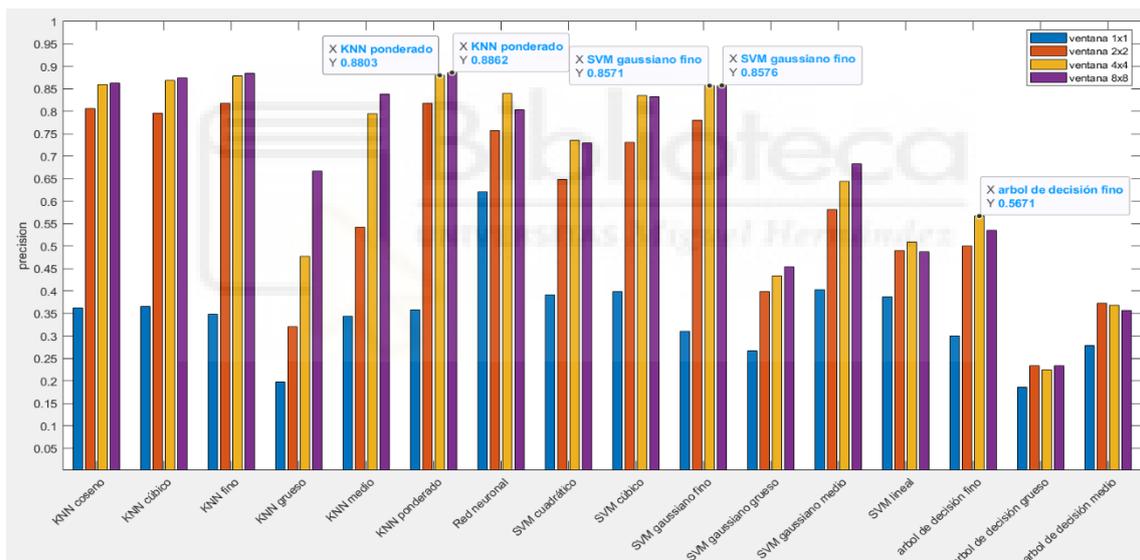
Gráfica 240. Validación del modelo elegido de la gráfica 239

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en LAB para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 240.

Visto los resultados anteriores, el clasificador SVM cuadrático y el SVM cúbico son los que mejor se comportan usando LBP invariante a rotación con radio 5 en LAB y una ventana de 8x1.

### 4.1.6 Comparación en RGB con el tercer data set

Hemos finalizado con los resultados del segundo data set, ahora empezaremos con los resultados del tercer data set.



Gráfica 241. Comparación clasificadores para ventanas cuadradas para momentos de histograma en RGB

En la gráfica 241, usando los momentos de histograma en RGB para ventanas cuadradas vemos que los mejores resultados de los clasificadores son o para ventana de 4x4 o para ventana de 8x8, siendo el clasificador K-NN ponderado el de mayor precisión con una ventana de 8x8.

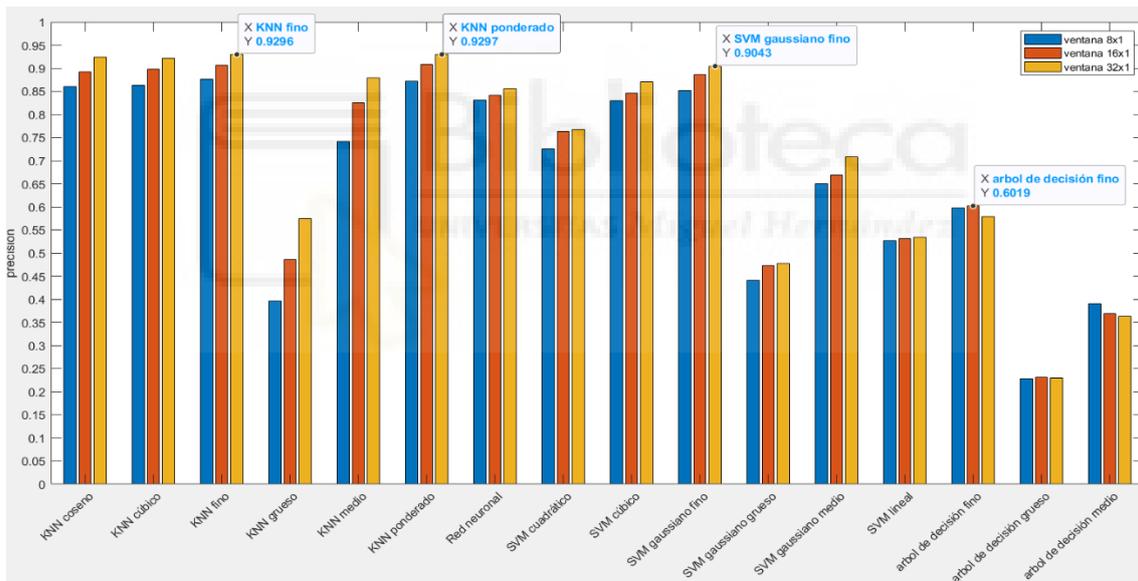
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9643	0.0059	0.9344	0.9643	0.9491
2	0.9159	0.0097	0.8914	0.9159	0.9035
3	0.8571	0.0177	0.8079	0.8571	0.8318
4	0.9085	0.0099	0.8880	0.9085	0.8981
5	0.8534	0.0115	0.8657	0.8534	0.8595
6	0.8512	0.0089	0.8924	0.8512	0.8713
7	0.9911	0.0026	0.9708	0.9911	0.9809
8	0.9301	0.0071	0.9191	0.9301	0.9246
9	0.8884	0.0144	0.8426	0.8884	0.8649
10	0.7798	0.0119	0.8506	0.7798	0.8137
11	0.7969	0.0096	0.8786	0.7969	0.8357
12	0.8698	0.0072	0.9126	0.8698	0.8907
13	0.9219	0.0114	0.8756	0.9219	0.8982

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	1296	7		32	1	3				4		1	
2	13	1231	14	15	2	1	8	1		21	21	14	3
3	1	13	1152	7	7	25	14		43	14	21	8	39
4	30	20	12	1221	7	14	1	2	1	15	20	1	
5	3	2	6	3	1147	11		29	65	8	9	21	40
6	7	5	49	21	7	1144			11	20	42	15	12
7			12				1332						
8		2	2	3	28	6		1250	15	4	1	20	13
9		1	37		57	9		12	1194	12	2	6	14
10	14	46	31	29	12	45	1	14	28	1048	43	12	21
11	20	28	47	37	5	17	16	8	17	39	1071	15	24
12	3	23	27	6	26	7		26	14	18	14	1169	11
13		3	37	1	26			7	20	7	2	2	1239

Gráfica 242. Validación del modelo elegido de la gráfica 241

Esta representación de la matriz de confusión y las tasas de acierto y error, para los momentos de histograma en RGB para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 242.



Gráfica 243. Comparación clasificadores para ventanas en filas para momentos de histograma en RGB

En la gráfica 243, siguiendo con el análisis en ventanas en filas, vemos que el clasificador K-NN ponderado para ventanas de 32x1 es el que mejor precisión tiene usando momentos de histograma en RGB, pero la diferencia con el K-NN fino es ínfima. También vemos que los mejores resultados de los clasificadores, generalmente, se produce en las ventanas de 32x1 y conforme la ventana decrece también lo hace la precisión.

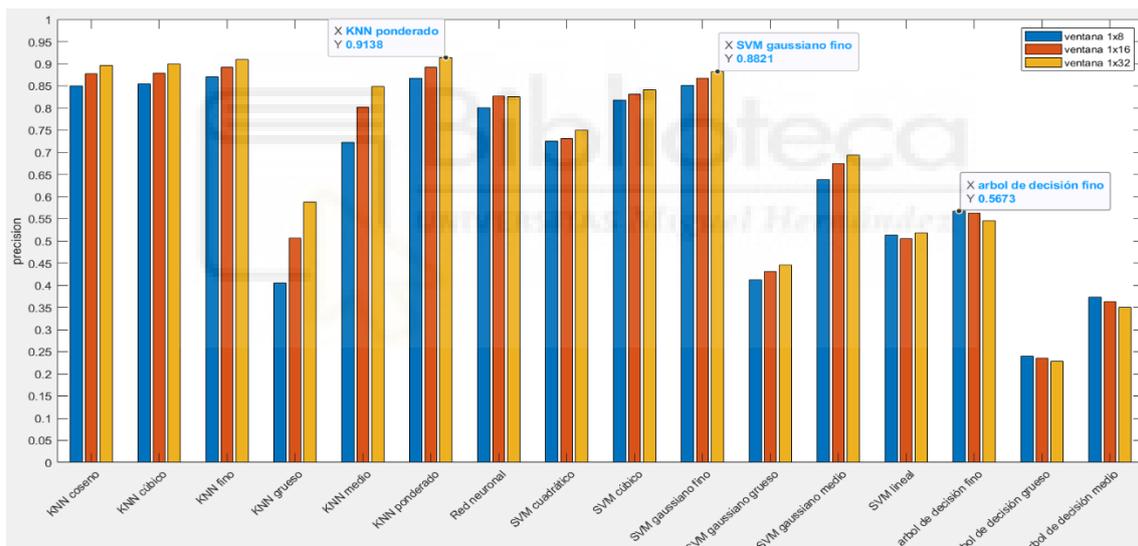
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9449	0.0170	0.8236	0.9449	0.8801
2	0.9375	0.0074	0.9144	0.9375	0.9258
3	0.9152	0.0094	0.8913	0.9152	0.9031
4	0.9271	0.0062	0.9257	0.9271	0.9264
5	0.8765	0.0062	0.9218	0.8765	0.8986
6	0.9018	0.0054	0.9337	0.9018	0.9175
7	0.9777	7.4850e-04	0.9910	0.9777	0.9843
8	0.9182	0.0062	0.9250	0.9182	0.9216
9	0.9390	0.0075	0.9132	0.9390	0.9259
10	0.8720	0.0091	0.8892	0.8720	0.8805
11	0.9048	0.0041	0.9485	0.9048	0.9261
12	0.9048	0.0034	0.9575	0.9048	0.9304
13	0.9092	0.0072	0.9133	0.9092	0.9113

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	635	4	8	5		5	1	1		9	1	1	2
2	8	630	12	5		2	1	2		7	1	4	
3	16	10	615	2		1	1	4	10	2	2	1	8
4	11	2	7	623		3		4	1	8	8	2	3
5	11		2	2	589	5		8	13	18	6	4	14
6	7	1	9	4	1	606		14	10	9	1	3	7
7	12	1	2				657						
8	8	4	3	8	9	8		617	4	2	3	4	2
9	7	1	2	2	13	4		1	631	2			9
10	10	16	4	11	12	6		5	5	586	5	6	6
11	19	8	7	5	3		3	3	3	8	608		5
12	13	8	6	3	4	8		6	6	5	3	608	2
13	14	4	13	3	8	3	1	2	8	3	3	2	611

Gráfica 244. Validación del modelo elegido de la gráfica 243

Usaremos el clasificador con más precisión, el K-NN ponderado, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en RGB para ventanas en fila de la gráfica 244.



Gráfica 245. Comparación clasificadores para ventanas en columnas para momentos de histograma en RGB

Generalmente en la gráfica 245, vemos que los clasificadores se comportan mejor para ventanas de 1x32 y a medida que la ventana es más pequeña, en la mayoría de clasificadores, la precisión disminuye. El clasificador que más precisión tiene usando momentos de histograma en RGB es el K-NN ponderado para ventanas de 1x32.

	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.8542	0.0159	0.8200	0.8542	0.8367
2	0.9330	0.0066	0.9234	0.9330	0.9282
3	0.9018	0.0114	0.8707	0.9018	0.8860
4	0.9048	0.0096	0.8889	0.9048	0.8968
5	0.9018	0.0049	0.9395	0.9018	0.9203
6	0.8750	0.0096	0.8855	0.8750	0.8802
7	0.9717	0.0034	0.9603	0.9717	0.9660
8	0.9494	0.0033	0.9608	0.9494	0.9551
9	0.9494	0.0095	0.8948	0.9494	0.9213
10	0.7946	0.0111	0.8585	0.7946	0.8253
11	0.8988	0.0061	0.9264	0.8988	0.9124
12	0.9033	0.0051	0.9382	0.9033	0.9204
13	0.9449	0.0069	0.9203	0.9449	0.9325

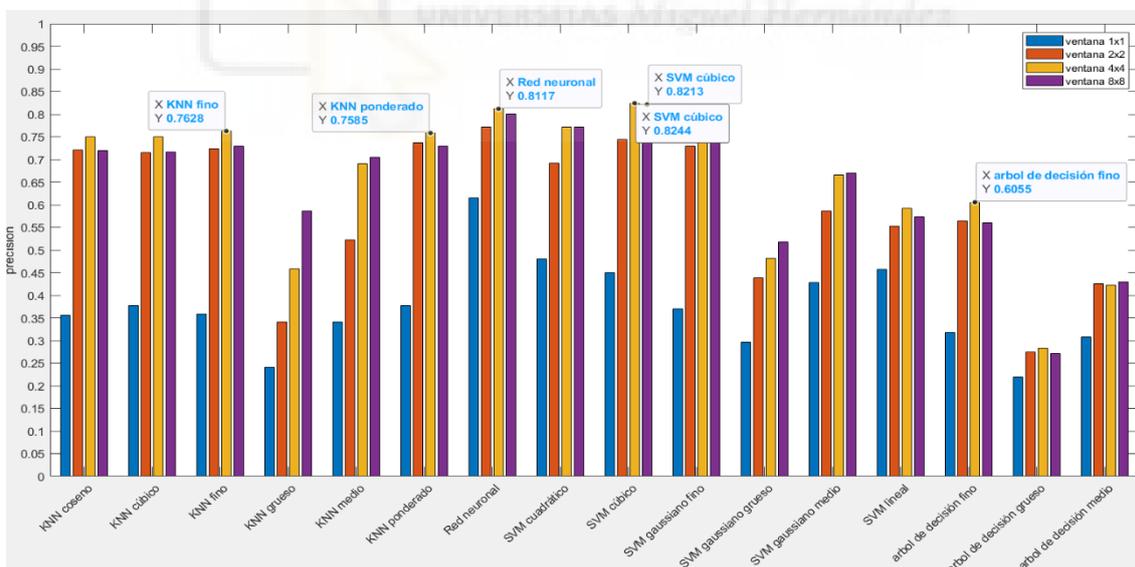
  

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	574	11	3	18	1	20	16		1	17	10	1	
2	16	627	10	3	1	1	1		3	2	5	2	1
3	6	6	606	7		9	3		7	7	2	2	17
4	17	1	6	608		13	4		1	17	3	2	
5	7	1	2	1	606	3		8	15	5	1	6	17
6	16	1	10	15	2	588		1	8	21	3	5	2
7	11	2	3	2		1	653						
8	7	1	3	2	1	3		638	9	1	2	4	1
9	4	4	4	2	5	3		4	638	1		4	3
10	20	8	22	14	11	14	1	6	10	534	19	7	6
11	16	12	4	4	2	3	2	3	2	8	604	7	5
12	3	5	9	6	10	3		3	14	7	2	607	3
13	3		14	2	6	3		1	5	2	1		635

Gráfica 246. Validación del modelo elegido de la gráfica 245

Usaremos el clasificador con más precisión, el K-NN ponderado, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en RGB para ventanas en columna de la gráfica 246.

Después de ver todas las gráficas, el clasificador K-NN ponderado para ventanas de 32x1 es el que mayor precisión nos da, y en general para los tres tipos de ventana es el que mejor se comporta.



Gráfica 247. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en RGB

En la gráfica 247 es en la ventana 4x4 es en la que suelen encontrar los clasificadores su mejor resultado. Por eso, usando la matriz de coocurrencia en

RGB, el SVM cúbico con ventana de 4x4 nos da el valor más elevado, seguido por el valor del mismo clasificador, pero para ventana de 2x2.

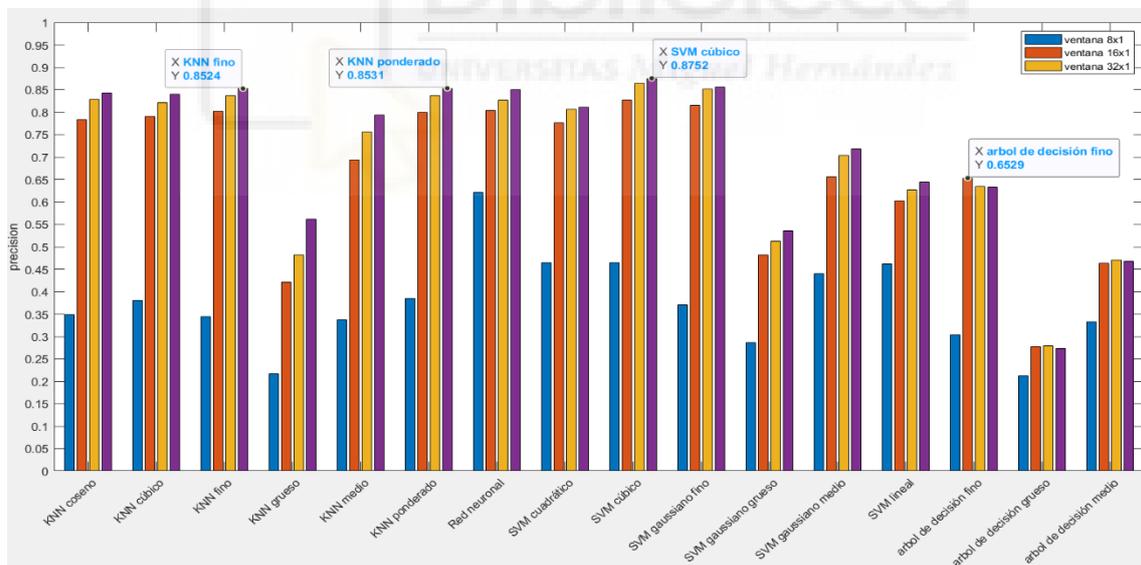
	1	2	3	4	5															
	TP	FP	Precision	Recall	F_measure															
1	0.9643	0.0047	0.9501	0.9643	0.9572															
2	0.7738	0.0070	0.9123	0.7738	0.8374															
3	0.8869	0.0153	0.8442	0.8869	0.8650															
4	0.7292	0.0150	0.8194	0.7292	0.7717															
5	0.8274	0.0195	0.7989	0.8274	0.8129															
6	0.8423	0.0250	0.7587	0.8423	0.7983															
7	0.9643	0.0042	0.9558	0.9643	0.9600															
8	0.9196	0.0231	0.7883	0.9196	0.8489															
9	0.9345	0.0273	0.7621	0.9345	0.8396															
10	0.6042	0.0245	0.6976	0.6042	0.6475															
11	0.7262	0.0239	0.7394	0.7262	0.7327															
12	0.6518	0.0131	0.8233	0.6518	0.7276															
13	0.8750	0.0125	0.8673	0.8750	0.8711															

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	324			4	4		1	1			1	1	
2	4	260	14	8	1	5	4	3	2	9	14	4	8
3	1	4	298	3	5	1			10	3	6	4	1
4	4	3	1	245	2	10	1	11	31	17	4	7	
5	1		4	1	278	16		5	13	2		5	11
6			1	5	14	283				15	8	3	7
7		1	1				324				5	5	
8			3	7	4	1		309	7		2	3	
9			9					11	314				1
10	3	5	3	17	10	27		12	4	203	34	9	9
11	3	11	11	3	5	8	8	4		26	244	7	6
12	1		2	5	26	14	1	21	30	4	11	219	2
13		1	2	1	3	7		16	1	6	1	4	294

Gráfica 248. Validación del modelo elegido de la gráfica 247

Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en RGB para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 248.



Gráfica 249. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en RGB

Vemos en la gráfica 250 que usando la matriz de coocurrencia en RGB el SVM cúbico es la que mejor se comporta cuando escogemos la ventana 32x1.

También se puede apreciar que los clasificadores, generalmente, ofrecen el

mejor resultado para ese tipo de ventana y a medida que el tamaño de la ventana aumenta, la precisión decrece.

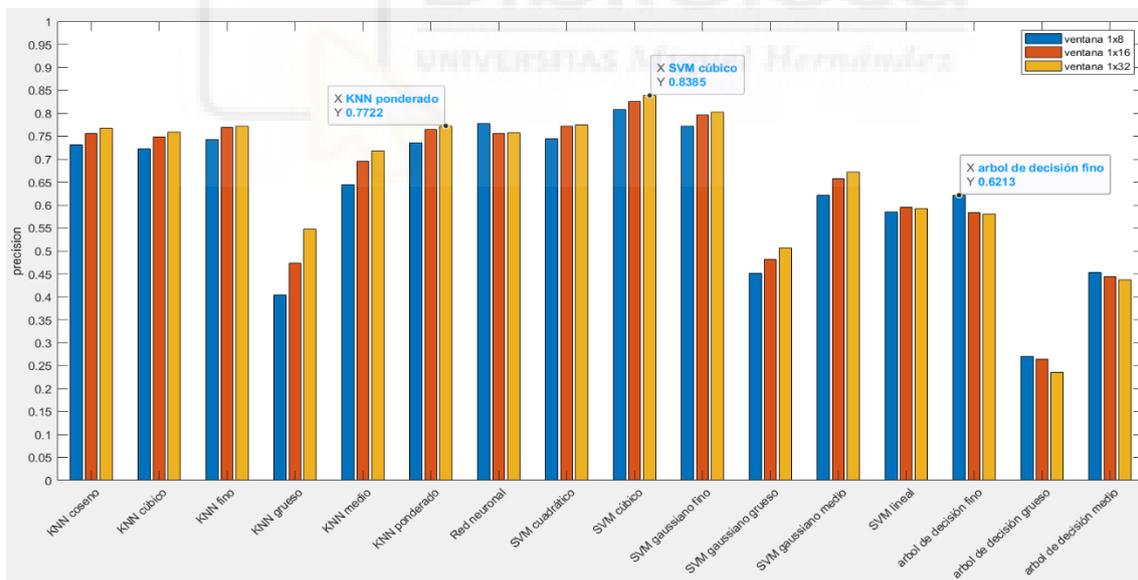
	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	0.9643	0.0186	0.8244	0.9643	0.8889
2	0.8452	0.0117	0.8672	0.8452	0.8561
3	0.5982	0.0028	0.9504	0.5982	0.7342
4	0.7842	0.0105	0.8711	0.7842	0.8254
5	0.8542	0.0234	0.7674	0.8542	0.8085
6	0.9241	0.0117	0.8771	0.9241	0.9000
7	0.9673	0.0024	0.9731	0.9673	0.9701
8	0.9375	0.0279	0.7527	0.9375	0.8350
9	0.9420	0.0252	0.7720	0.9420	0.8485
10	0.7842	0.0157	0.8183	0.7842	0.8009
11	0.8438	0.0140	0.8450	0.8438	0.8444
12	0.7589	0.0055	0.9256	0.7589	0.8340
13	0.8542	0.0062	0.9258	0.8542	0.8885

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	648	1		5		7				5	6		
2	7	568	4	6	4	8	9	5	8	10	30	3	10
3	14	41	402	18	72		1	12	71	13	12	14	2
4	12	11		527	8	16	1	31	45	17	4		
5	10		8	7	574	15		22	14	9	2	8	3
6	6	3		6	16	621				11	5	1	3
7	11	1					650				8		2
8	8		3	9	5	3		630	7	1	2	3	1
9	7		3	1	2	1		21	633	3			1
10	13	8	2	15	22	17	3	31	4	527	21		9
11	16	18		6	4	4	3	8		31	567	10	5
12	18	1		4	29	6	1	38	35	7	12	510	11
13	16	3	1	1	12	10		39	3	10	2	1	574

Gráfica 250. Validación del modelo elegido de la gráfica 249

Sacamos del clasificador SVM cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en RGB para ventanas en filas de la gráfica 250.



Gráfica 251. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en RGB

La gráfica 251 muestra el comportamiento de los clasificadores cuando usamos las ventanas en columna con la matriz de coocurrencia en RGB, vemos que el mejor resultado nos lo da el SVM cúbico para ventanas de 1x32. También cabe

mencionar que conforme la ventana se hace más grande la precisión de los clasificadores se reduce.

	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	0.8854	0.0177	0.8230	0.8854	0.8530
2	0.7560	0.0069	0.9104	0.7560	0.8260
3	0.8348	0.0159	0.8299	0.8348	0.8323
4	0.7515	0.0173	0.8016	0.7515	0.7757
5	0.8884	0.0137	0.8578	0.8884	0.8728
6	0.8051	0.0199	0.7898	0.8051	0.7973
7	0.9375	0.0043	0.9531	0.9375	0.9452
8	0.8929	0.0149	0.8475	0.8929	0.8696
9	0.9077	0.0308	0.7323	0.9077	0.8106
10	0.6503	0.0269	0.6915	0.6503	0.6702
11	0.8274	0.0256	0.7503	0.8274	0.7870
12	0.7589	0.0068	0.9123	0.7589	0.8286
13	0.8720	0.0066	0.9243	0.8720	0.8974

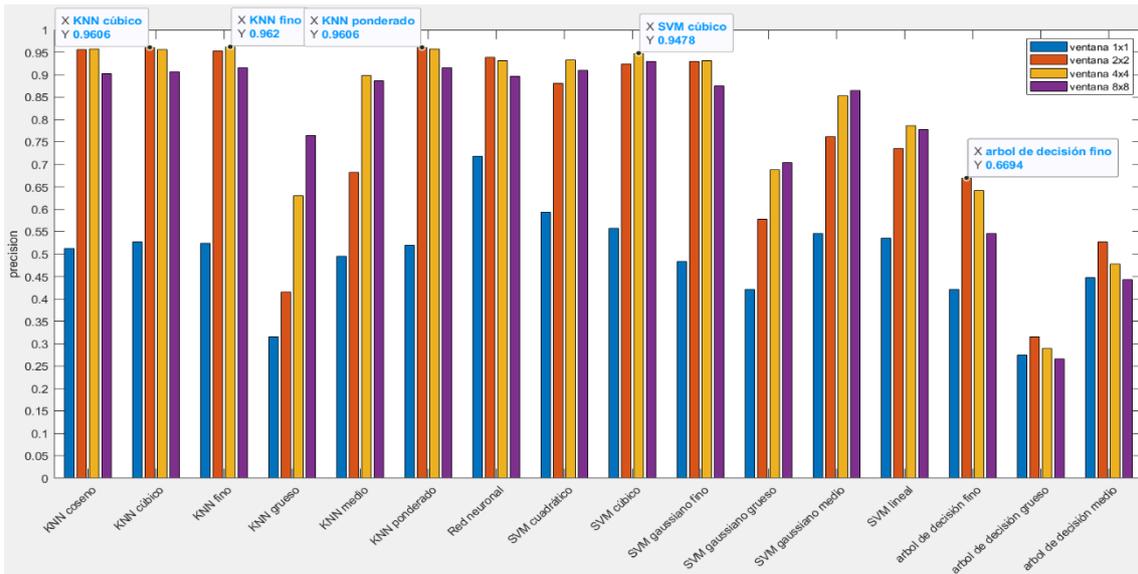
  

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	595	3	5	13		13	19		1	13	7	3	
2	12	508	24	15	3	11	5	2		26	47	11	8
3	9	5	561	4	9	2			39	23	14	6	
4	15	9	1	505	12	22	1	8	52	23	23	1	
5	6		7	5	597	13		5	19	4	3	1	12
6	9	3	1	20	14	541	1	5	2	43	13	10	10
7	29	4		1			630			2	2		4
8	6		11	9	9	4		600	20	2	1	7	3
9	4		23		1	1		29	610	1		1	2
10	16	9	22	35	17	29		10	26	437	62	4	5
11	13	17	8	17	4	6	5		1	41	556	1	3
12	4		11	3	24	19		16	62	15	7	510	1
13	5		2	3	6	24		33	1	2	6	4	586

Gráfica 252. Validación del modelo elegido de la gráfica 251

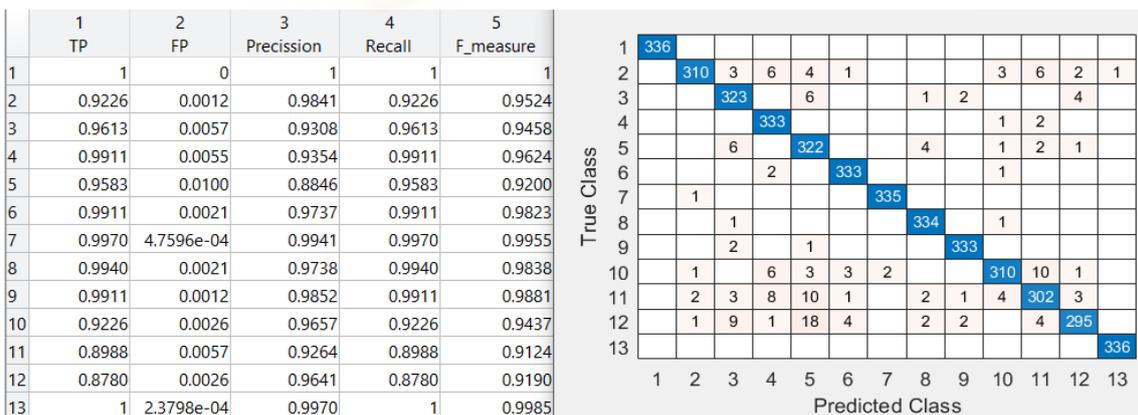
Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en RGB para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 252.

Viendo los últimos gráficos, la red neuronal es la que mejor resultado ofrece con ventana de 32x1. Sin embargo, es digno de mención el comportamiento del SVM cúbico que para los distintos tipos de ventana siempre tiene valores muy buenos.



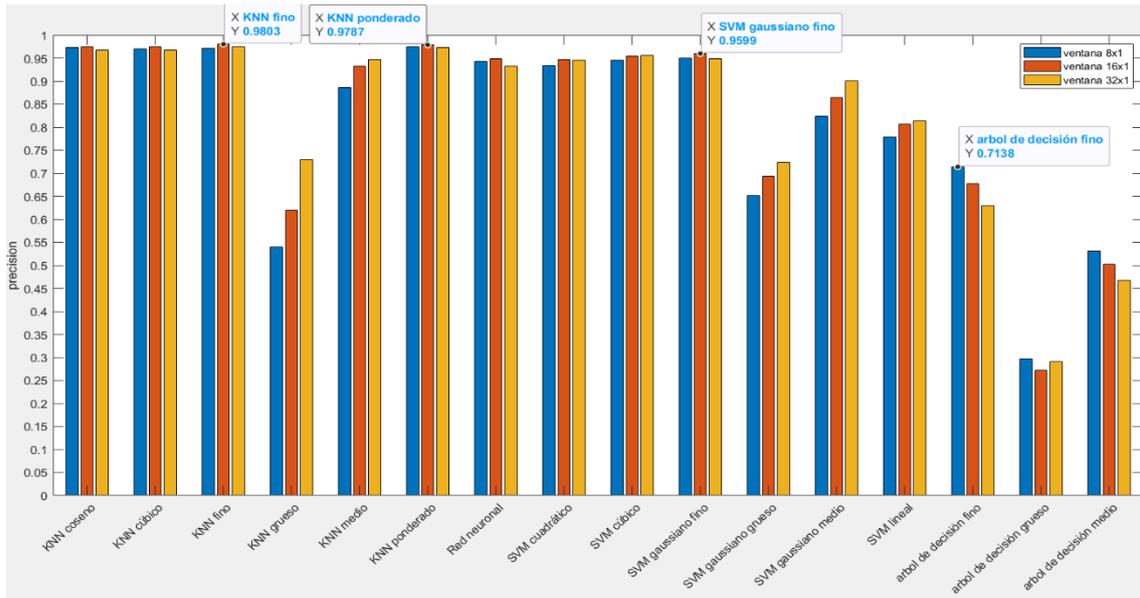
Gráfica 253. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en RGB

En la gráfica 253, usando LBP variante a rotación en RGB vemos que, en la mayoría de clasificadores, los valores de las ventanas 2x2 y 4x4 son muy similares. El clasificador K-NN fino es el que mayor precisión tiene usando la ventana de 4x4, siendo el K-NN cúbico y el K-NN ponderado los que tienen el siguiente.



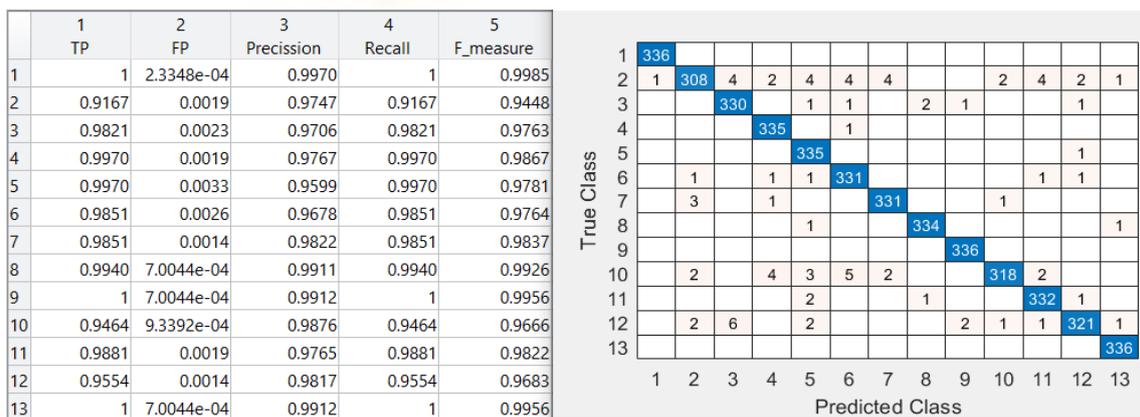
Gráfica 254. Validación del modelo elegido de la gráfica 253

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en RGB para ventanas cuadradas, es del clasificador K-NN fino de la gráfica 254.



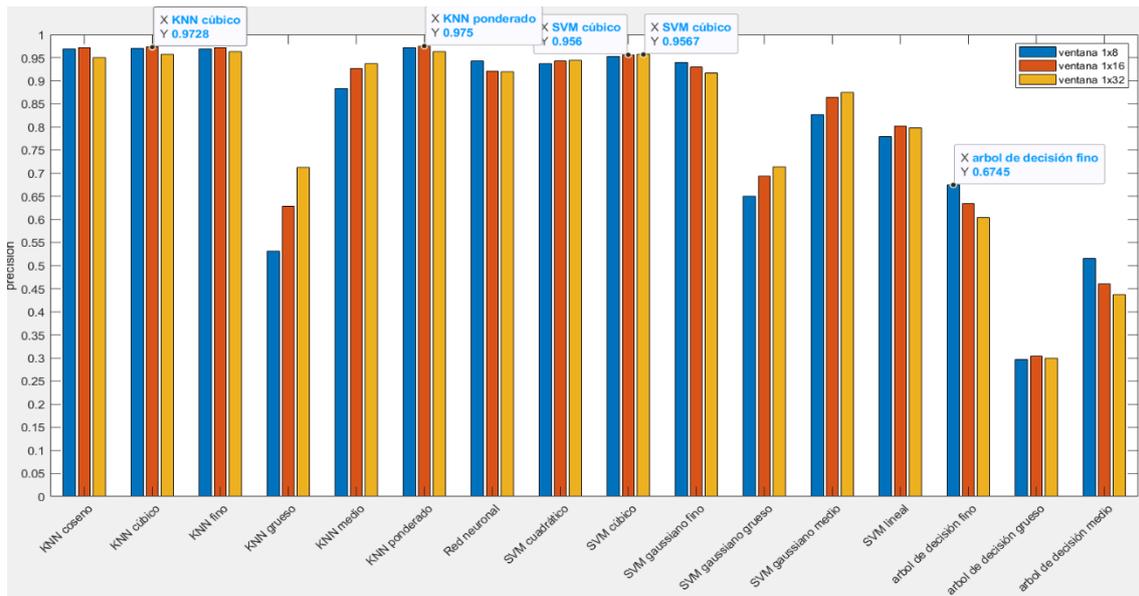
Gráfica 255. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en RGB

En la gráfica 255 los clasificadores no alcanzan su valor máximo en una ventana específica, va cambiando según el clasificador. El clasificador que usando LBP variante a rotación con radio 1 alcanza el valor más alto de la gráfica, es el K-NN fino para ventanas de 16x1 y, el siguiente valor más alto viene por el K-NN ponderado.



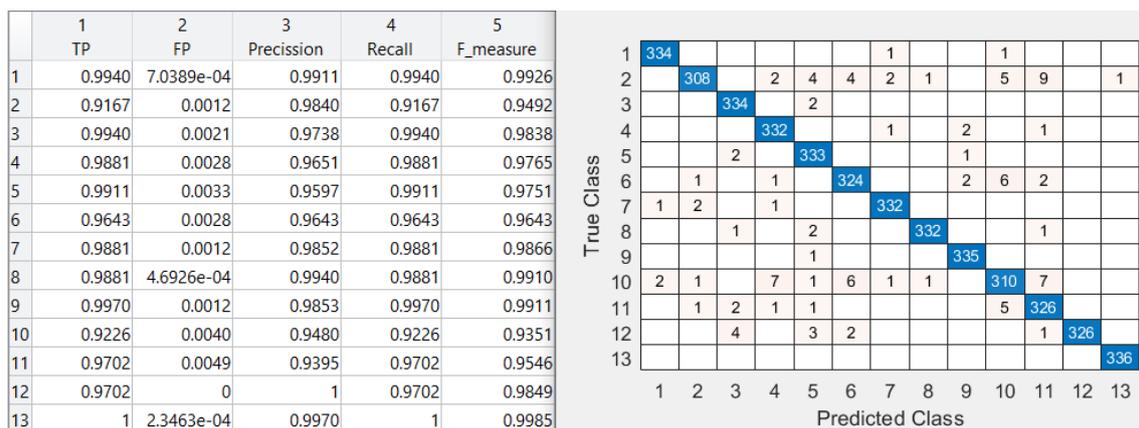
Gráfica 256. Validación del modelo elegido de la gráfica 255

Sacamos del clasificador K-NN fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en RGB para ventanas en filas de la gráfica 256.



Gráfica 257. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en RGB

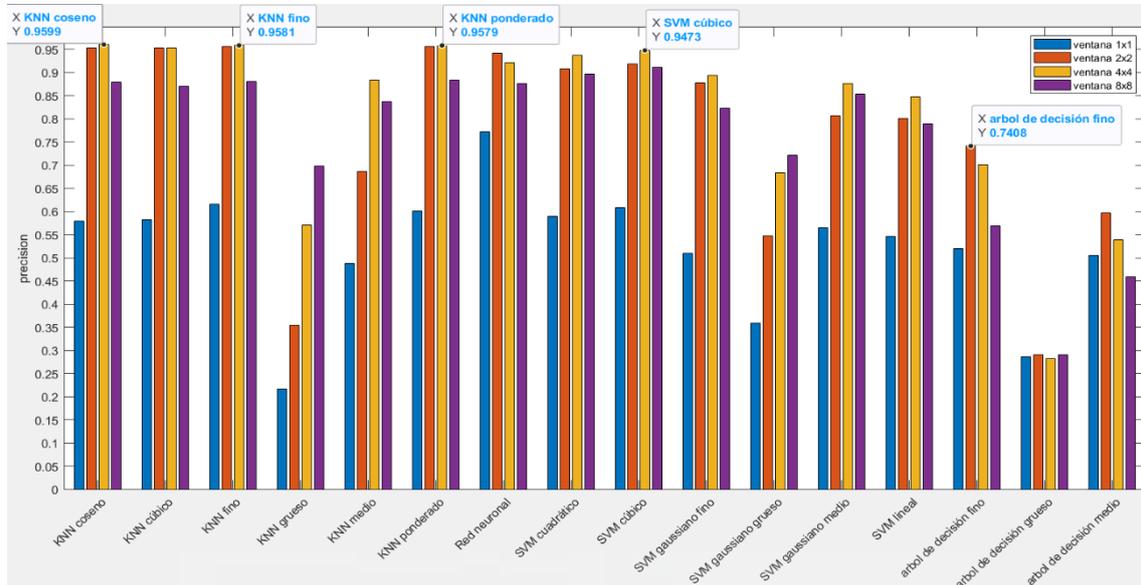
Vemos en la gráfica 257 que al analizar las ventanas en columna para LBP variante a rotación con radio 1 en RGB, los valores de un mismo clasificador en las diferentes ventanas tienen valores cercanos, hay excepciones. El mejor resultado es alcanzado por el clasificador K-NN ponderado para ventana de 1x16 y, el siguiente por el K-NN cúbico para el mismo tamaño de ventana.



Gráfica 258. Validación del modelo elegido de la gráfica 257

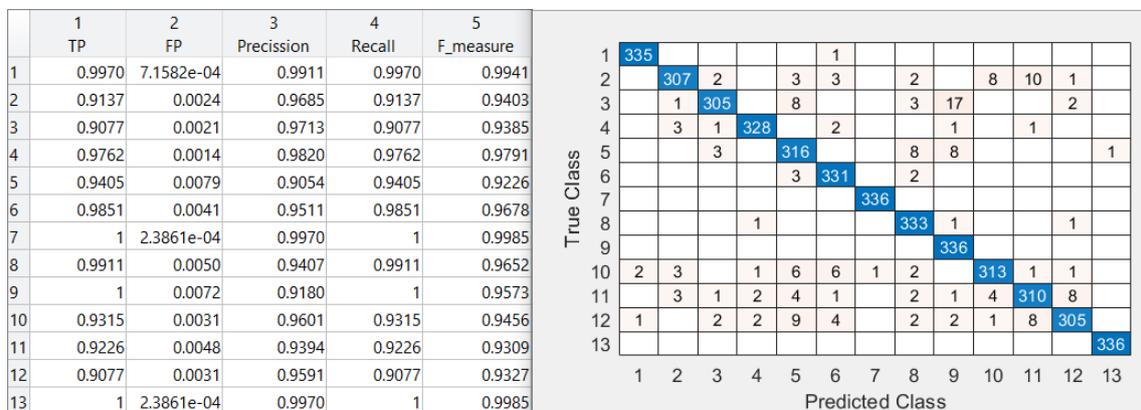
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en RGB para ventanas en columnas, es del clasificador K-NN ponderado de la gráfica 258.

Queda claro que el clasificador K-NN fino es el que mejor resultado ofrece para la ventana 16x1 el de mayor valor para LBP variante a rotación con radio 1 en RGB.



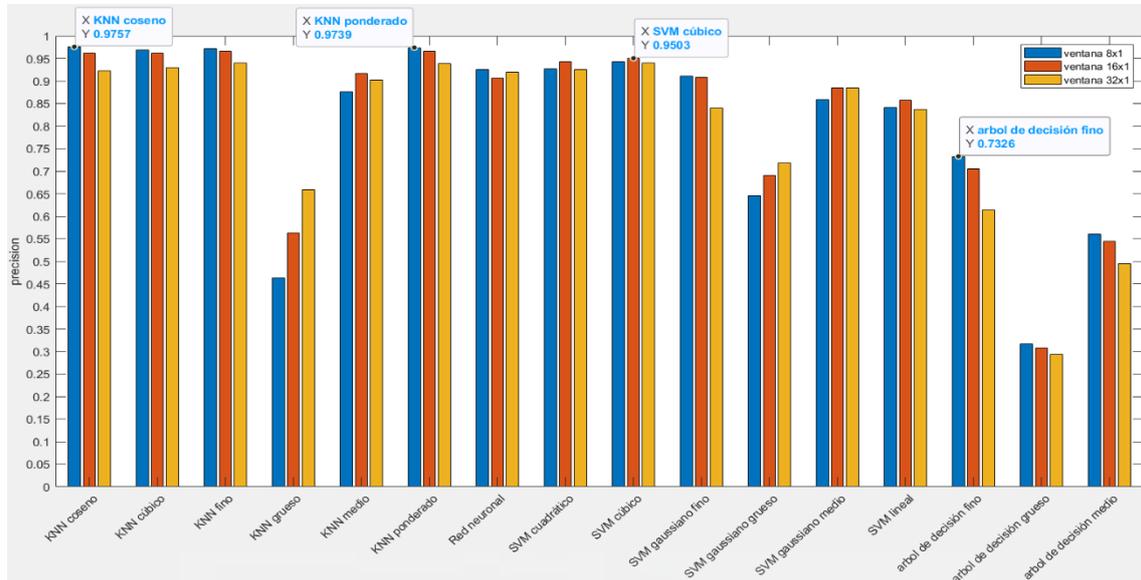
Gráfica 259. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en RGB

En la gráfica 259, usando LBP variante a rotación con radio 3 en RGB los valores más altos en general se encuentran cuando usamos ventanas de 4x4, siendo esta ventana las que se logra la mayor precisión con el clasificador K-NN coseno, seguido de cerca por el K-NN fino y K-NN ponderado para la misma ventana.



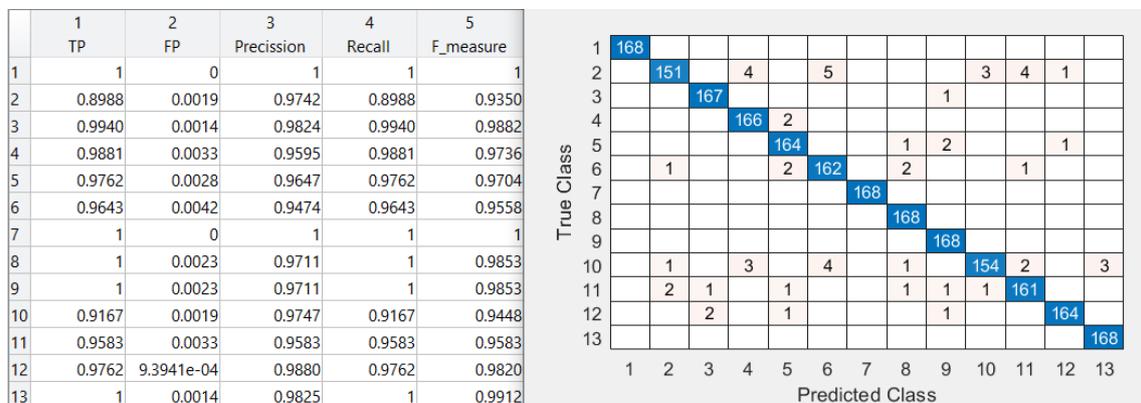
Gráfica 260. Validación del modelo elegido de la gráfica 259

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en RGB para ventanas cuadradas, es del clasificador K-NN coseno de la gráfica 260.



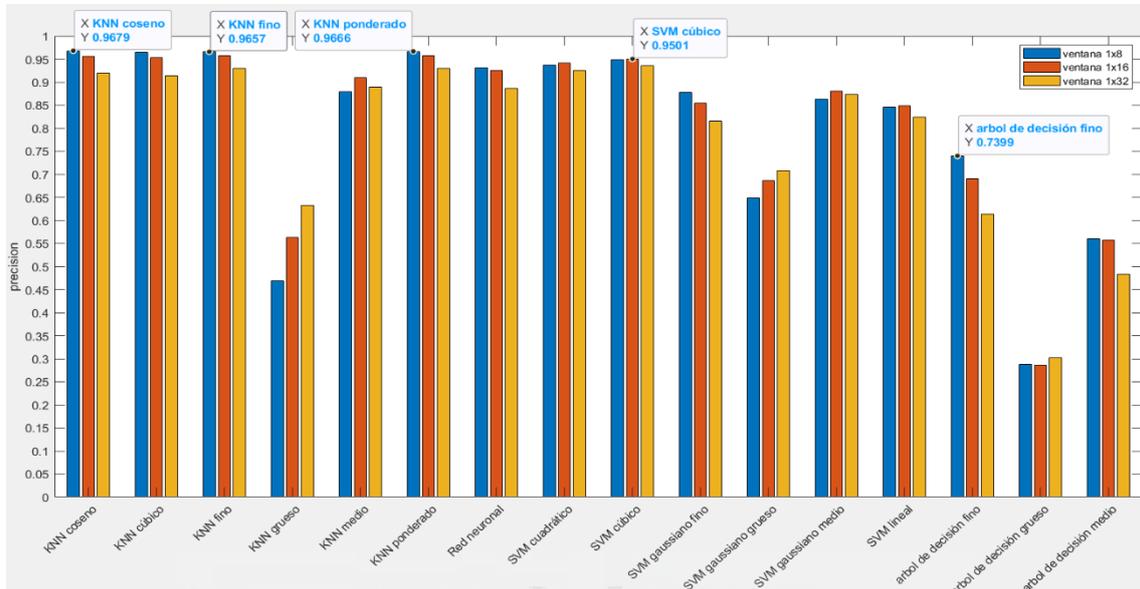
Gráfica 261. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en RGB

Analizando las ventanas en filas para LBP variante a rotación con radio 3 en RGB, vemos en la gráfica 261 que la mayoría de los clasificadores estudiados alcanzan su valor más alto para las ventanas de 8x1, siendo el clasificador K-NN coseno el que alcanza el valor más alto. Cabe destacar que algunos valores de otros clasificadores están muy cerca del valor anterior.



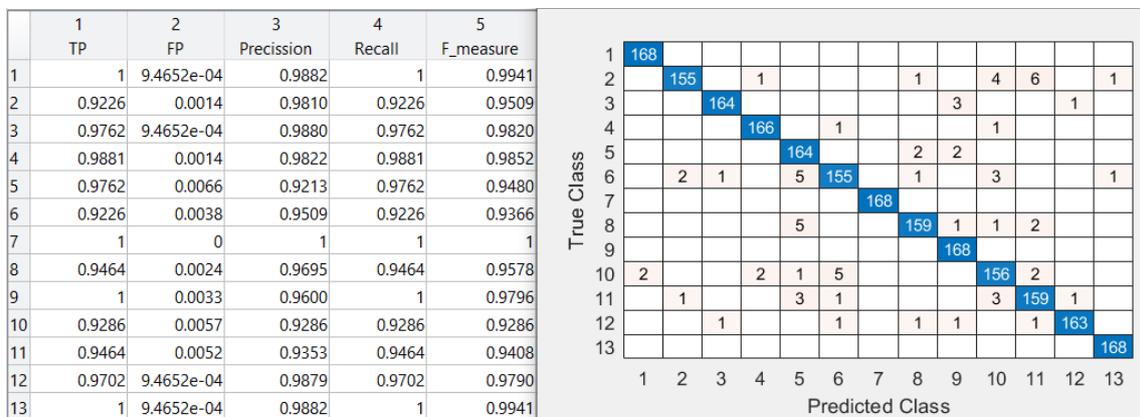
Gráfica 262. Validación del modelo elegido de la gráfica 261

Sacamos del clasificador K-NN coseno esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en RGB para ventanas en filas de la gráfica 262.



Gráfica 263. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en RGB

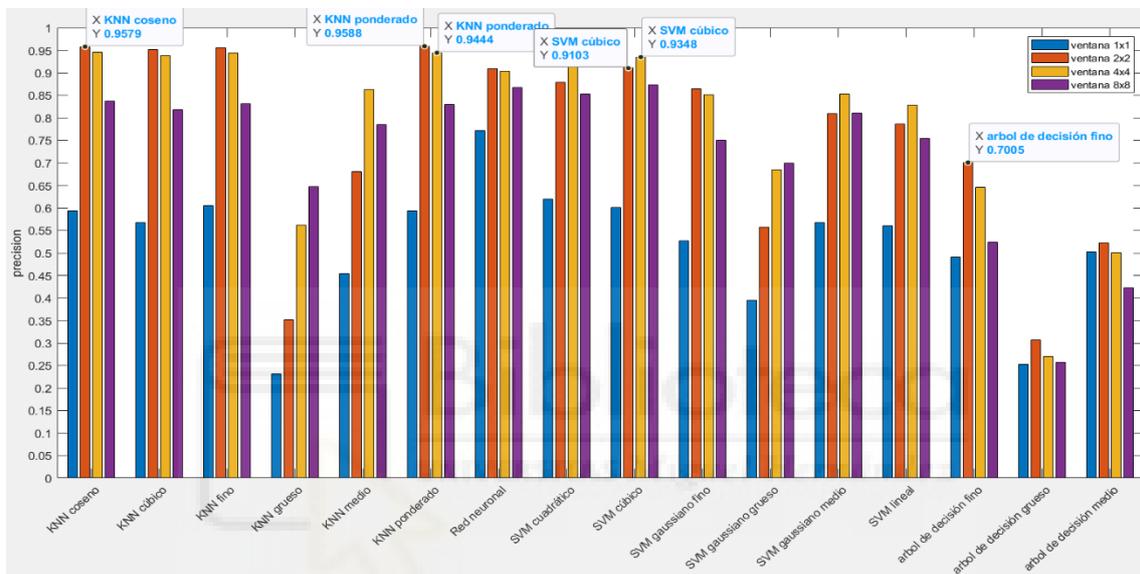
Podemos observar en la gráfica 263 que los resultados más altos usando LBP variante a rotación con radio 3 en RGB se dan cuando usamos las ventanas de 1x8 o 1x16. Es para la primera ventana para la cual alcanzamos el valor máximo con el clasificador K-NN coseno, seguido por el K-NN ponderado para la misma ventana.



Gráfica 264. Validación del modelo elegido de la gráfica 263

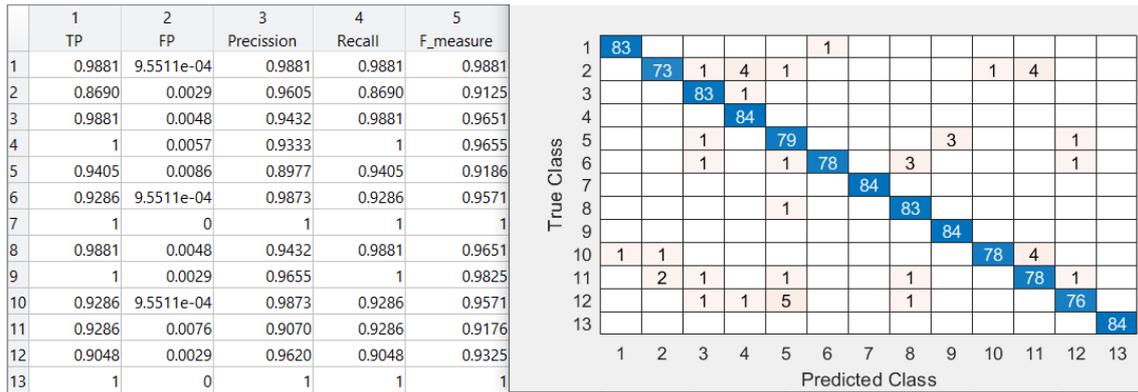
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en RGB para ventanas en columnas, es del clasificador K-NN coseno de la gráfica 264.

Hemos comprobado que para LBP variante a rotación con radio 3 en RGB el clasificador K-NN coseno es el que mejor se comporta, y no solo para un tipo de ventana, siendo la ventana 8x1 la de mejor resultado. Es por eso que se considera este clasificador el mejor para este caso.



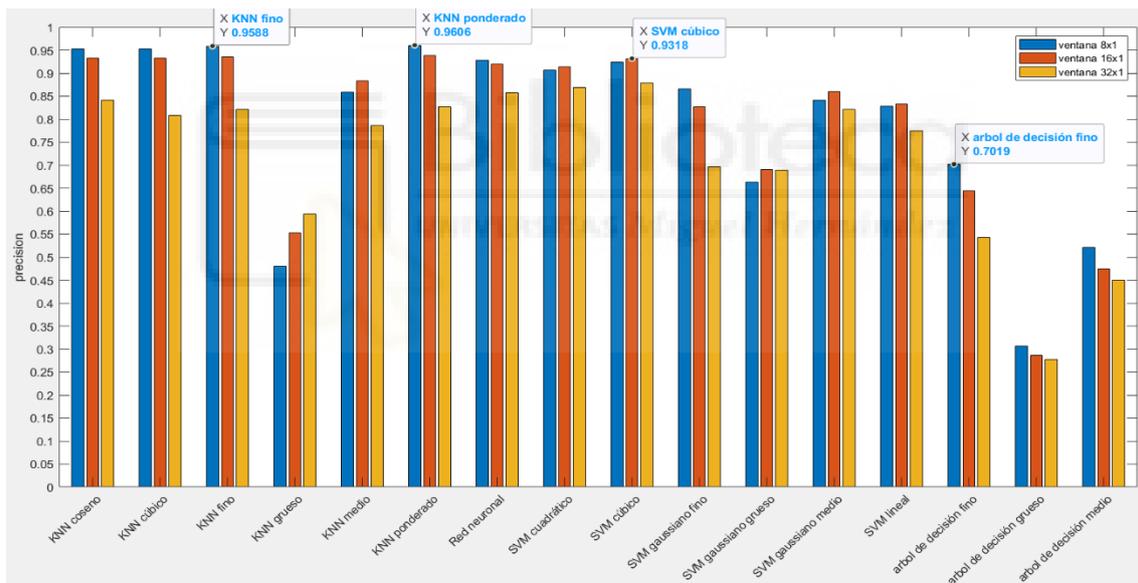
Gráfica 265. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en RGB

Ahora analizaremos en la gráfica 265 para ventanas cuadradas el uso de LBP variante a rotación con radio 5 en RGB, el valor más alto está localizado en la ventana 2x2 del clasificador K-NN ponderado. Hay que mencionar, que este valor máximo es muy cercano al valor ofrecido por otros clasificadores como el K-NN coseno.



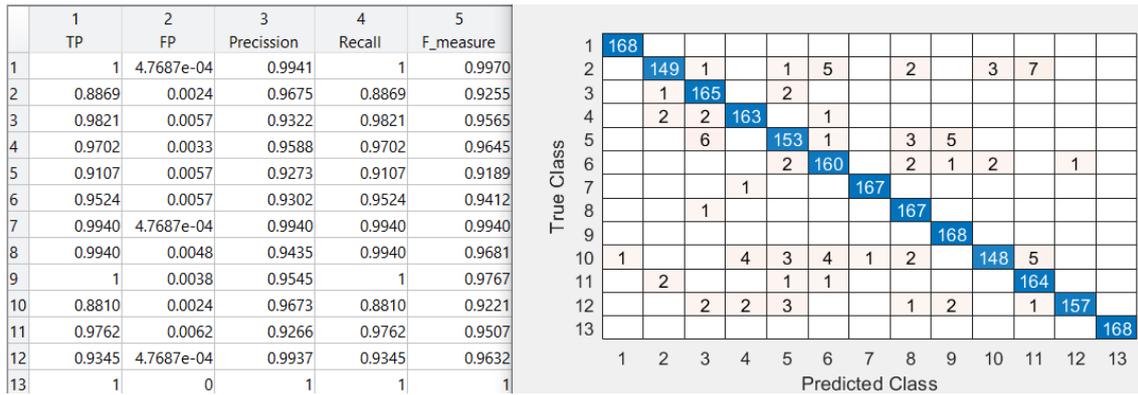
Gráfica 266. Validación del modelo elegido de la gráfica 265

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en RGB para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 266.



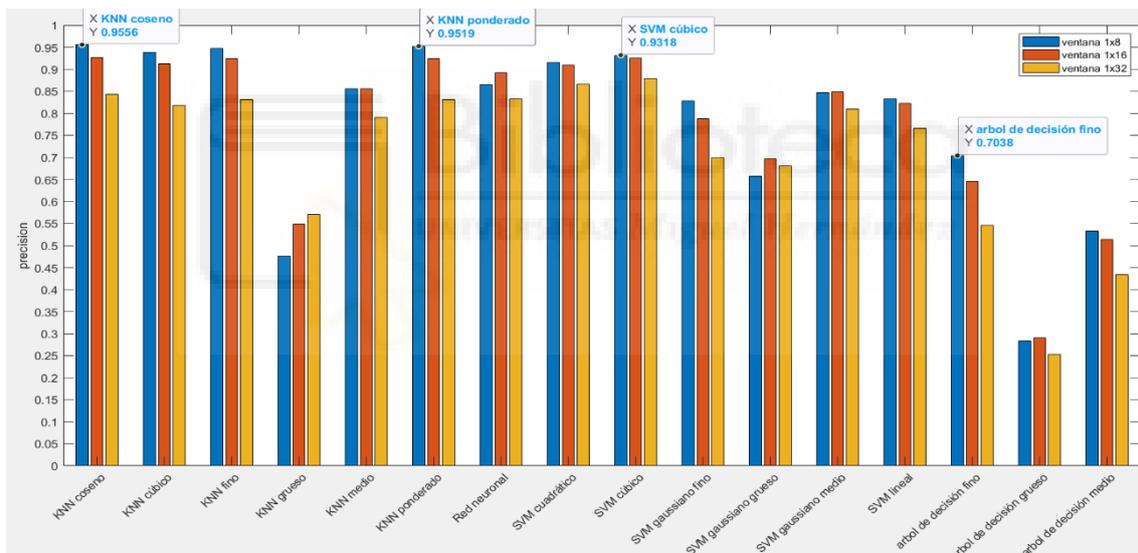
Gráfica 267. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en RGB

En la gráfica 267 el mejor clasificador usando LBP variante a rotación con radio 5 en RGB con ventanas en fila es el K-NN ponderado para ventanas de 8x1, seguido muy de cerca por el K-NN fino para el mismo tamaño de ventana. También, podemos ver como a medida que se disminuye el tamaño de la ventana también disminuye la precisión del clasificador.



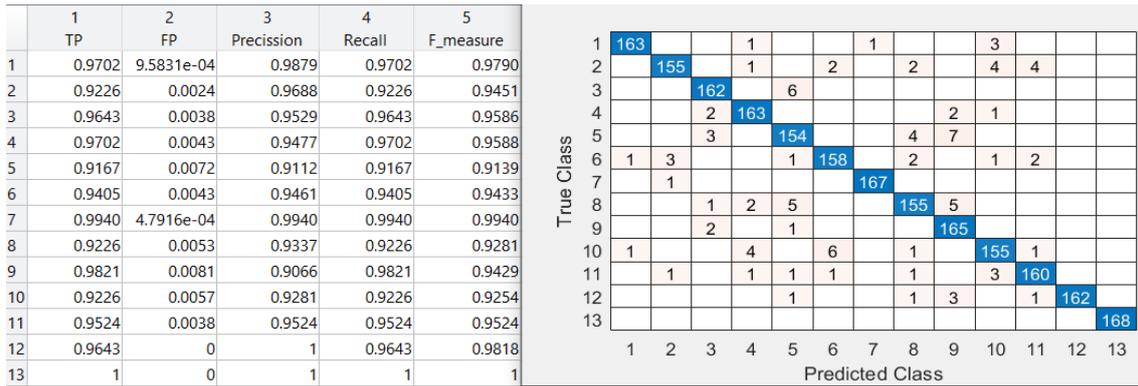
Gráfica 268. Validación del modelo elegido de la gráfica 267

Sacamos del clasificador K-NN ponderado esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en RGB para ventanas en filas de la gráfica 268.



Gráfica 269. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en RGB

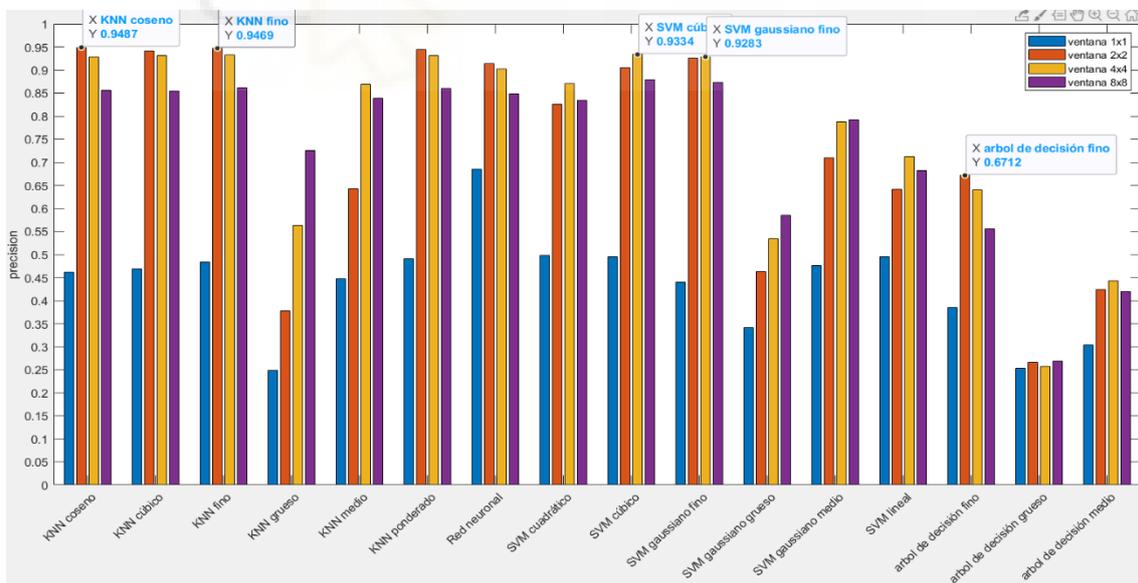
Terminando de analizar el LBP variante a rotación con radio 5 en RGB, vemos en la gráfica 269 que para ventanas en columnas los clasificadores se comportan mejor para el tamaño de 1x8 y conforme este tamaño disminuye, el resultado empeora. El mejor resultado lo encontramos en el clasificador K-NN coseno para la ventana de 1x8.



Gráfica 270. Validación del modelo elegido de la gráfica 269

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en RGB para ventanas en columnas, es del clasificador K-NN coseno de la gráfica 270.

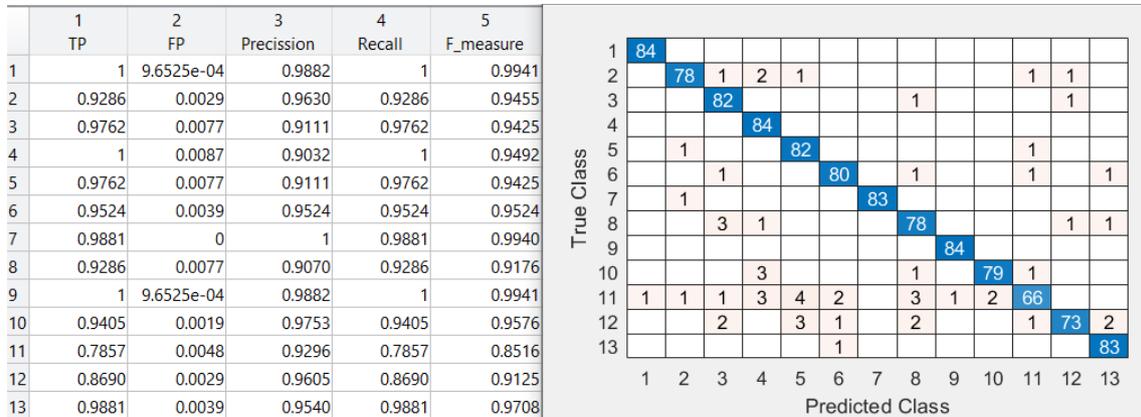
Viendo el comportamiento de los clasificadores usando LBP variante a rotación con radio 5 en RGB, que el clasificador K-NN ponderado es el que por lo general mejor se comporta, y, específicamente, para la ventana de 8x1 es el resultado más alto.



Gráfica 271. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en RGB

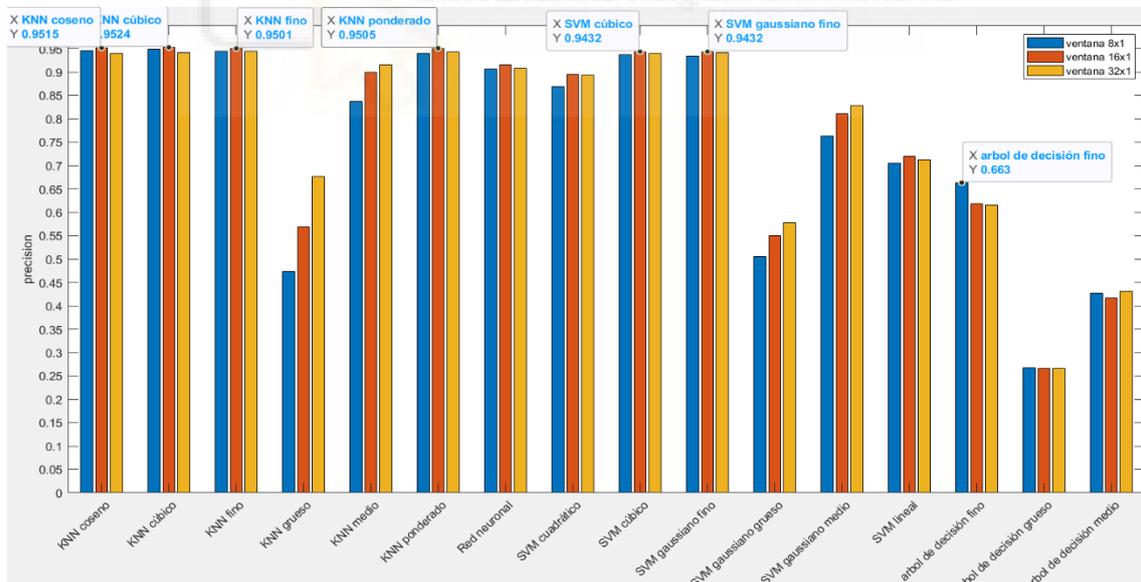
Ahora, usando LBP invariante a rotación con radio 1 en RGB, vemos en la gráfica 271 que no hay una ventana específica donde los clasificadores

alcancen su valor más alto. Entonces, el clasificador K-NN coseno el que mayor precisión alcanza para una ventana de 2x2, seguido muy de cerca del K-NN fino para el mismo tamaño de ventana.



Gráfica 272. Validación del modelo elegido de la gráfica 271

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en RGB para ventanas cuadradas, es del clasificador K-NN coseno de la gráfica 272.



Gráfica 273. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en RGB

En muchos clasificadores vemos en la gráfica 273 que los valores en cada ventana son muy parecidos entre sí. Por eso, el clasificador que usando LBP

invariante a rotación con radio 1 en RGB tiene la mayor precisión dista muy poco del mismo clasificador, pero para otra ventana. El K-NN cúbico para ventana de 16x1 es el de mayor precisión y, seguido muy de cerca, el K-NN coseno para ventanas de 16x1 es el siguiente.

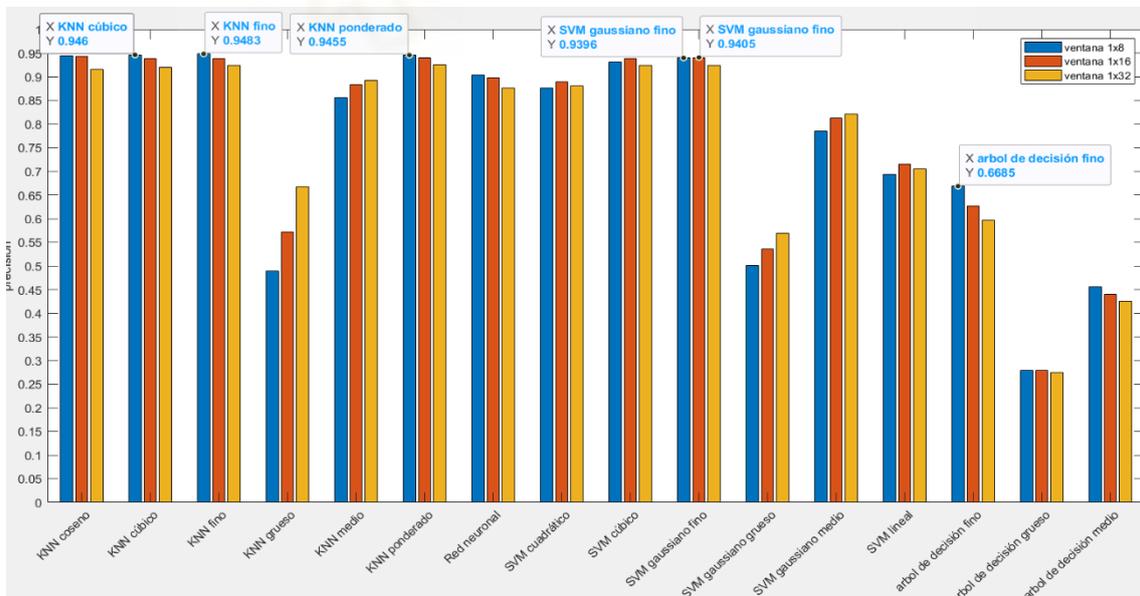
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	1	9.6131e-04	0.9882	1	0.9941
2	0.8690	0.0029	0.9605	0.8690	0.9125
3	0.9375	0.0055	0.9320	0.9375	0.9347
4	0.9821	0.0017	0.9792	0.9821	0.9807
5	0.9583	0.0072	0.9148	0.9583	0.9360
6	0.9762	0.0036	0.9563	0.9762	0.9661
7	0.9792	0.0031	0.9620	0.9792	0.9705
8	0.9494	0.0103	0.8812	0.9494	0.9140
9	0.9851	0.0012	0.9851	0.9851	0.9851
10	0.9345	0.0022	0.9721	0.9345	0.9530
11	0.8988	0.0060	0.9235	0.8988	0.9110
12	0.9167	0.0034	0.9565	0.9167	0.9362
13	0.9970	0.0017	0.9795	0.9970	0.9882

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	336												
2		292	5	1	5	4	10	2	1	6	6	1	1
3		1	315		1			10	2		1	6	
4				330		2		1	1		2		
5			2	1	322			8				3	
6			1			328			1	3	2	1	
7	1	5					329		1				
8			2	1	10			319	1		2		1
9			3	1				1	331				
10	1	2	2	2	4	1	3			314	7		
11		4		1	6	7		12	1		302	2	1
12			8	4	1			8			4	308	3
13								1					335

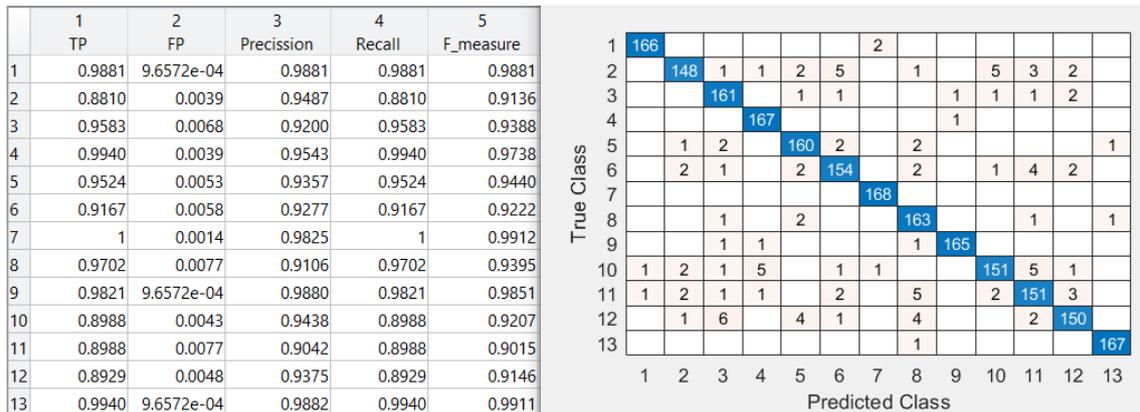
Gráfica 274. Validación del modelo elegido de la gráfica 273

Sacamos del clasificador K-NN cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en RGB para ventanas en filas de la gráfica 274.



Gráfica 275. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en RGB

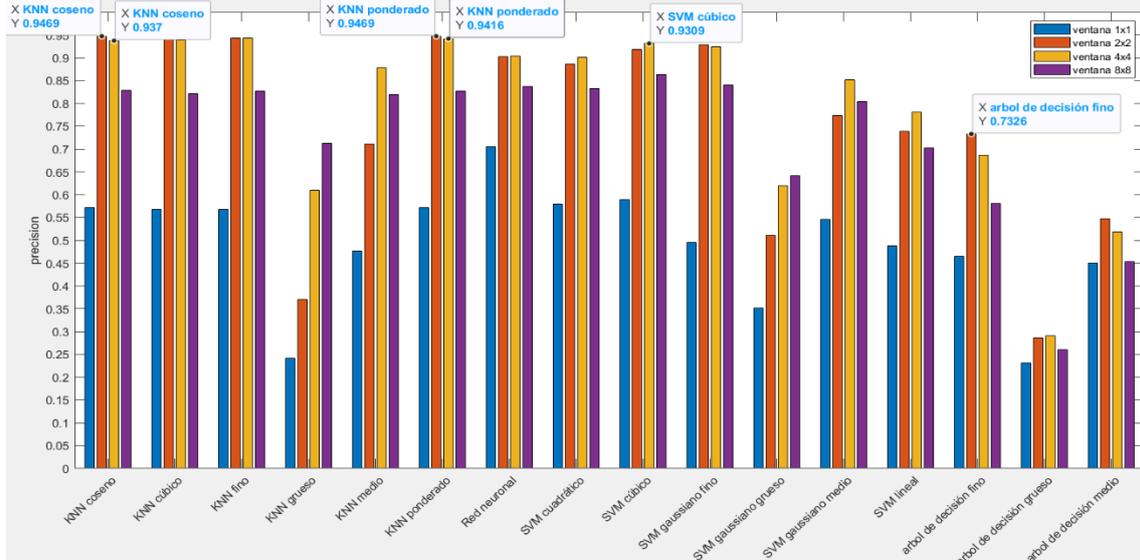
Generalmente en la gráfica 275, los clasificadores tienen su mejor resultado para ventana de 1x8, pero la diferencia con los valores de las otras ventanas tampoco es muy grande. Por ello, usando LBP invariante a rotación con radio 1 en RGB, el clasificador K-NN fino con ventana de 1x8 es el que mejor resultado proporciona.



Gráfica 276. Validación del modelo elegido de la gráfica 275

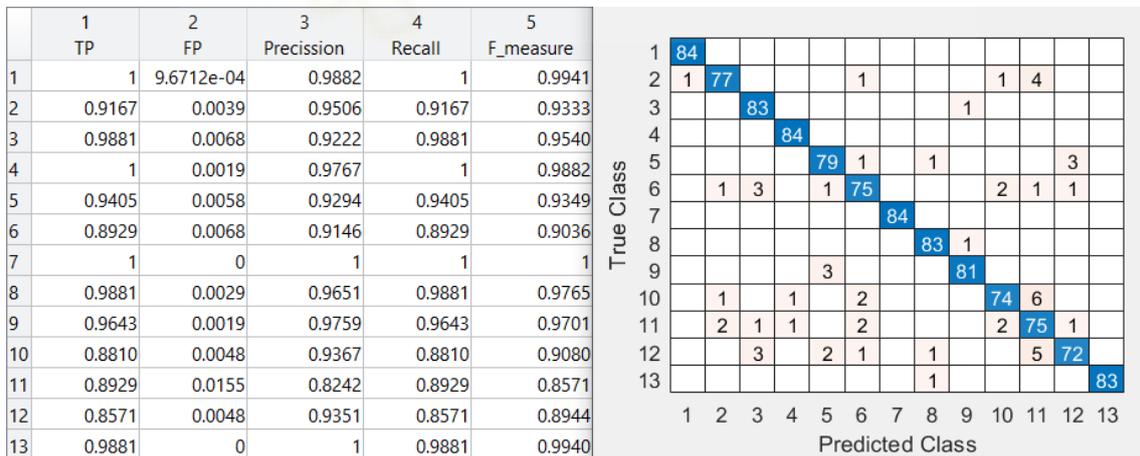
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en RGB para ventanas en columnas, es del clasificador K-NN fino de la gráfica 276.

Una vez vistas las tres graficas (gráfica 271, 273 y 275) usando LBP invariante a rotación con radio 1 en RGB el clasificador K-NN cúbico para ventanas de 16x1 es el que mejor resultado nos ofrece objetivamente, pero cabe destacar el K-NN fino se ha comportado muy bien en las distintas ventanas.



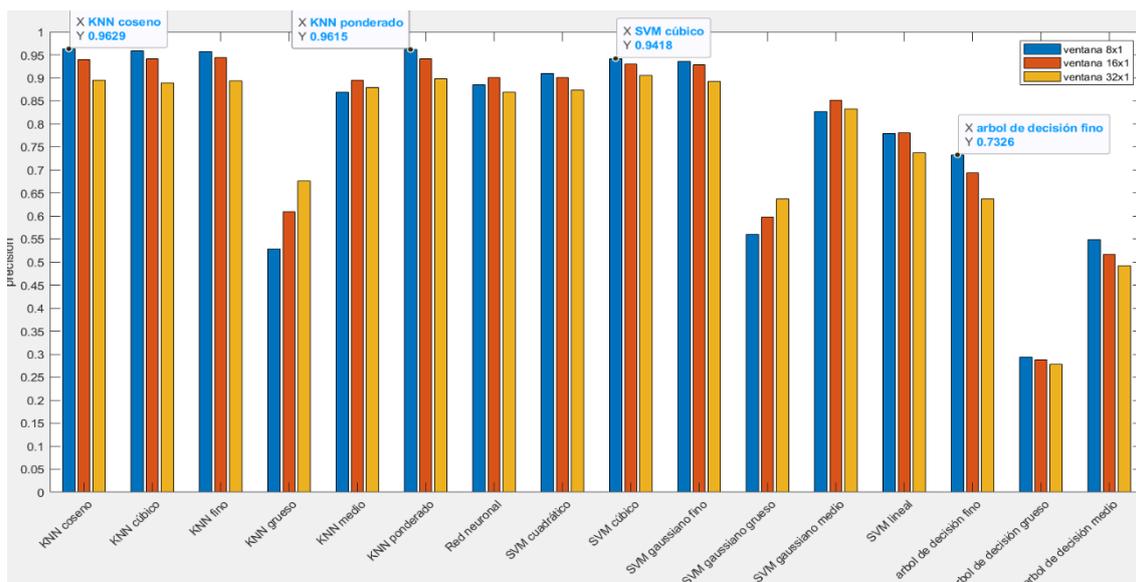
Gráfica 277. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en RGB

En la gráfica 277 con LBP invariante a rotación con radio 3 en RGB, tanto el clasificador K-NN coseno como el K-NN ponderado alcanzan la misma y más alta precisión de toda la gráfica, ambos para la ventana de 2x2 y los valores de estos mismos clasificadores para ventana 4x4 no distan mucho de los anteriores.



Gráfica 278. Validación del modelo elegido de la gráfica 277

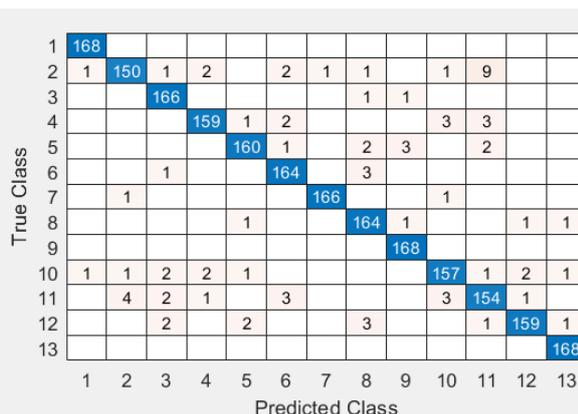
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en RGB para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 278.



Gráfica 279. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en RGB

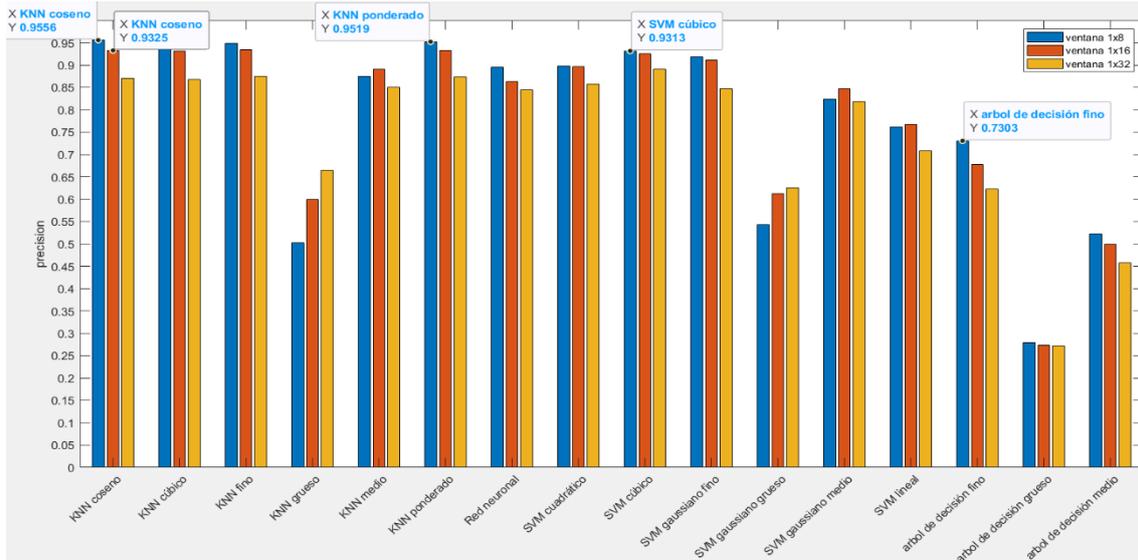
Podemos observar en la gráfica 279 que los mejores resultados, de la mayoría de los clasificadores, aparece cuando usamos ventanas de 8x1 y, a medida que este tamaño decrece, también lo hace la precisión. El mejor resultado viene por el clasificador K-NN coseno para ventana de 8x1, sin embargo, el K-NN ponderado para ventana de 8x1 tiene un valor también muy elevado y cercano al anterior.

	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	1	9.5102e-04	0.9882	1	0.9941
2	0.8929	0.0029	0.9615	0.8929	0.9259
3	0.9881	0.0038	0.9540	0.9881	0.9708
4	0.9464	0.0024	0.9695	0.9464	0.9578
5	0.9524	0.0024	0.9697	0.9524	0.9610
6	0.9762	0.0038	0.9535	0.9762	0.9647
7	0.9881	4.7551e-04	0.9940	0.9881	0.9910
8	0.9762	0.0048	0.9425	0.9762	0.9591
9	1	0.0024	0.9711	1	0.9853
10	0.9345	0.0038	0.9515	0.9345	0.9429
11	0.9167	0.0076	0.9059	0.9167	0.9112
12	0.9464	0.0019	0.9755	0.9464	0.9607
13	1	0.0014	0.9825	1	0.9912



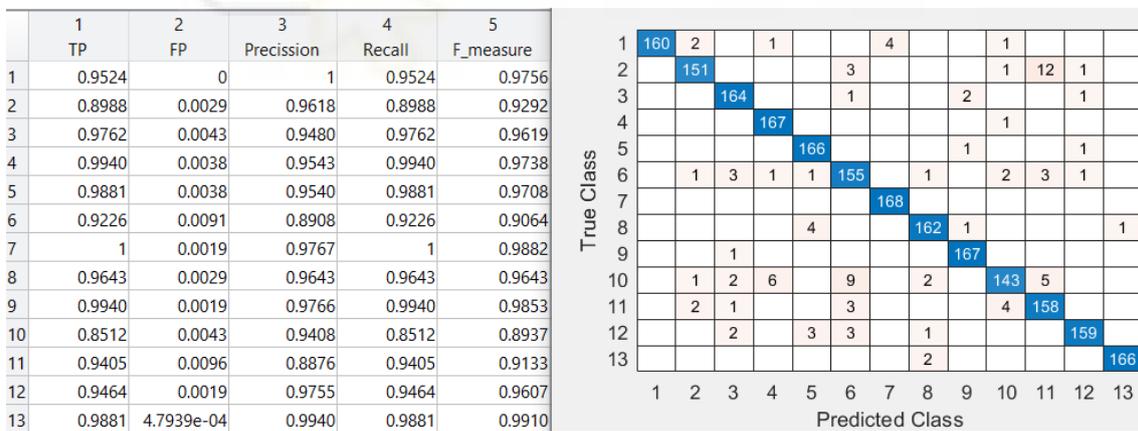
Gráfica 280. Validación del modelo elegido de la gráfica 279

Sacamos del clasificador K-NN coseno esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en RGB para ventanas en filas de la gráfica 280.



Gráfica 281. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en RGB

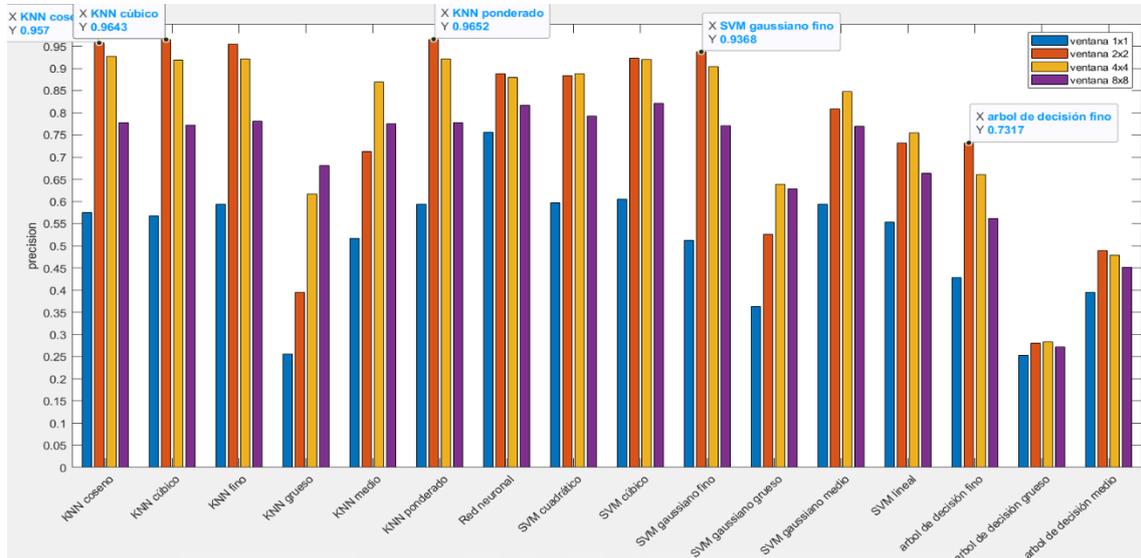
En la gráfica 281 para LBP invariante a rotación con radio 3 en RGB, la ventana de 1x8 es la que provoca los mejores resultados de muchos clasificadores y, conforme la ventana se hace más pequeña, la precisión disminuye. El que mejor resultado ofrece en este caso es el K-NN coseno con ventana de 1x8.



Gráfica 282. Validación del modelo elegido de la gráfica 281

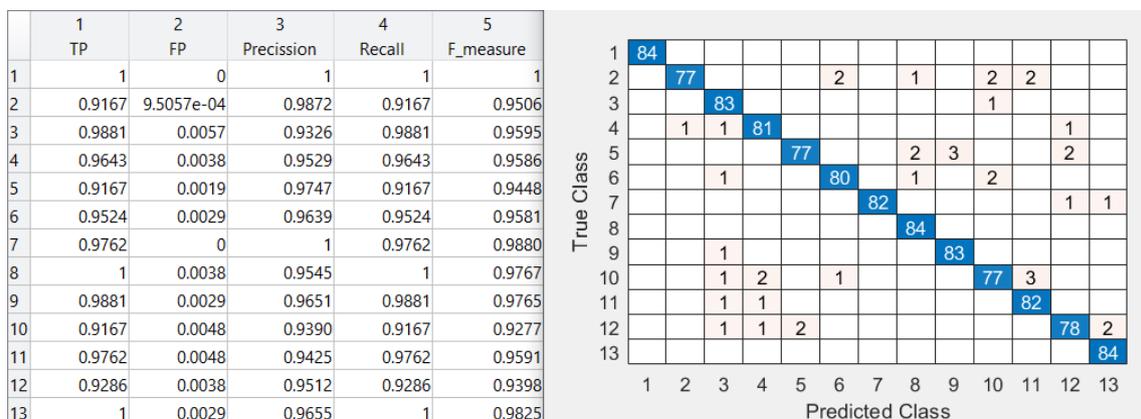
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en RGB para ventanas en columnas, es del clasificador K-NN coseno de la gráfica 282.

Una vez visto todos los resultados usando LBP invariante a rotación con radio 3 en RGB, el clasificador K-NN coseno es el que mejores resultados ha ofrecido en los tres casos, siendo el mayor de todos para ventana de 8x1.



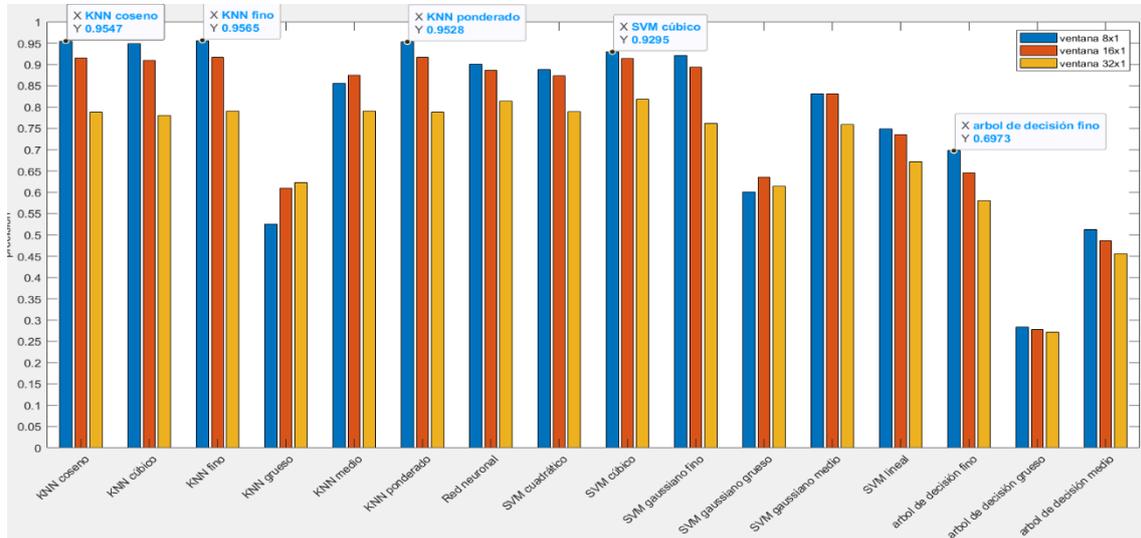
Gráfica 283. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en RGB

Continuando con LBP invariante a rotación con radio 5 en RGB, vemos en la gráfica 283 que no hay ninguna ventana cuadrada en la que todos los clasificadores adquieren su mayor valor. El valor más alto viene por parte del clasificador K-NN ponderado con ventana de 2x2, y el siguiente valor más alto también es con esta ventana, pero con el clasificador K-NN cúbico.



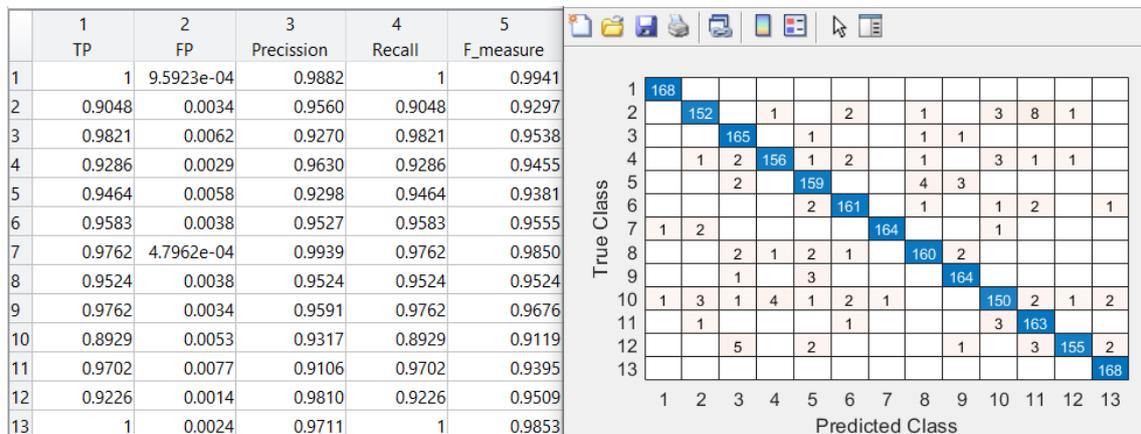
Gráfica 284. Validación del modelo elegido de la gráfica 283

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en RGB para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 284.



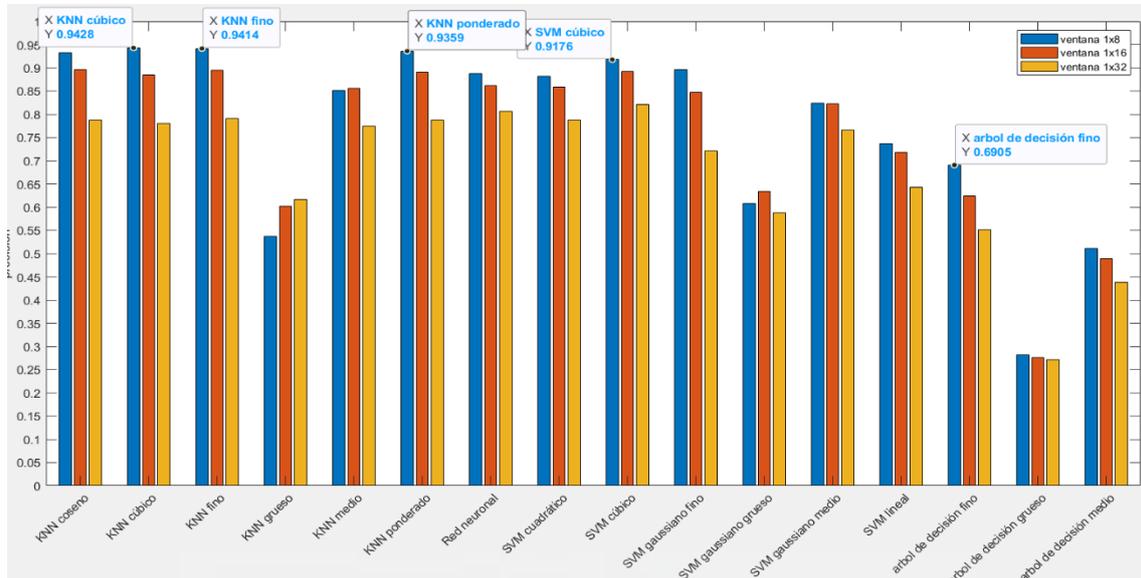
Gráfica 285. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en RGB

En la gráfica 285 la ventana de 8x1 es la que consigue el mejor resultado en la mayoría de los clasificadores usando LBP invariante a rotación con radio 5 en RGB y, si la ventana cambia su tamaño a uno menor la precisión se ve reducida. El mejor clasificador es el K-NN fino para ventana de 8x1, pero para esta misma ventana el K-NN coseno también proporciona un resultado muy similar.



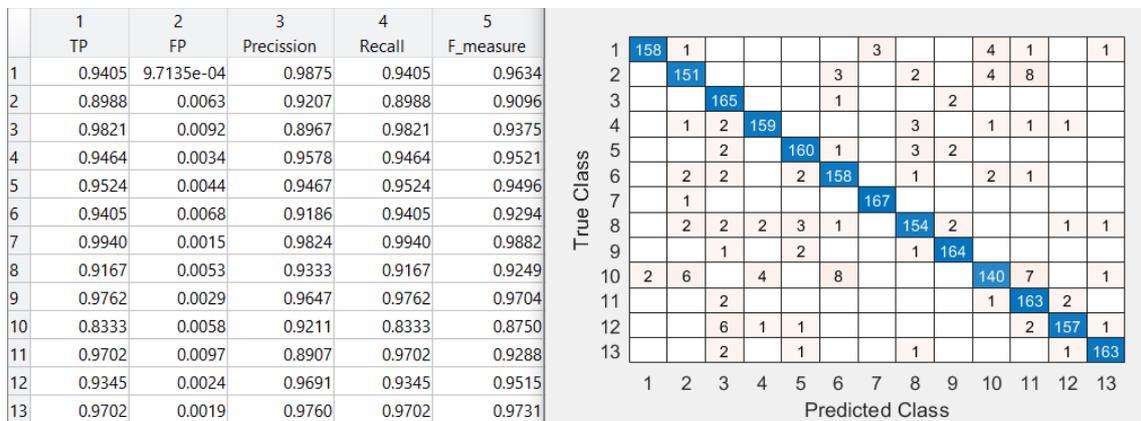
Gráfica 286. Validación del modelo elegido de la gráfica 285

Sacamos del clasificador K-NN fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en RGB para ventanas en filas de la gráfica 286.



Gráfica 287. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en RGB

En la gráfica 287 el mejor resultado nos lo da el clasificador K-NN cúbico para ventana de 1x8 usando LBP invariante a rotación con radio 5 en RGB. También hay que mencionar que el K-NN fino tiene un valor semejante usando el mismo tamaño de ventana. Por último, es apreciable que a medida que la ventana se hace más pequeña la precisión también se reduce.

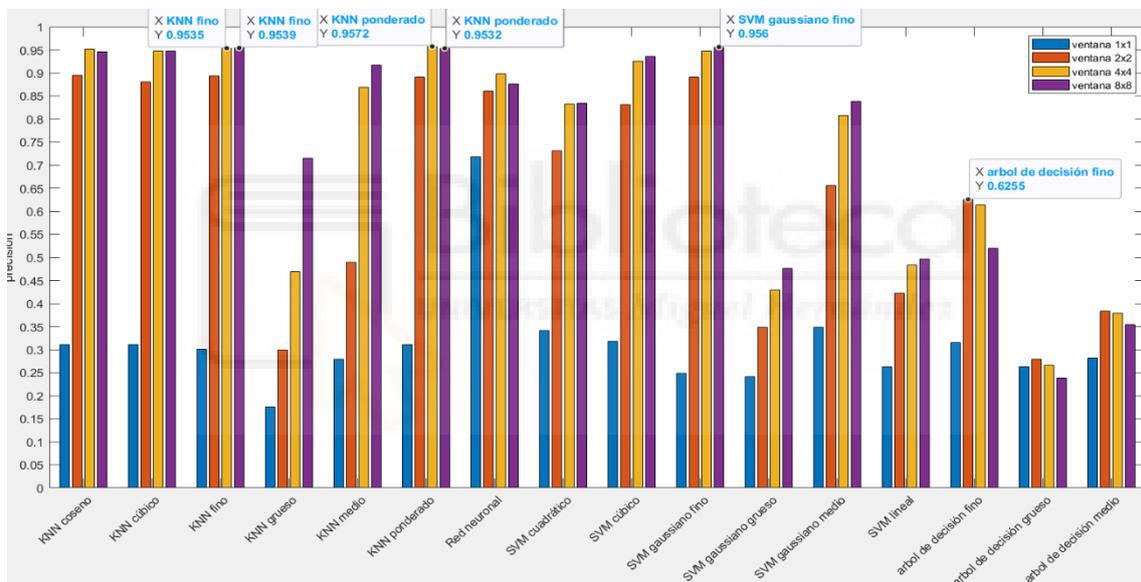


Gráfica 288. Validación del modelo elegido de la gráfica 287

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en RGB para ventanas en columnas, es del clasificador K-NN cúbico de la gráfica 288.

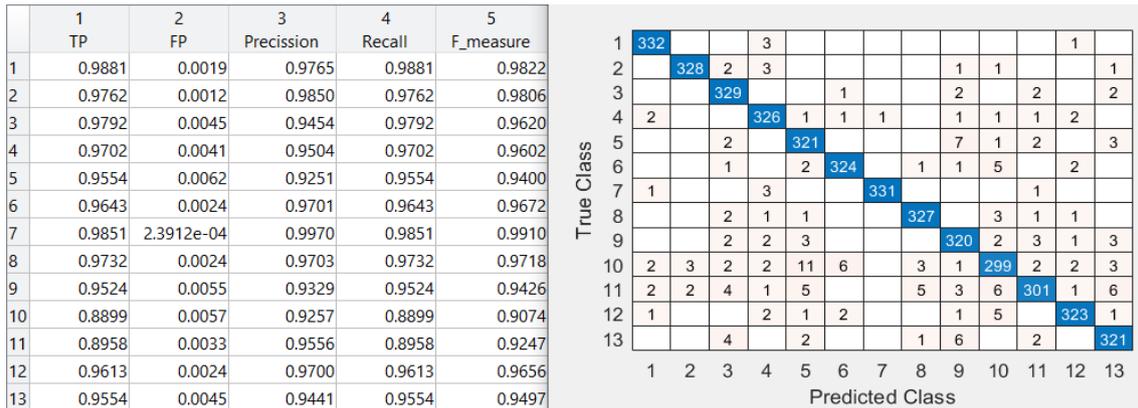
Visto los resultados anteriores, el clasificador K-NN cúbico es el que mejor se comporta usando LBP invariante a rotación con radio 5 en RGB y una ventana de 2x2. Pero se debe mencionar que el clasificador K-NN fino siempre ha tenido unos buenos resultados en general.

### 4.1.7 Comparación en colores opuestos con el tercer data set



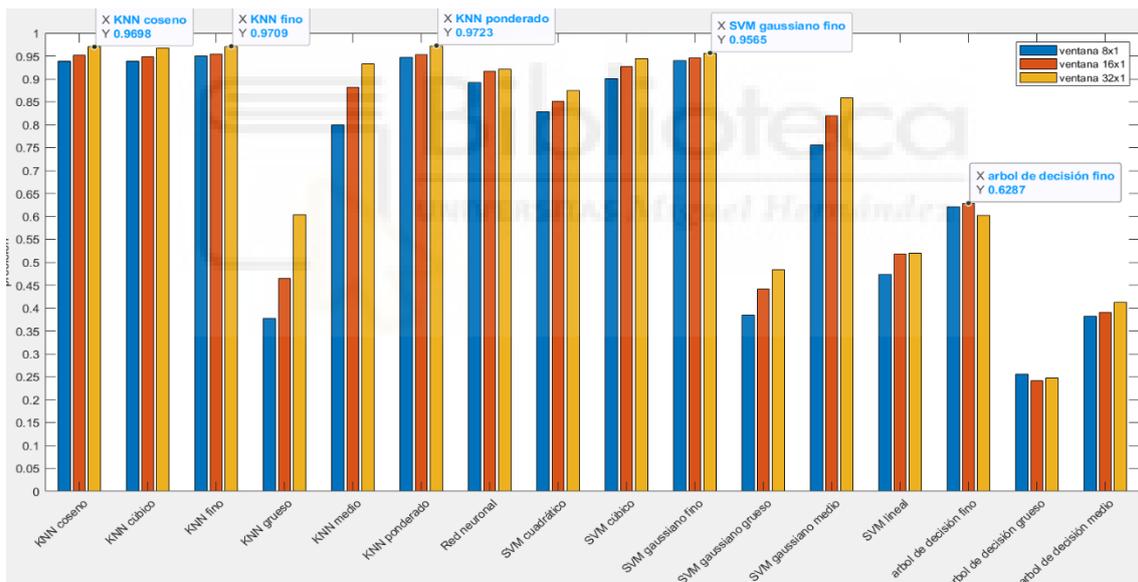
Gráfica 289. Comparación clasificadores para ventanas cuadradas para momentos de histograma en colores opuestos

En la gráfica 289, usando los momentos de histograma en colores opuestos para ventanas cuadradas vemos que el mejor resultado de cada clasificador varía entre la ventana de 4x4 y la de 8x8. También se puede observar que resultado más alto viene por parte del clasificador K-NN ponderado en ventana de 4x4, pero el valor es prácticamente el mismo para una ventana de 8x8 del mismo clasificador y del SVM gaussiano fino.



Gráfica 290. Validación del modelo elegido de la gráfica 289

Esta representación de la matriz de confusión y las tasas de acierto y error, para momentos de histograma en colores opuestos para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 290.



Gráfica 291. Comparación clasificadores para ventanas en filas para momentos de histograma en colores opuestos

En la gráfica 291, siguiendo con el análisis en ventanas en filas, vemos que el K-NN ponderado para ventanas de 32x1 es el que mejor precisión tiene usando momentos de histograma en colores opuestos. También vemos que los mejores resultados de los clasificadores, generalmente, se produce en las ventanas de 32x1.

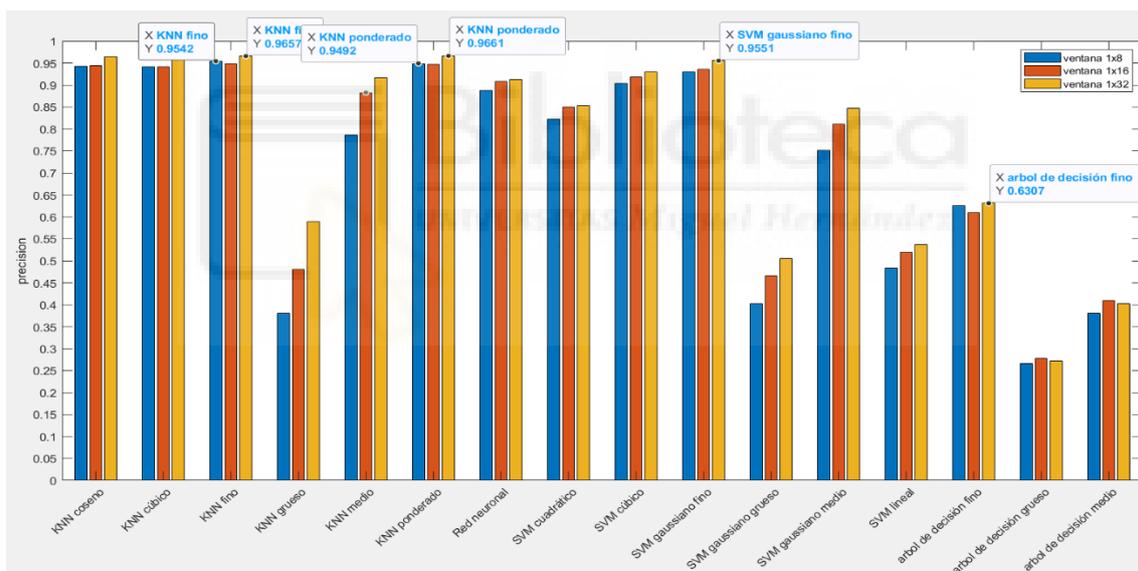
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9568	0.0146	0.8405	0.9568	0.8949
2	0.9643	0.0017	0.9789	0.9643	0.9715
3	0.9583	0.0020	0.9743	0.9583	0.9662
4	0.9688	0.0035	0.9574	0.9688	0.9630
5	0.9658	0.0023	0.9716	0.9658	0.9687
6	0.9568	0.0026	0.9669	0.9568	0.9619
7	0.9792	3.5800e-04	0.9955	0.9792	0.9872
8	0.9583	0.0039	0.9513	0.9583	0.9548
9	0.9732	0.0029	0.9646	0.9732	0.9689
10	0.9375	0.0012	0.9844	0.9375	0.9604
11	0.9375	0.0032	0.9589	0.9375	0.9481
12	0.9568	0.0016	0.9802	0.9568	0.9684
13	0.9568	0.0027	0.9655	0.9568	0.9611

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	643	2	1	4	1	2		6	2	1	5	2	3
2	7	648		5		1	1	2		2	4	1	1
3	13		644	1		1		2	2		4		5
4	6	4		651		3	2		1		2	1	2
5	10		1	1	649	2			1	1		3	2
6	7	2	2	6	1	643		3	2	2	1	1	2
7	11	1		1			658					1	
8	10	2	2	2	2	1		644	4	1	1	2	1
9	7		1	2				3	654		2	1	2
10	12	1	1	3	6	7		3	5	630	1	1	2
11	14	2	7	2	1	3		8	1	1	630	2	1
12	13			2	3	2		4	3		1	643	2
13		2			5			1	3	3	2		643

Gráfica 292. Validación del modelo elegido de la gráfica 291

Usaremos el clasificador con más precisión, el K-NN ponderado, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en colores opuestos para ventanas en fila de la gráfica 292.



Gráfica 293. Comparación clasificadores para ventanas en columnas para momentos de histograma en colores opuestos

Vemos que el clasificador que más precisión tiene, usando momentos de histograma en colores opuestos, es el K-NN ponderado para ventana de 1x32, seguido muy de cerca por el K-NN fino para ventana de 1x32. Generalmente en la gráfica 293, es en esta ventana en la que los distintos clasificadores alcanzan un valor más alto respecto de las otras ventanas.

	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9152	0.0108	0.8723	0.9152	0.8932
2	0.9688	0.0023	0.9716	0.9688	0.9702
3	0.9643	0.0033	0.9586	0.9643	0.9614
4	0.9688	0.0036	0.9559	0.9688	0.9623
5	0.9702	0.0030	0.9631	0.9702	0.9666
6	0.9375	0.0043	0.9459	0.9375	0.9417
7	0.9821	0.0016	0.9807	0.9821	0.9814
8	0.9702	0.0018	0.9775	0.9702	0.9739
9	0.9821	0.0020	0.9749	0.9821	0.9785
10	0.8750	0.0048	0.9363	0.8750	0.9046
11	0.9524	0.0029	0.9639	0.9524	0.9581
12	0.9866	0.0019	0.9764	0.9866	0.9815
13	0.9807	0.0017	0.9792	0.9807	0.9799

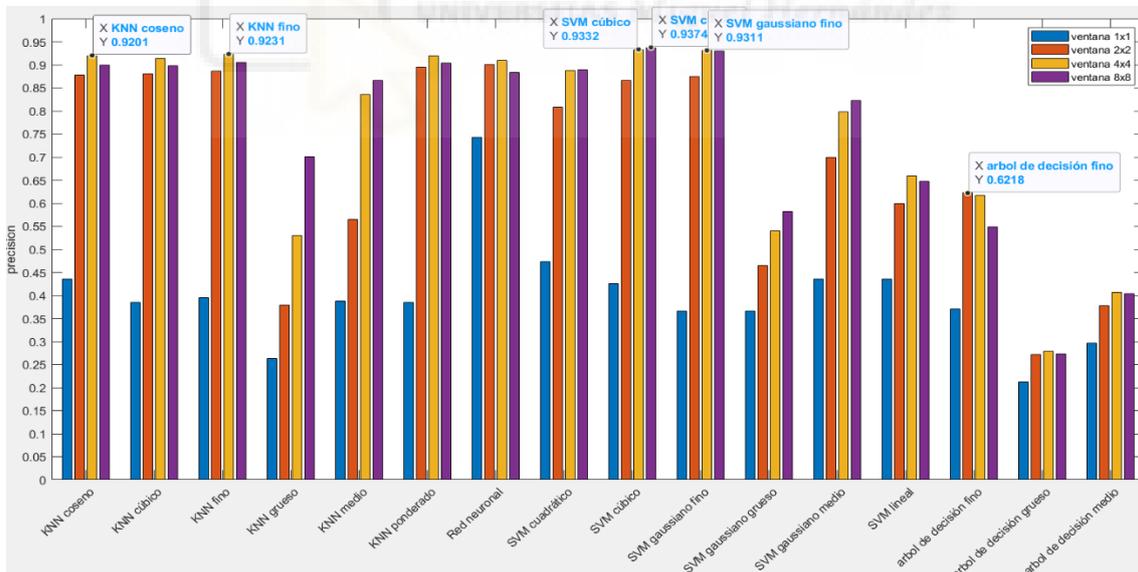
  

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	615	7	4	18	2	2	8	6		5	3	1	1
2	11	651	1			1				3	3	1	1
3	7		648		6	1	2			2	1		5
4	8	2		651	1	4	1		2	1	2		
5	6	1	3		652				1	4	2	1	2
6	8	3	1	1	2	630	1	6	4	11		3	2
7	11		1			660							
8	6			1	1	7		652	1	3		1	
9	5		2	1		1		660	1				2
10	12	2	9	4	9	17	1	3	6	588	12	9	
11	10	2	5	4	3	1			6	640		1	
12	3	1		1					1	3		663	
13	3	1	2		1	2			2	1	1		659

Gráfica 294. Validación del modelo elegido de la gráfica 293

Usaremos el clasificador con más precisión, el K-NN ponderado, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en colores opuestos para ventanas en columna de la gráfica 294.

Después de ver todas las gráficas, el clasificador K-NN ponderado para ventanas de 32x1 es el que mayor precisión nos da, y en general para los tres tipos de ventana es el que mejor se comporta.



Gráfica 295. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en colores opuestos

Generalmente en la gráfica 295, obtenemos el mayor valor en las ventanas de 2x2. Sin embargo, usando la matriz de coocurrencia en colores opuestos, el clasificador SVM cúbico para la ventana de 8x8 es el que mejor resultado nos

ofrece, sin embargo, cabe destacar que para el mismo clasificador usando ventanas 4x4 el valor es muy próximo al anterior, al igual que con el SVM gaussiano fino.

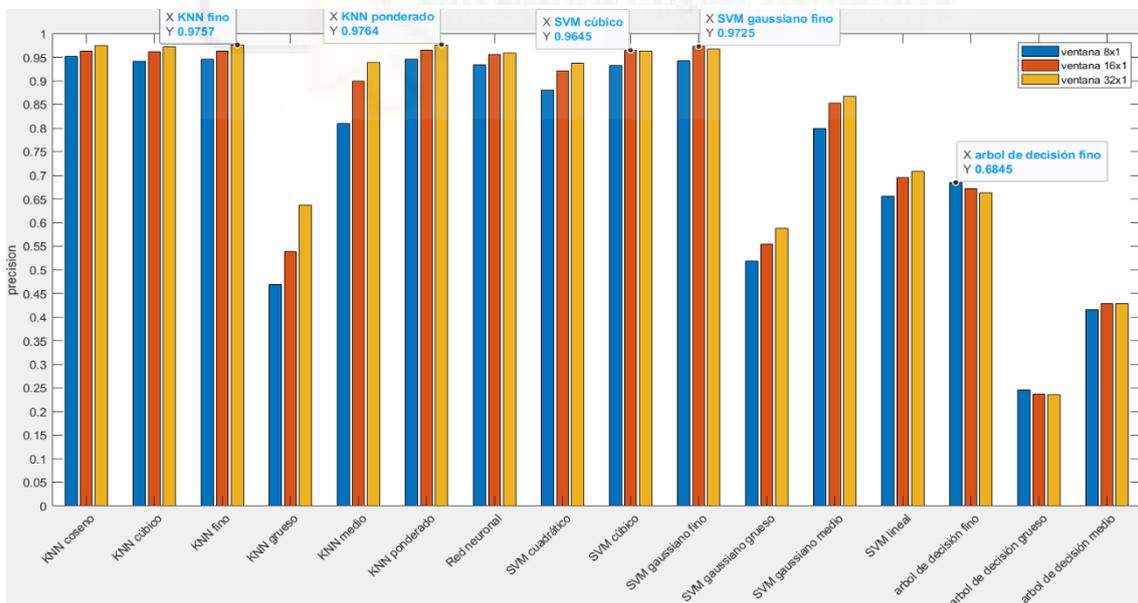
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9680	6.7147e-04	0.9916	0.9680	0.9797
2	0.9405	0.0055	0.9335	0.9405	0.9370
3	0.9650	0.0035	0.9579	0.9650	0.9615
4	0.8862	0.0070	0.9126	0.8862	0.8992
5	0.9345	0.0095	0.8895	0.9345	0.9115
6	0.9546	0.0056	0.9331	0.9546	0.9437
7	0.9918	6.1043e-04	0.9926	0.9918	0.9922
8	0.9621	0.0045	0.9466	0.9621	0.9542
9	0.9792	0.0031	0.9634	0.9792	0.9712
10	0.8348	0.0102	0.8704	0.8348	0.8523
11	0.8713	0.0104	0.8732	0.8713	0.8723
12	0.9301	0.0034	0.9579	0.9301	0.9438
13	0.9710	0.0027	0.9667	0.9710	0.9688

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	1301	28		4				3		1	4	2	1
2		1264	4	7	8	8	2	2	1	15	26	5	
3		2	1297	12	5	2			5	6	2	4	5
4	1	11	5	1191	6	20	2	7	15	39	40	6	1
5	1	1	4	2	1256	11			14	4	11	14	12
6	2	2	2	12	6	1283			4	1	20	8	2
7		6					1333					5	
8			1	6	13	8			1293	8	5	4	5
9				2	5				13	1316	8		
10	2	12	20	35	33	29	2	13	5	1122	54	6	11
11	3	24	4	29	29	8	1	4	1	50	1171	10	10
12	4	15	5	34	4	4		9	2	10	7	1250	4
13			2		17	2			2	6	3	6	1

Gráfica 296. Validación del modelo elegido de la gráfica 295

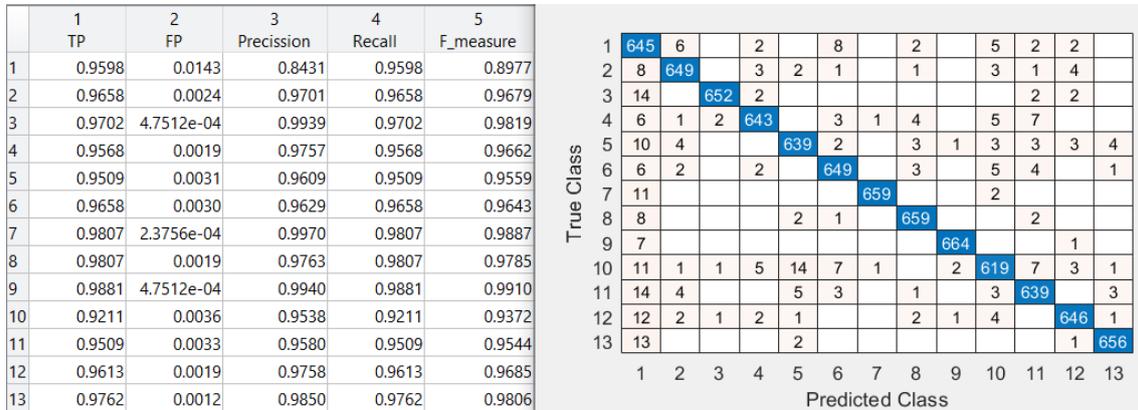
Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en colores opuestos para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 296.



Gráfica 297. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en colores opuestos

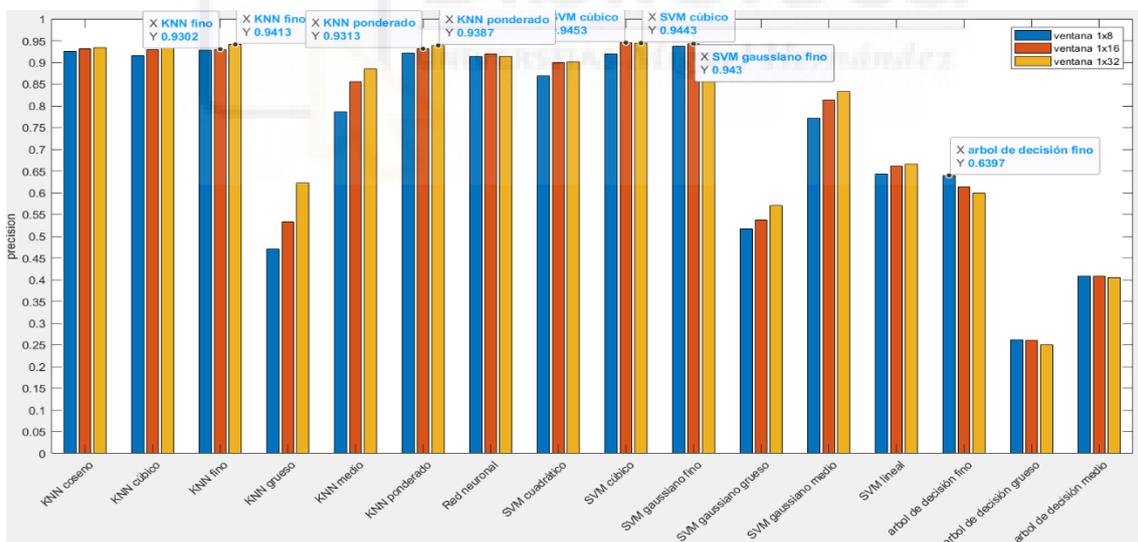
Vemos en la gráfica 297 que usando la matriz de coocurrencia en colores opuestos el clasificador K-NN ponderado es el que mejor se comporta cuando

escogemos la ventana 32x1. Hay que mencionar que la diferencia con el clasificador K-NN fino con ventana de 32x1 es muy pequeña.



Gráfica 298. Validación del modelo elegido de la gráfica 297

Sacamos del clasificador K-NN ponderado esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en colores opuestos para ventanas en filas de la gráfica 298.



Gráfica 299. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en colores opuestos

La gráfica 299 muestra el comportamiento de los clasificadores cuando usamos las ventanas en columna con la matriz de coocurrencia en colores opuestos, vemos que el mejor resultado nos lo da el SVM cúbico para ventanas de 1x16

seguido muy de cerca por el resultado del mismo clasificador para ventanas de 1x16 y el SVM cuadrático para ventanas de 1x16.

	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9167	0.0027	0.9655	0.9167	0.9405
2	0.9554	0.0036	0.9554	0.9554	0.9554
3	0.9762	0.0027	0.9676	0.9762	0.9719
4	0.9583	0.0065	0.9226	0.9583	0.9401
5	0.9792	0.0167	0.8266	0.9792	0.8965
6	0.9256	0.0044	0.9453	0.9256	0.9353
7	0.9821	7.2710e-04	0.9910	0.9821	0.9865
8	0.9673	0.0034	0.9587	0.9673	0.9630
9	0.9821	9.6946e-04	0.9880	0.9821	0.9851
10	0.8720	0.0078	0.9015	0.8720	0.8865
11	0.9405	0.0046	0.9433	0.9405	0.9419
12	0.9196	0.0015	0.9810	0.9196	0.9493
13	0.9048	0.0032	0.9590	0.9048	0.9311

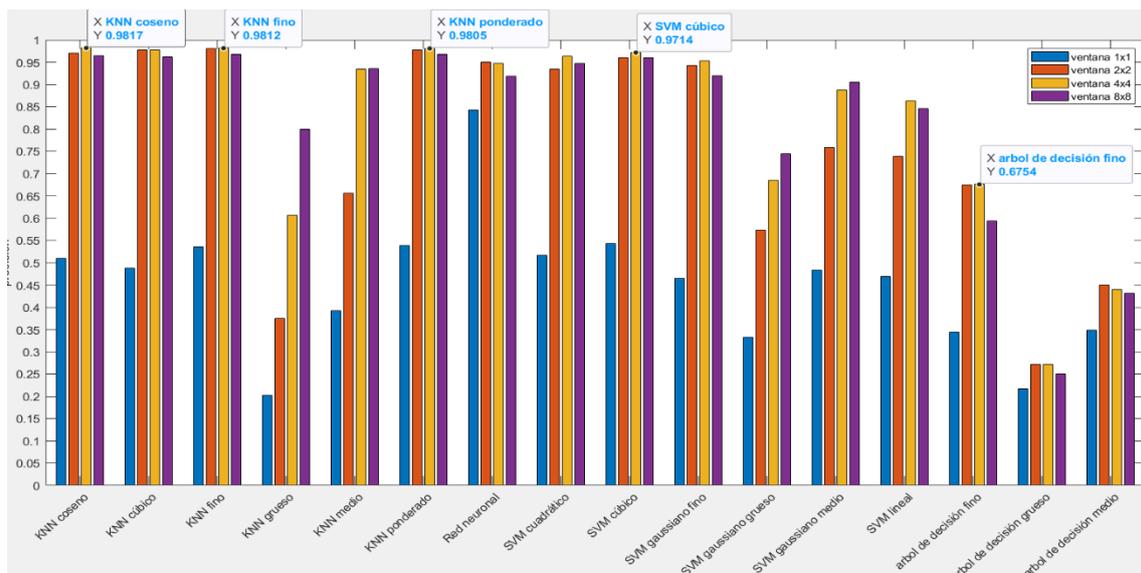
  

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	308	8	2	3			3	1	1	7	1	1	1
2	2	321		5	1	1		1		1	3	1	
3	1		328	2		1		1			1		2
4			1	322				2	1	6	2		
5		2			329			3				1	1
6	1	1		5		311		2		10	1	2	3
7	5	1					330						
8				1	5	3		325	1	1			
9			2					2	330	2			
10	1		2	5	10	7		2		293	10	1	5
11		3		4	7	2				3	316		1
12	1		3	2	17	2			1	1		309	
13			1		29					1	1	1	304

Gráfica 300. Validación del modelo elegido de la gráfica 299

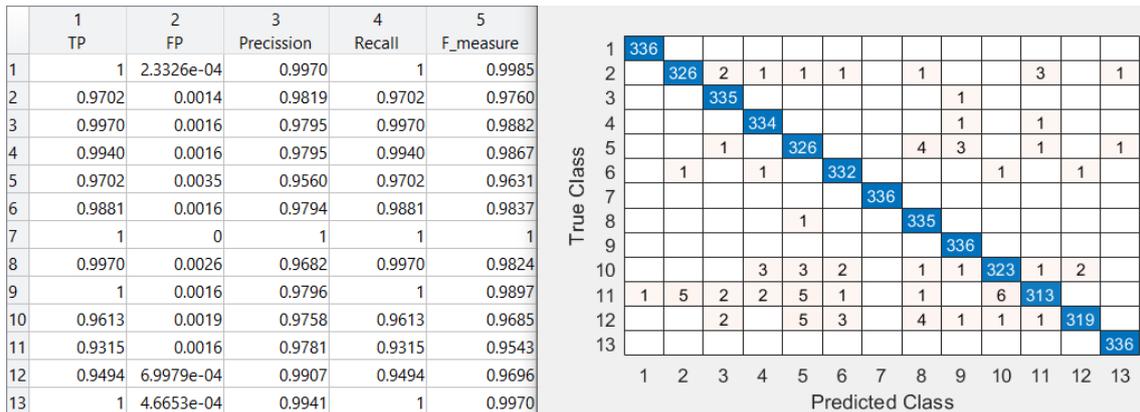
Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en colores opuestos para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 300.

Una vez vistos los resultados anteriores, el mejor clasificador es el K-NN ponderado con ventana de 32x1, cabe destacar que este clasificador se comporta muy bien, incluso, en el resto de tipos de ventana.



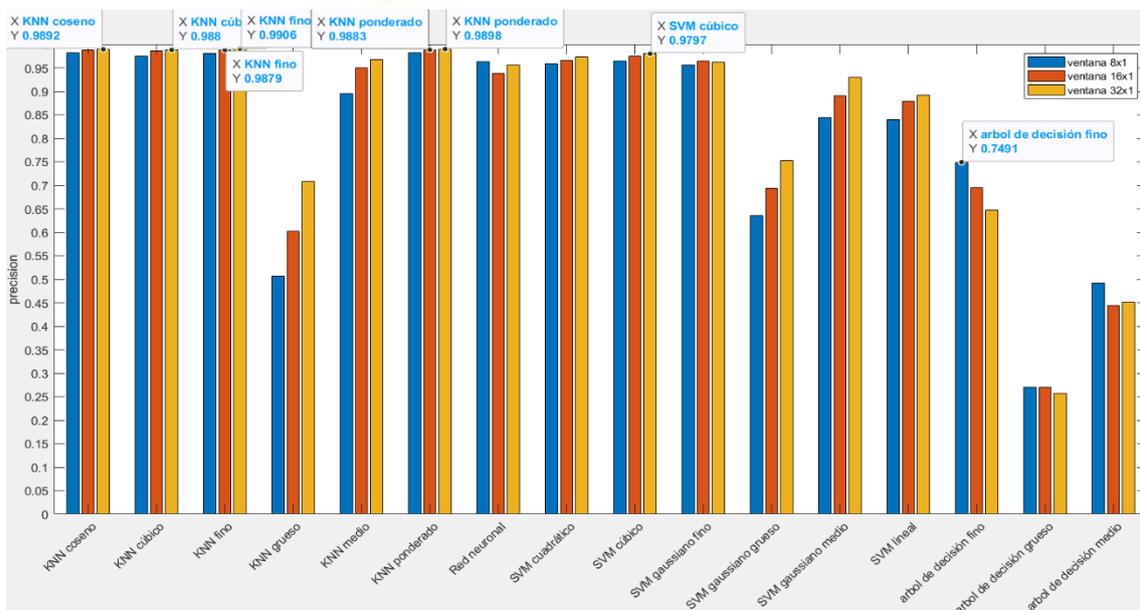
Gráfica 301. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en colores opuestos

En la gráfica 301, usando LBP variante a rotación en colores opuestos vemos que, en la mayoría de los clasificadores, los valores más elevados se dan para la ventana de 4x4, pero se diferencian poco de los valores para la ventana de 2x2. El clasificador K-NN coseno es el que mayor precisión tiene usando la ventana de 4x4, pero el K-NN fino para la misma ventana está muy cerca.



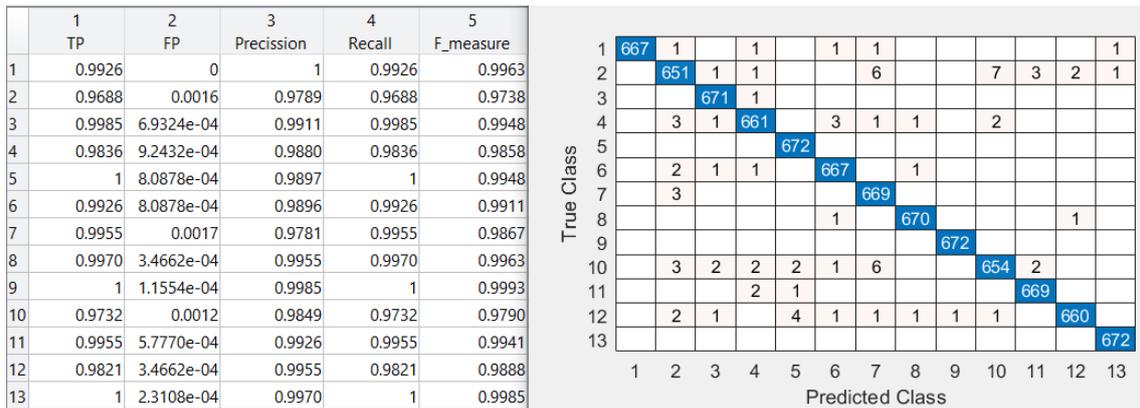
Gráfica 302. Validación del modelo elegido de la gráfica 301

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en colores opuestos para ventanas cuadradas, es del clasificador K-NN coseno de la gráfica 302.



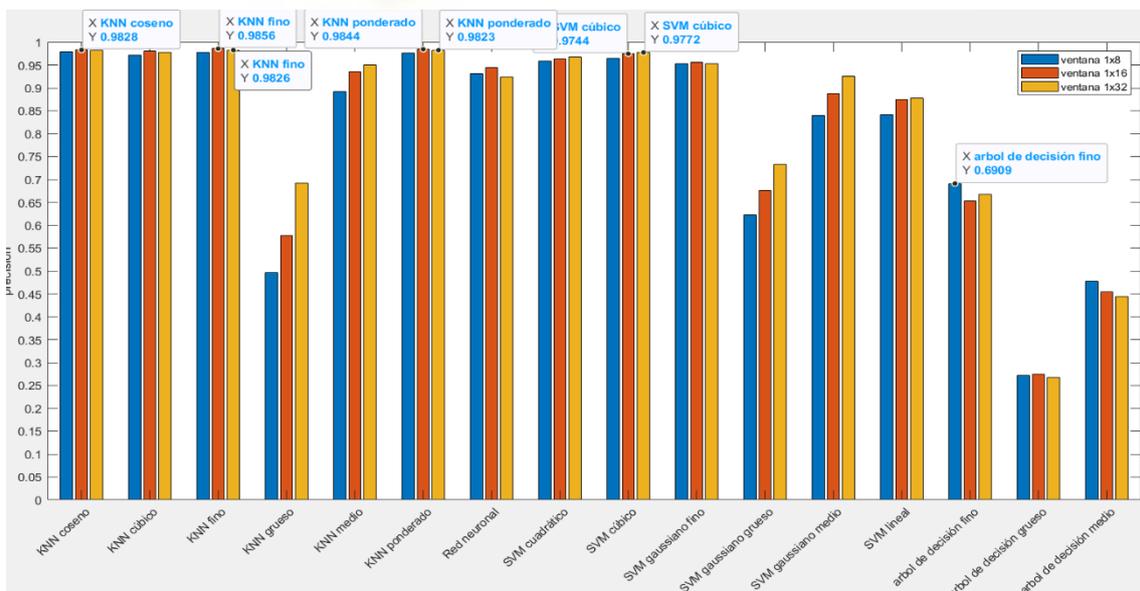
Gráfica 303. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en colores opuestos

Vemos en la gráfica 303 que la mayoría de los clasificadores alcanzan su valor más alto para la ventana de 32x1. El clasificador, que usando LBP variante a rotación con radio 1, alcanza el valor más alto de la gráfica es el K-NN fino para la ventana de 32x1, pero el valor del clasificador K-NN ponderado con ventana de 32x1 es muy cercano.



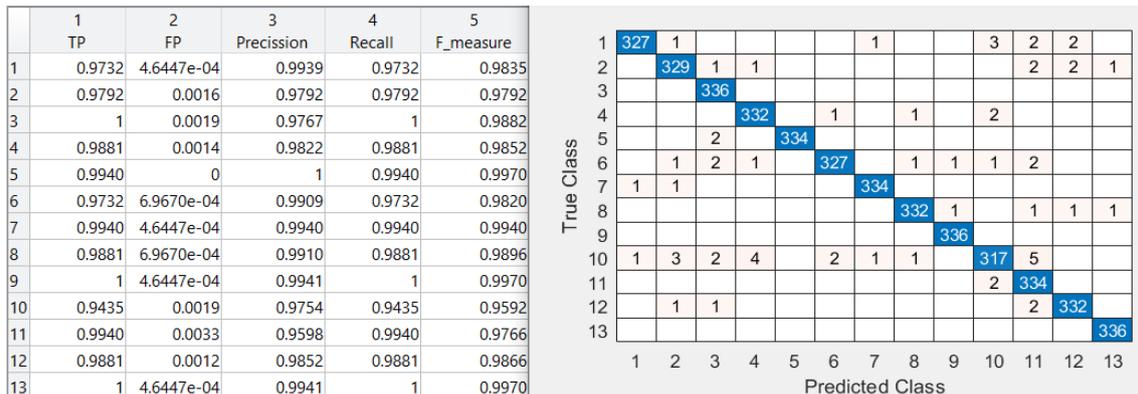
Gráfica 304. Validación del modelo elegido de la gráfica 303

Sacamos del clasificador K-NN fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en colores opuestos para ventanas en filas de la gráfica 304.



Gráfica 305. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en colores opuestos

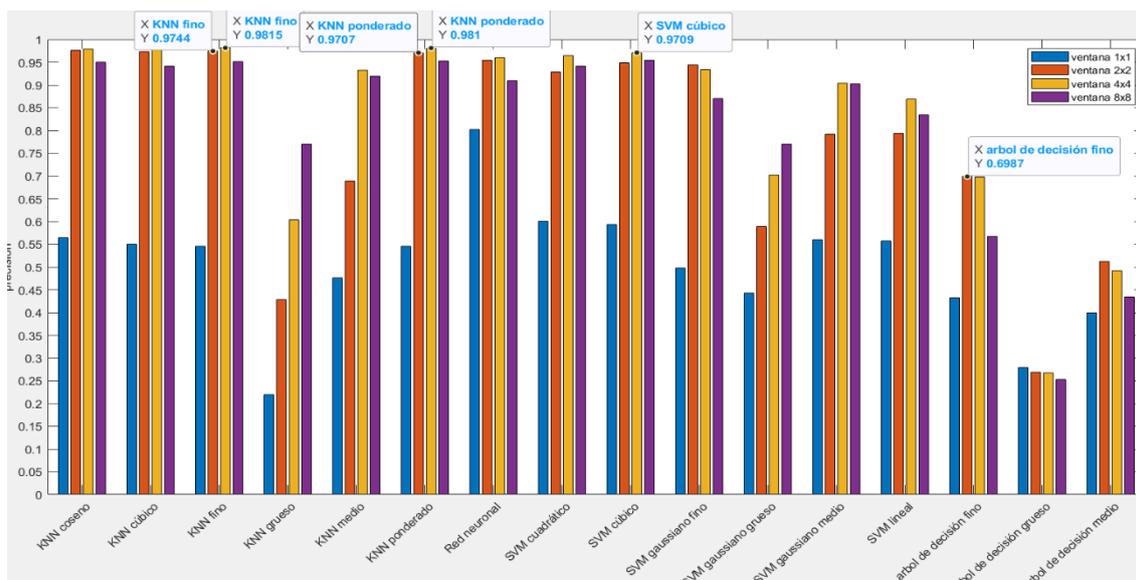
Vemos en la gráfica 305 que al analizar las ventanas en columna para LBP variante a rotación con radio 1 en colores opuestos los valores de un mismo clasificador las diferentes ventanas tienen valores cercanos, hay excepciones. El mejor resultado es alcanzado por el clasificador K-NN fino con una ventana de 1x16, pero muy cerca está también el K-NN ponderado para ventanas de 1x16.



Gráfica 306. Validación del modelo elegido de la gráfica 305

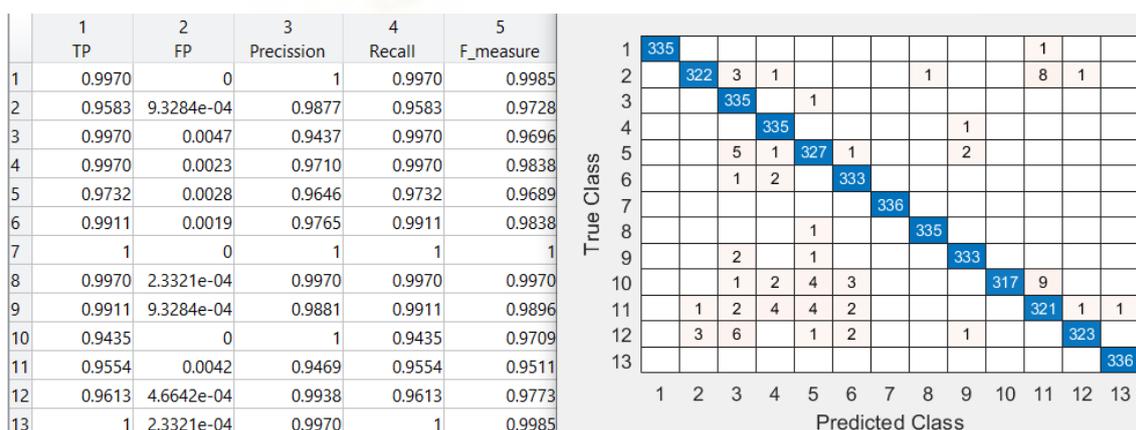
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en colores opuestos para ventanas en columnas, es del clasificador K-NN fino de la gráfica 306.

Queda claro que el clasificador K-NN fino es el que, independientemente de la ventana, siempre alcanza un resultado muy bueno respecto al resto de clasificadores. Siendo para la ventana 32x1 el de mayor valor para LBP variante a rotación con radio 1 en colores opuestos.



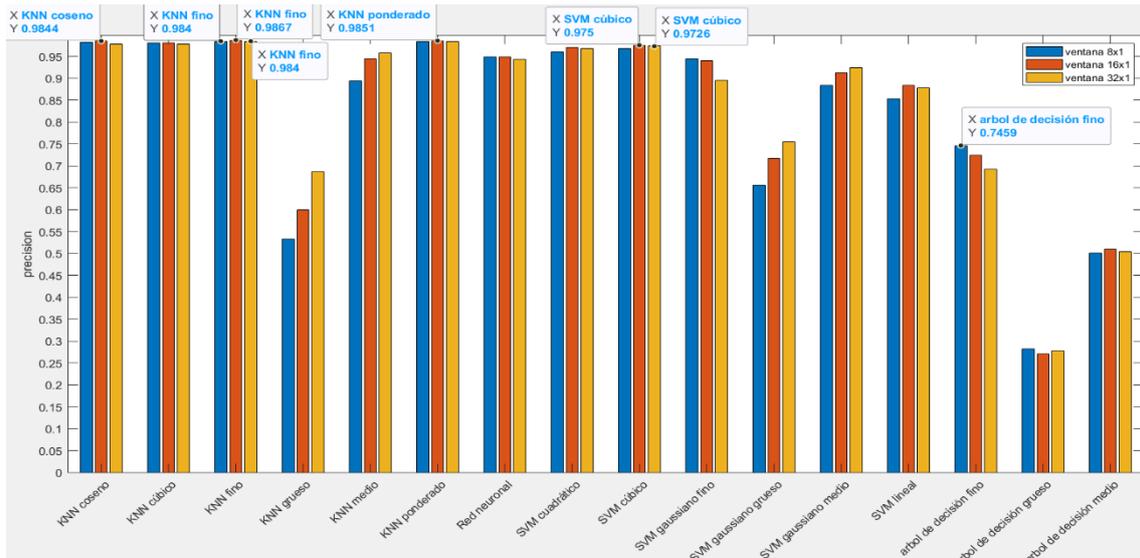
Gráfica 307. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en colores opuestos

En la gráfica 307, usando LBP variante a rotación con radio 3 en colores opuestos los valores más altos en general se encuentran cuando usamos ventanas de 4x4, siendo esta ventana la que logra la mayor precisión con el clasificador K-NN fino y, el siguiente valor más alto viene por parte del K-NN ponderado, la diferencia es muy pequeña.



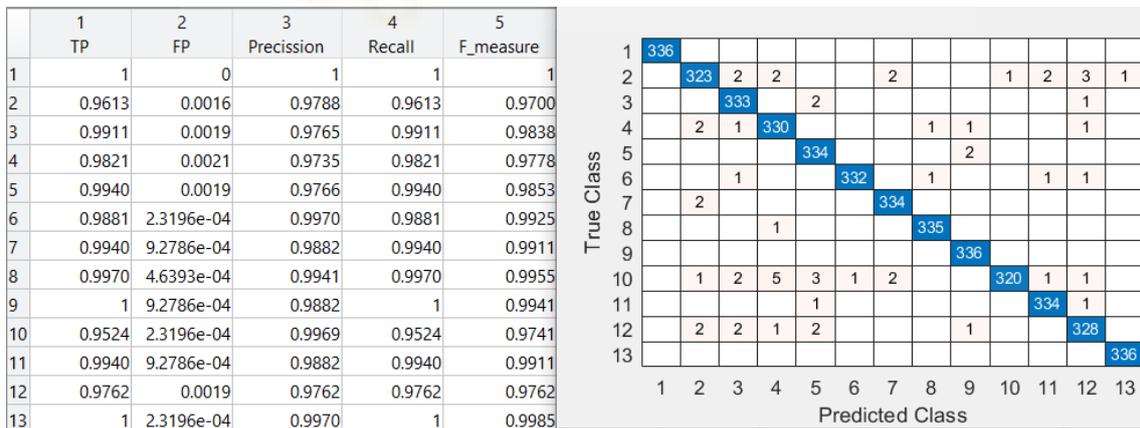
Gráfica 308. Validación del modelo elegido de la gráfica 307

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en colores opuestos para ventanas cuadradas, es del clasificador K-NN fino de la gráfica 308.



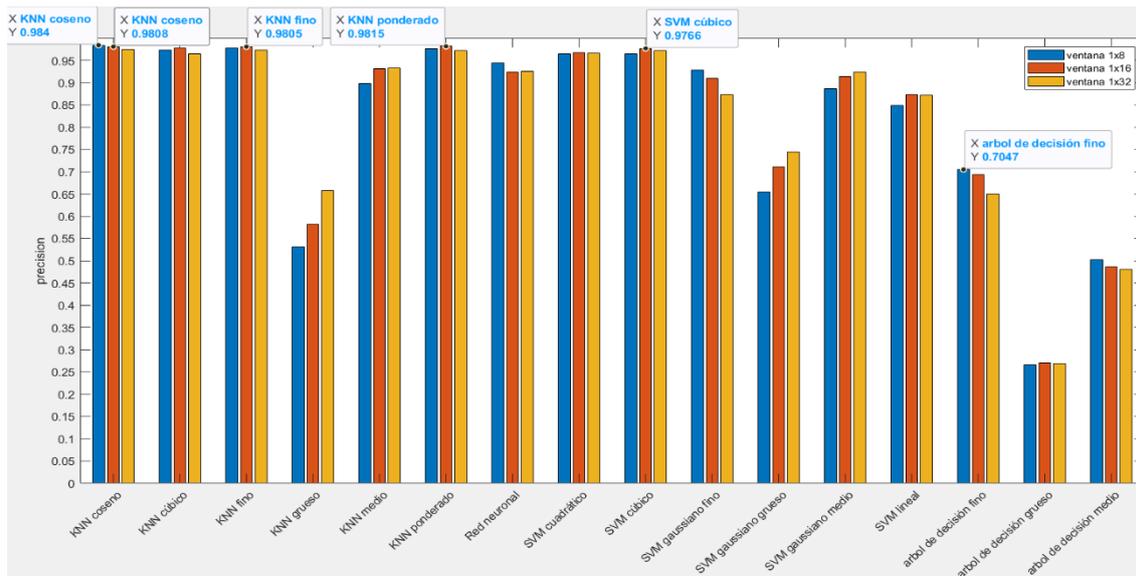
Gráfica 309. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en colores opuestos

Analizando las ventanas en filas para LBP variante a rotación con radio 3 en colores opuestos, vemos en la gráfica 309 que los valores del mismo clasificador para distintas ventanas son muy parecidos, siendo el clasificador K-NN fino con ventana de 16x1 el que alcanza el valor más alto, pero la diferencia con el K-NN ponderado para ventana de 16x1 es pequeña.



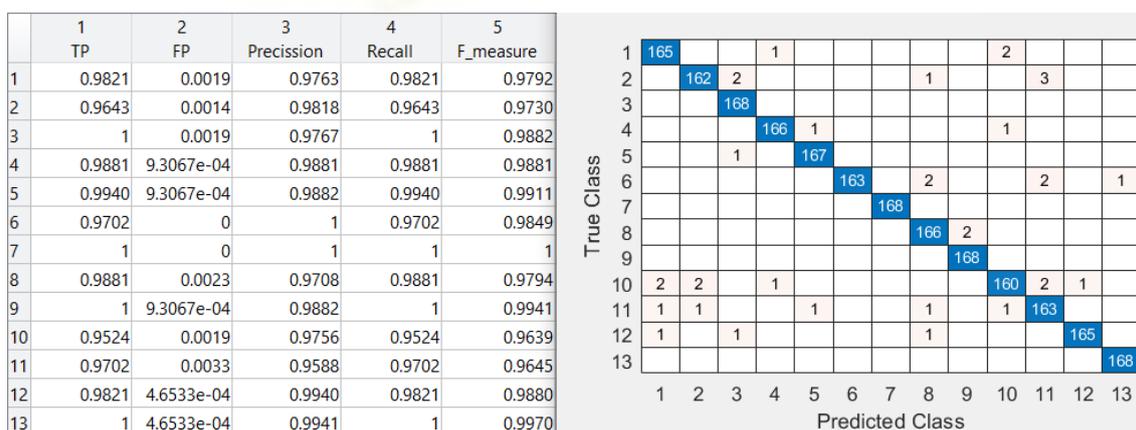
Gráfica 310. Validación del modelo elegido de la gráfica 309

Sacamos del clasificador K-NN fino representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en colores opuestos para ventanas en filas de la gráfica 310.



Gráfica 311. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en colores opuestos

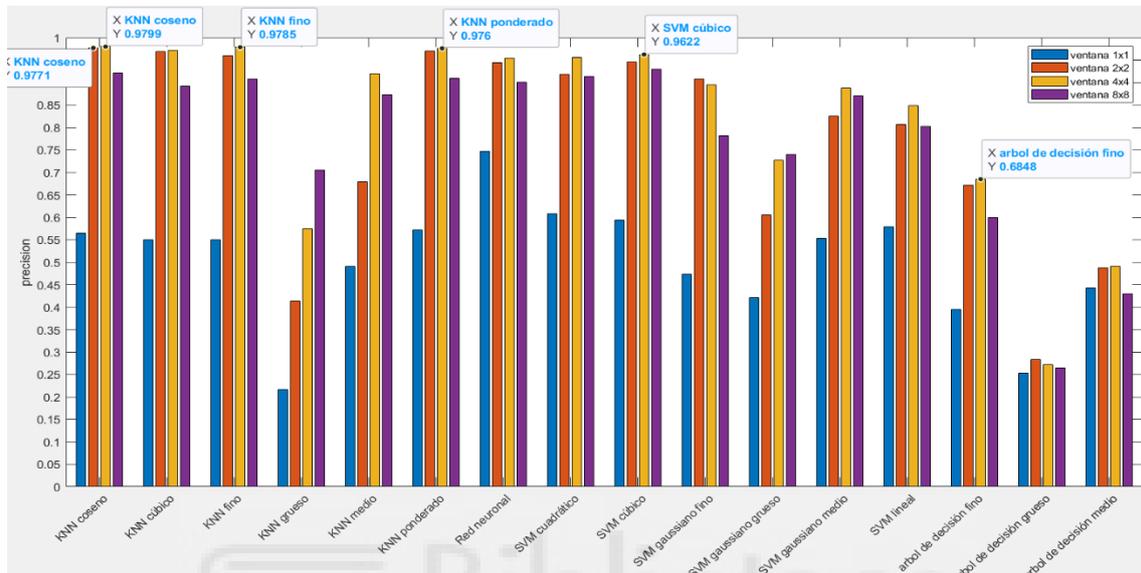
Podemos observar en la gráfica 311 que los resultados para los diferentes tamaños de ventana, usando LBP variante a rotación con radio 3 en colores opuestos, son muy cercanos en la mayoría de los clasificadores. Para estas ventanas el clasificador K-NN coseno con ventana 1x8 es el que mayor valor alcanza, seguido de cerca por el K-NN ponderado con ventana de 1x16.



Gráfica 312. Validación del modelo elegido de la gráfica 311

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en colores opuestos para ventanas en columnas, es del clasificador K-NN coseno de la gráfica 312.

Hemos comprobado que para LBP variante a rotación con radio 3 en RGB el clasificador K-NN fino es el que mejor se comporta con una ventana de 16x1, aunque no solo lo hace para un tipo de ventana. También debemos mencionar que el K-NN ponderado tienen valores muy cercanos a los del K-NN fino.



Gráfica 313. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en colores opuestos

Ahora analizaremos en la gráfica 313 para ventanas cuadradas el uso de LBP variante a rotación con radio 5 en colores opuestos, el valor más alto está localizado en la ventana 4x4 del clasificador K-NN coseno. Hay que mencionar, que este valor máximo es cercano al valor ofrecido por otros clasificadores o incluso para el mismo clasificador.

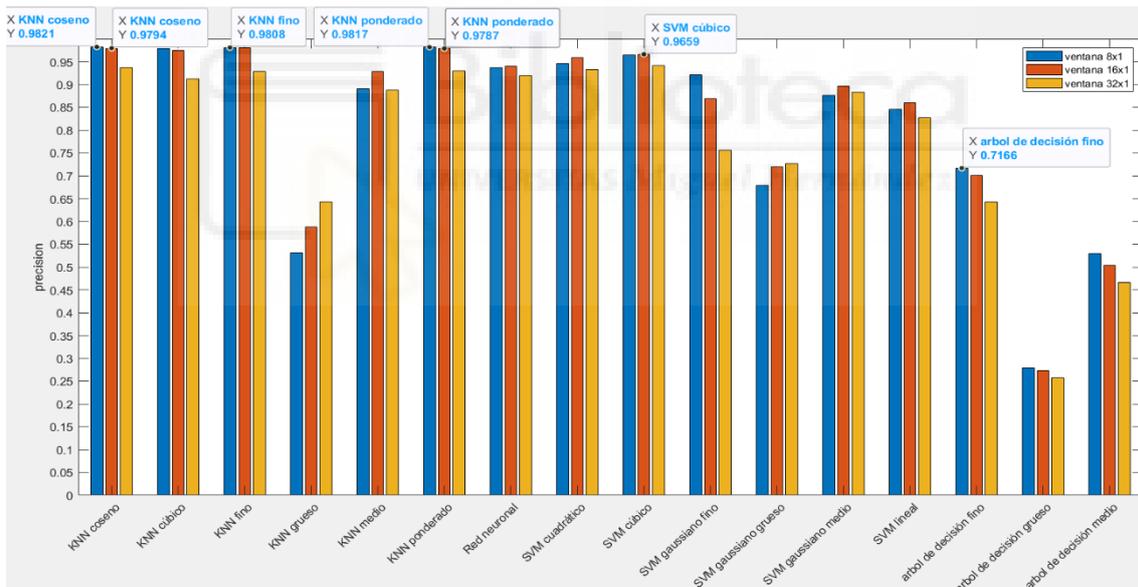
	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	0.9970	2.3359e-04	0.9970	0.9970	0.9970
2	0.9583	0.0012	0.9847	0.9583	0.9713
3	0.9792	0.0023	0.9705	0.9792	0.9748
4	0.9821	0.0012	0.9851	0.9821	0.9836
5	0.9762	0.0033	0.9591	0.9762	0.9676
6	0.9940	0.0016	0.9795	0.9940	0.9867
7	1	0	1	1	1
8	0.9970	0.0023	0.9710	0.9970	0.9838
9	0.9940	0.0019	0.9766	0.9940	0.9853
10	0.9494	4.6718e-04	0.9938	0.9494	0.9711
11	0.9613	0.0033	0.9585	0.9613	0.9599
12	0.9524	0.0021	0.9726	0.9524	0.9624
13	1	4.6718e-04	0.9941	1	0.9970

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	335							1		1			
2		322	2	1				1			9	1	
3			329		2			1	2			2	
4		2		330		2			1			1	
5			1	1	328			1	3			2	
6						334		1					1
7							336						
8				1				335					
9									334				1
10				2	5	3		2	1	319	4		
11	1	2			2	1		3		1	323	2	1
12		1	7		4	1		1	1		1	320	
13													336

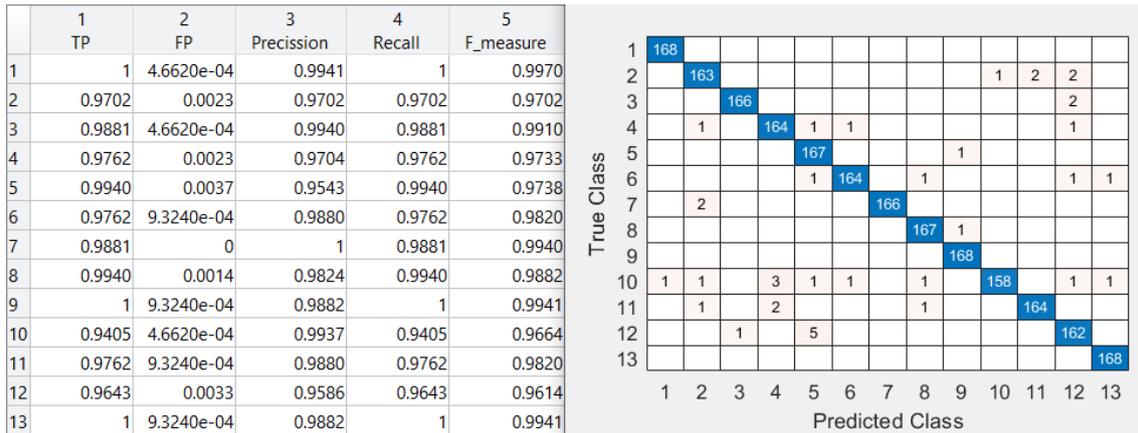
Gráfica 314. Validación del modelo elegido de la gráfica 313

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en colores opuestos para ventanas cuadradas, es del clasificador K-NN coseno de la gráfica 314.



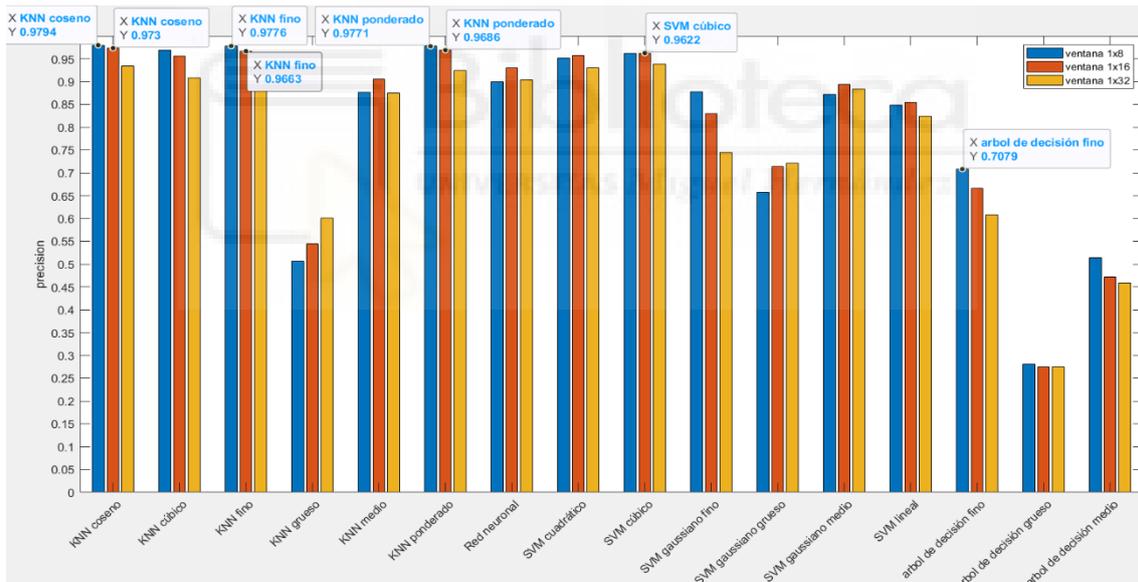
Gráfica 315. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en colores opuestos

En la gráfica 315 el mejor clasificador, usando LBP variante a rotación con radio 5 en colores opuestos con ventanas en fila, es el K-NN coseno para ventanas de 8x1 seguido muy de cerca por el K-NN ponderado para ventana de 8x1. Como se puede ver es en esta ventana en la que muchos clasificadores alcanzan el máximo valor



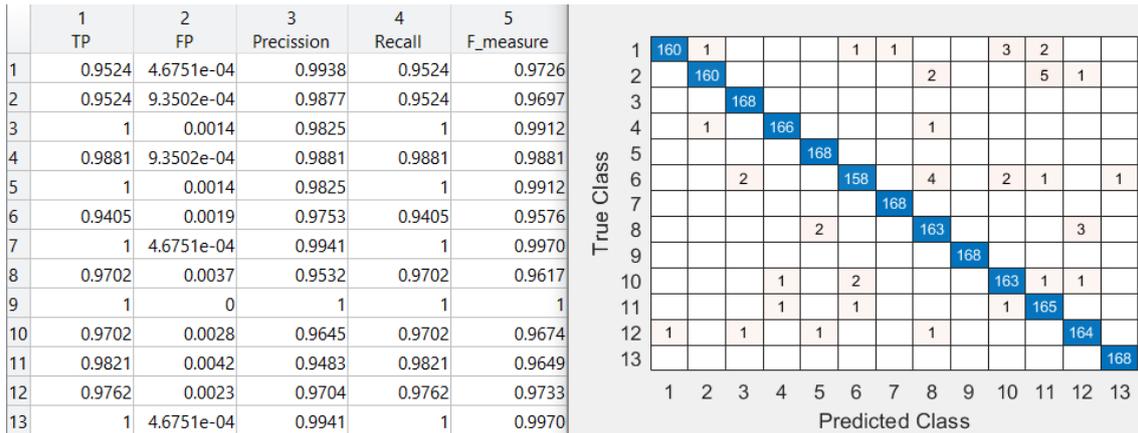
Gráfica 316. Validación del modelo elegido de la gráfica 315

Sacamos del clasificador K-NN coseno esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en colores opuestos para ventanas en filas de la gráfica 306.



Gráfica 317. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en colores opuestos

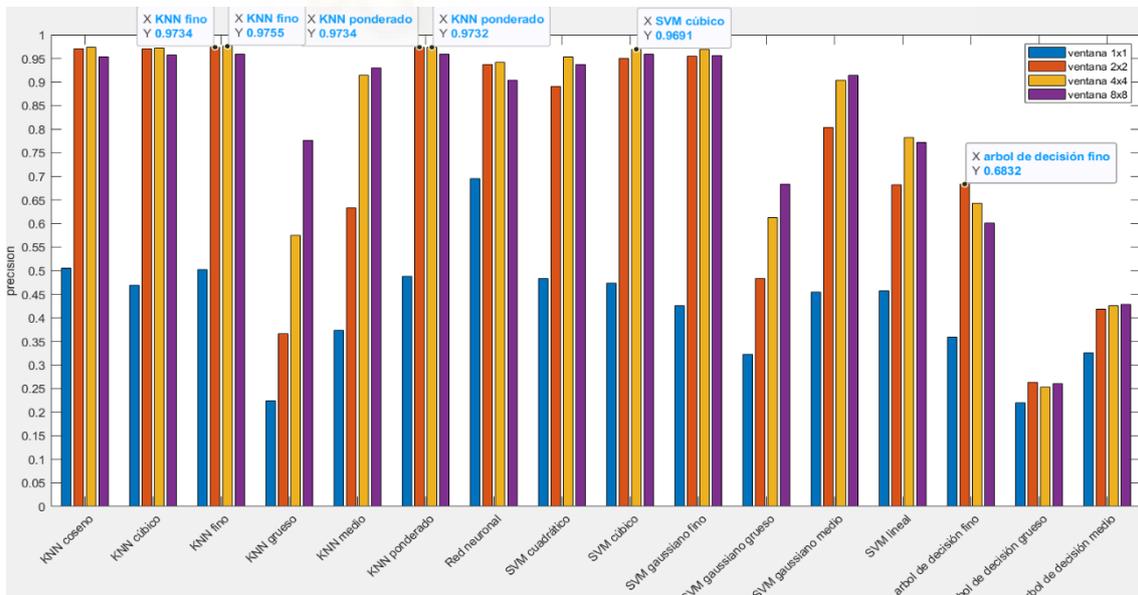
Terminando de analizar el LBP variante a rotación con radio 5 en colores opuestos, vemos en la gráfica 317 que, en general, para ventanas en columnas los clasificadores se comportan mejor para el tamaño de 1x8 y conforme este tamaño disminuye, el resultado empeora. El mejor resultado lo encontramos en el clasificador K-NN coseno para la ventana de 1x8.



Gráfica 318. Validación del modelo elegido de la gráfica 317

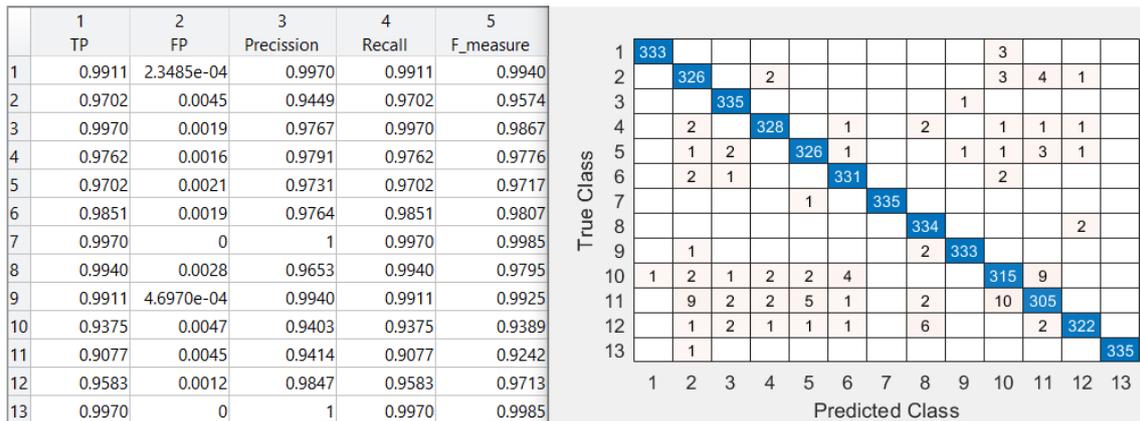
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en colores opuestos para ventanas en columnas, es del clasificador K-NN coseno de la gráfica 318.

Viendo el comportamiento de los clasificadores usando LBP variante a rotación con radio 5 en colores opuestos, que el clasificador K-NN ponderado es el que por lo general mejor se comporta, y, específicamente, para la ventana de 8x1 es el resultado más alto.



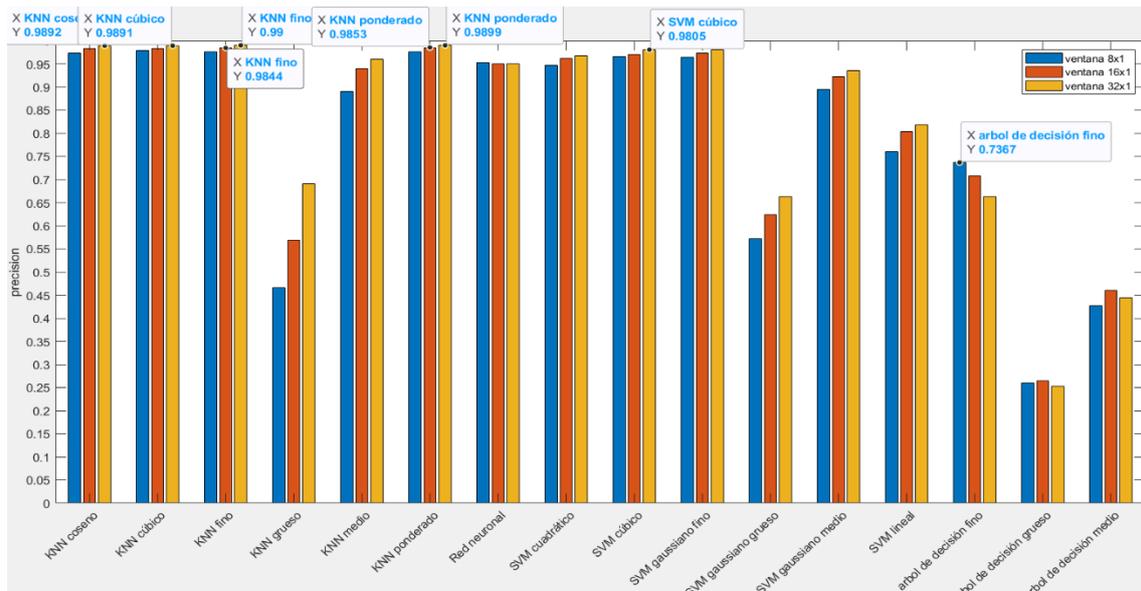
Gráfica 319. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en colores opuestos

Ahora, usando LBP invariante a rotación con radio 1 en colores opuestos, vemos en la gráfica 319 que la mayoría los clasificadores tienen valores muy parejos con las ventanas de 2x2 y 4x4, siendo el K-NN fino el que mayor precisión alcanza, seguido muy de cerca por el propio clasificador para ventana de 2x2 y del K-NN ponderado para una ventana de 2x2.



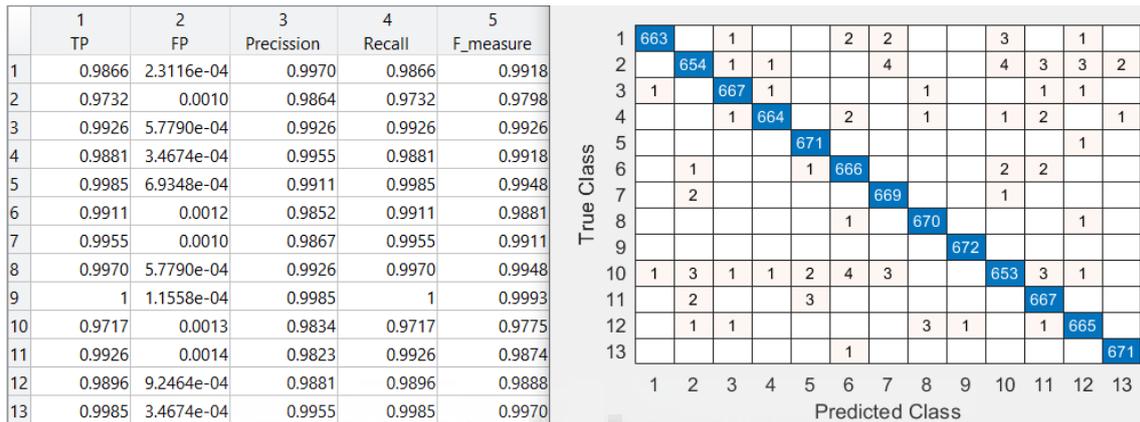
Gráfica 320. Validación del modelo elegido de la gráfica 319

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en colores opuestos para ventanas cuadradas, es del clasificador K-NN fino de la gráfica 320.



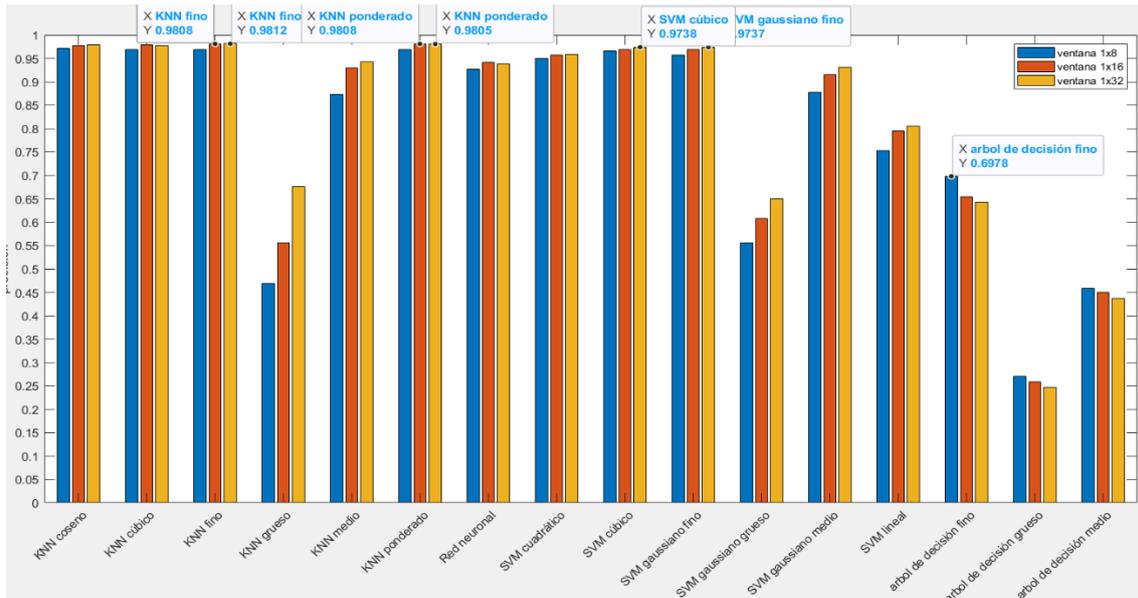
Gráfica 321. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en colores opuestos

En muchos clasificadores vemos en la gráfica 321 que los valores en cada ventana son muy parecidos entre sí. Por eso, los clasificadores que, usando LBP invariante a rotación con radio 1 en colores opuestos, tienen la mayor precisión dista muy poco del mismo clasificador, pero para otra ventana. El K-NN fino y el K-NN ponderado para ventana de 32x1 es el de mayor precisión y, seguido muy de cerca, por los valores de los otros clasificadores para esa ventana.



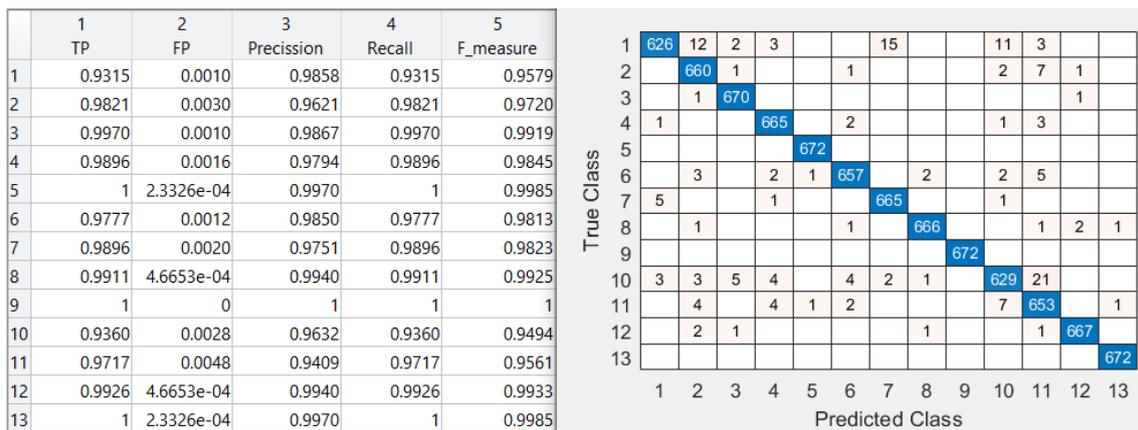
Gráfica 322. Validación del modelo elegido de la gráfica 321

Sacamos del clasificador K-NN fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en colores opuestos para ventanas en filas de la gráfica 322.



Gráfica 323. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en colores opuestos

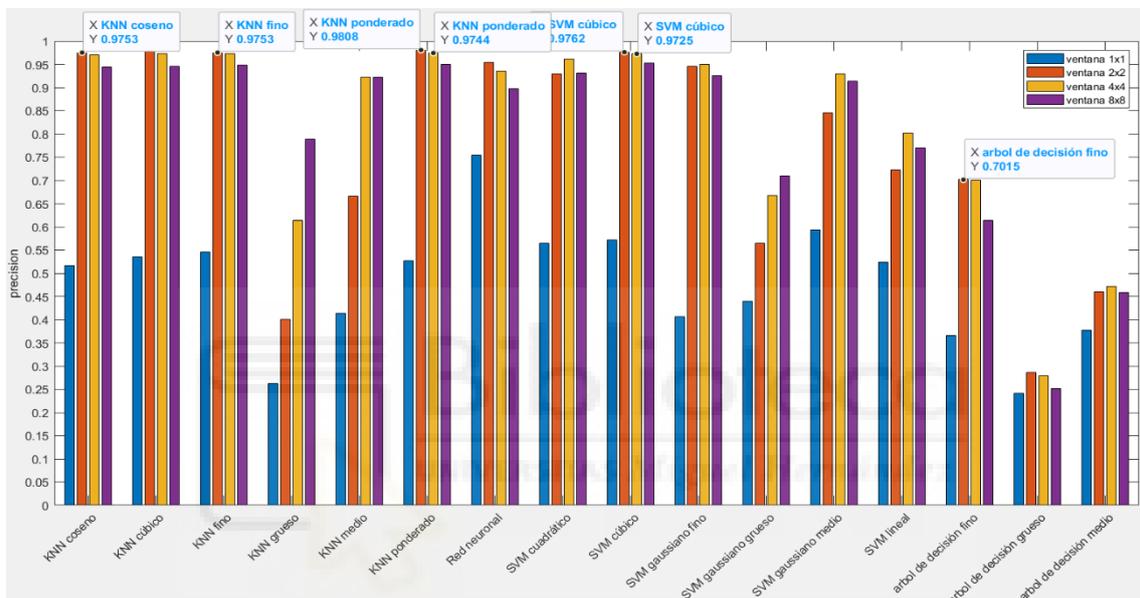
Generalmente en la gráfica 323, los clasificadores tienen unos valores semejantes para los distintos tipos de ventana. Por ello, usando LBP invariante a rotación con radio 1 en colores opuestos, el clasificador K-NN fino con ventana de 1x32 es el que mejor resultado proporciona, pero dista muy poco del propio clasificador para ventana de 1x16 y para el K-NN ponderado con ventana de 1x16.



Gráfica 324. Validación del modelo elegido de la gráfica 323

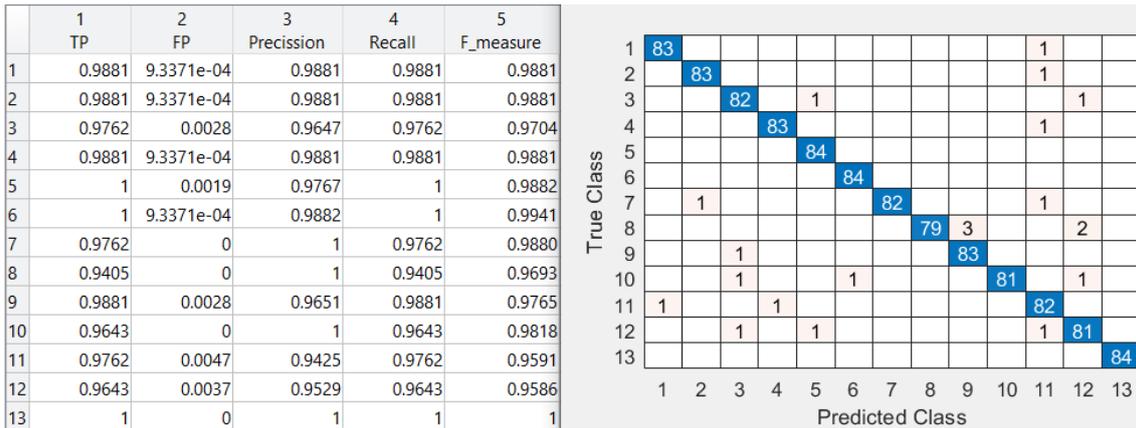
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en colores opuestos para ventanas en columnas, es del clasificador K-NN fino de la gráfica 324.

Una vez vistas las tres graficas (gráfica 319, 321 y 323) usando LBP invariante a rotación con radio 1 en colores opuestos el clasificador K-NN fino para ventanas de 16x1 es el que mejor resultado nos ofrece y, en general, es el que mejor se comporta.



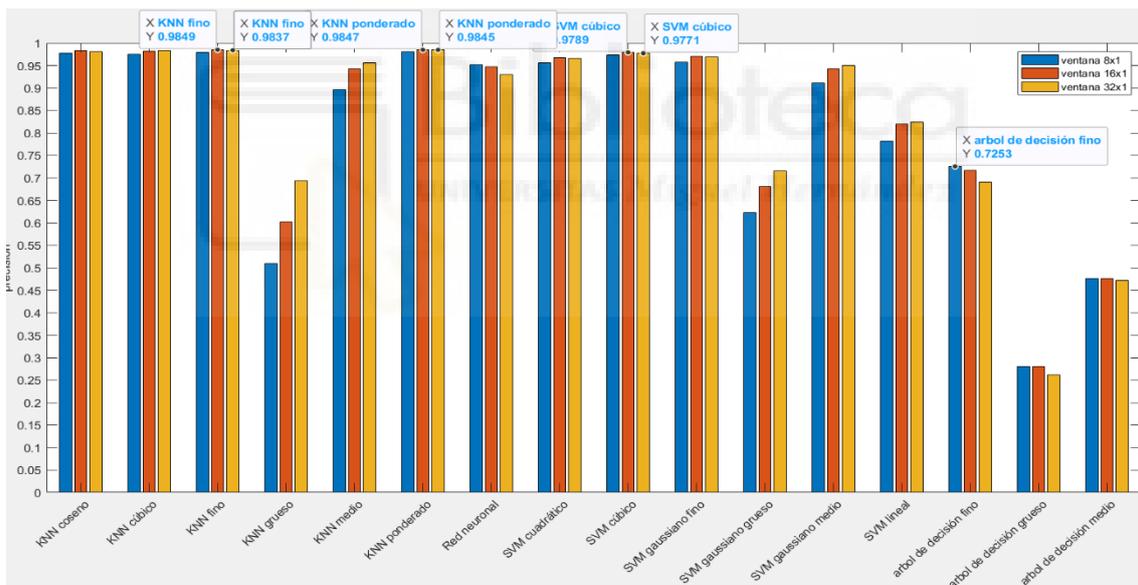
Gráfica 325. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en colores opuestos

Con LBP invariante a rotación con radio 3 en colores opuestos, el clasificador K-NN ponderado alcanza la más alta precisión de toda la gráfica para la ventana de 2x2. Generalmente en la gráfica 325, es en esta ventana en la que la mayoría de los clasificadores tienen mejores resultados.



Gráfica 326. Validación del modelo elegido de la gráfica 325

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en colores opuestos para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 326.



Gráfica 327. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en colores opuestos

Podemos observar en la gráfica 327 que los mejores resultados, de la mayoría de los clasificadores, aparece cuando usamos ventanas de. El mejor resultado viene por el clasificador K-NN fino para ventana de 16x1, sin embargo, el K-NN ponderado para ventana de 16x1 tiene un valor también muy elevado y cercano al anterior.

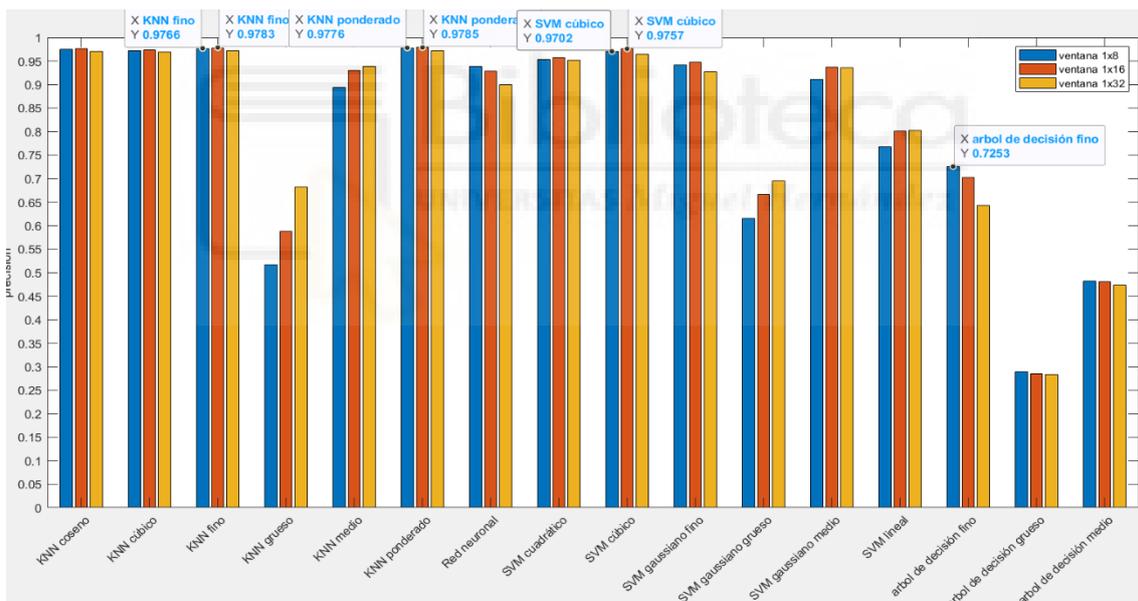
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9911	2.3250e-04	0.9970	0.9911	0.9940
2	0.9673	0.0023	0.9701	0.9673	0.9687
3	0.9881	0.0021	0.9736	0.9881	0.9808
4	0.9792	0.0016	0.9792	0.9792	0.9792
5	0.9911	4.6501e-04	0.9940	0.9911	0.9925
6	0.9851	0.0019	0.9764	0.9851	0.9807
7	0.9881	6.9751e-04	0.9910	0.9881	0.9896
8	0.9911	6.9751e-04	0.9911	0.9911	0.9911
9	1	6.9751e-04	0.9912	1	0.9956
10	0.9613	9.3002e-04	0.9878	0.9613	0.9744
11	0.9881	0.0019	0.9765	0.9881	0.9822
12	0.9702	0.0019	0.9760	0.9702	0.9731
13	1	2.3250e-04	0.9970	1	0.9985

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	333	2											1
2		325		2			2					4	3
3			332	1	1			1					1
4		2		329		1				1	2	1	
5			1		333	1			1				
6			1			331		2		1	1		
7	1	2					332			1			
8			1		1		333	1					
9								336					
10		3	1	3		2	1		1	323			2
11		1				2					332	1	
12			5	1	1	1				1		326	1
13													336

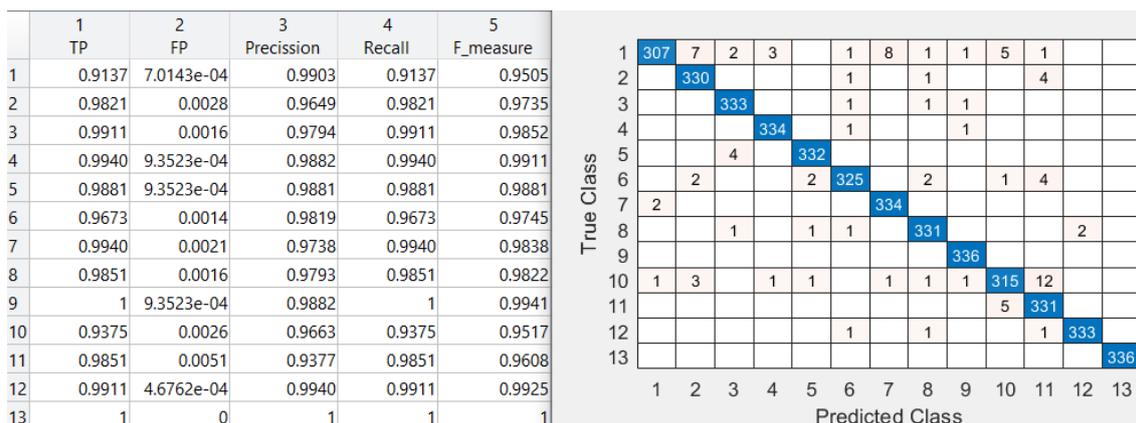
Gráfica 328. Validación del modelo elegido de la gráfica 327

Sacamos del clasificador K-NN fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en colores opuestos para ventanas en filas de la gráfica 328.



Gráfica 329. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en colores opuestos

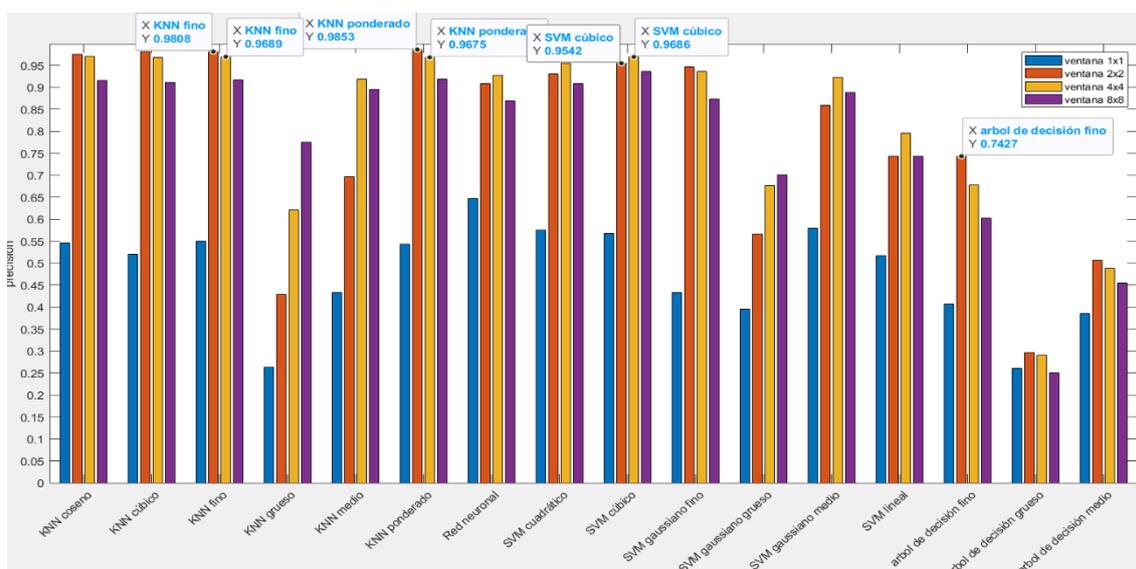
En la gráfica 329 para LBP invariante a rotación con radio 3 en colores opuestos, la ventana de 1x16 es la que provoca los mejores resultados de muchos clasificadores. El que mejor resultado ofrece en este caso es el K-NN ponderado con ventana de 1x16, pero la diferencia con el K-NN fino para la misma ventana es ínfima.



Gráfica 330. Validación del modelo elegido de la gráfica 329

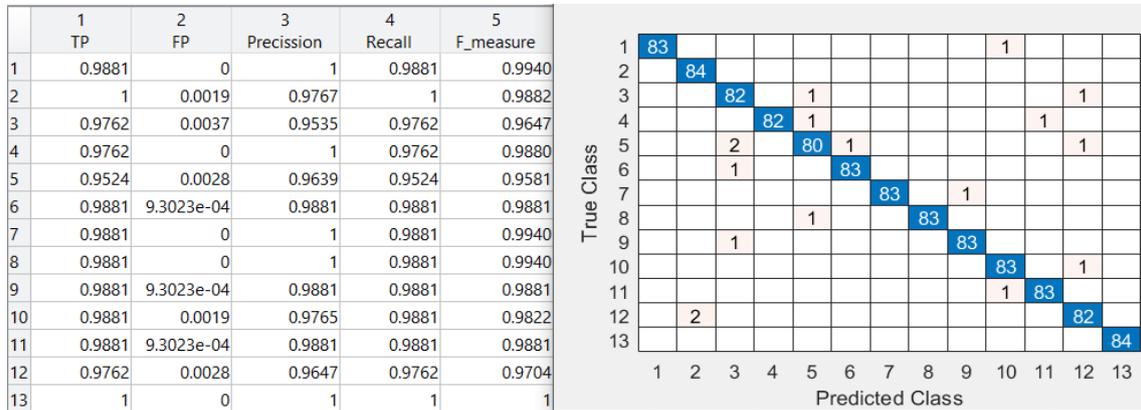
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en colores opuestos para ventanas en columnas, es del clasificador K-NN ponderado de la gráfica 330.

Una vez visto todos los resultados usando LBP invariante a rotación con radio 3 en colores opuestos, el clasificador K-NN fino es el que mejores resultados ha ofrecido en los tres casos, siendo el mayor de todos para ventana de 16x1, pero hay que mencionar que el K-NN ponderado también tiene un comportamiento parecido.



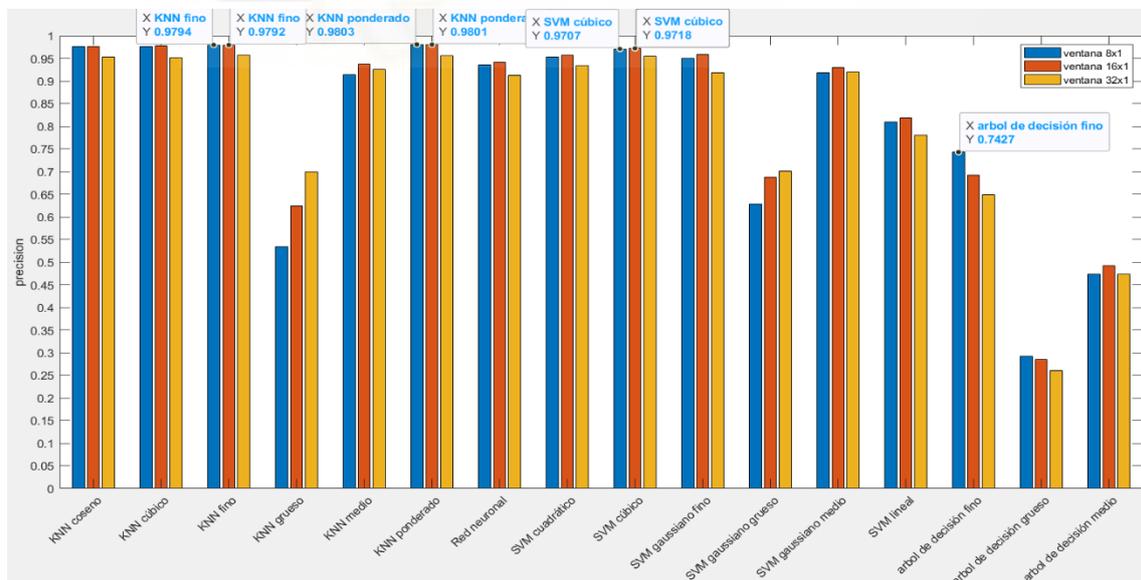
Gráfica 331. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en colores opuestos

En la gráfica 331, continuando con LBP invariante a rotación con radio 5 en colores opuestos, vemos los resultados más elevados de los clasificadores vienen por el uso de las ventanas de 2x2 o de 4x4. El valor más alto nos lo da el clasificador K-NN ponderado con ventana de 2x2.



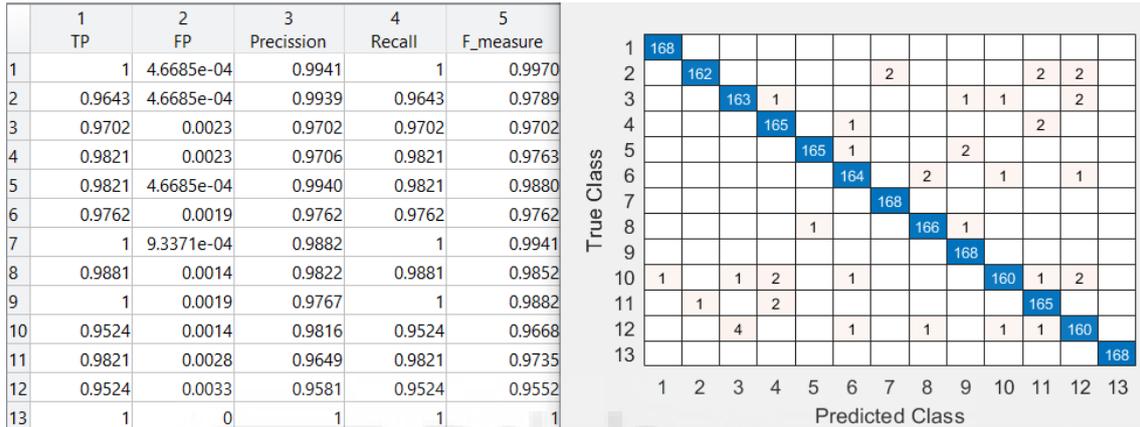
Gráfica 332. Validación del modelo elegido de la gráfica 331

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en colores opuestos para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 332.



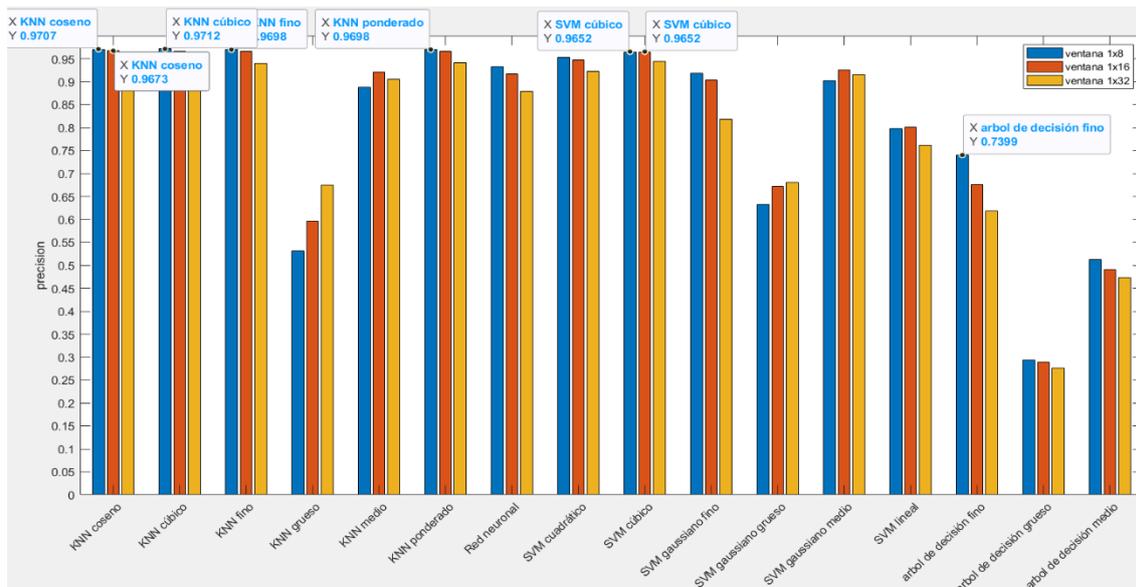
Gráfica 333. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en colores opuestos

En la gráfica 333 la ventana de 8x1 es la que consigue el mejor resultado en la mayoría de los clasificadores usando LBP invariante a rotación con radio 5 en colores opuestos, pero dista muy poco de los valores para una ventana de 16x1. El mejor clasificador es el K-NN ponderado para ventana de 8x1, pero para esta misma ventana el K-NN fino también proporciona un resultado muy similar.



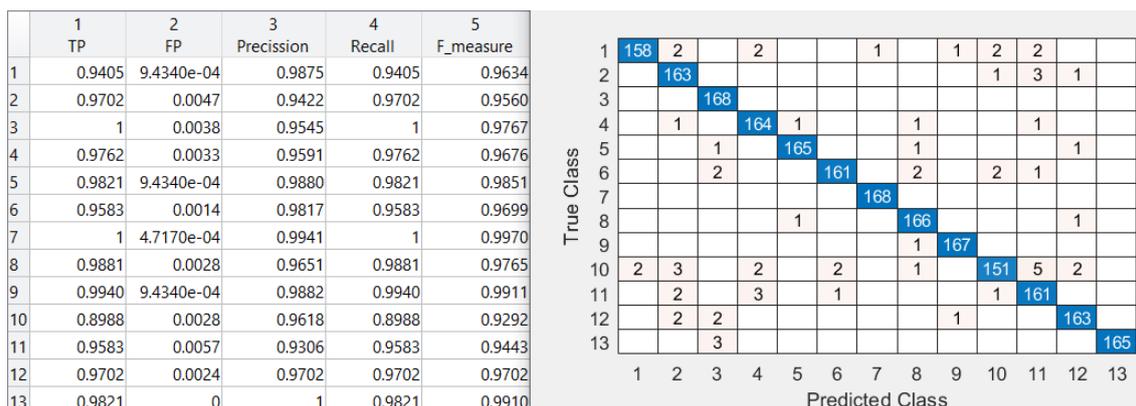
Gráfica 334. Validación del modelo elegido de la gráfica 333

Sacamos del clasificador K-NN ponderado esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en colores opuestos para ventanas en filas de la gráfica 334.



Gráfica 335. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en colores opuestos

En la gráfica 335 el mejor resultado nos lo da el clasificador K-NN cúbico para ventana de 1x8 usando LBP invariante a rotación con radio 5 en colores opuestos. También hay que mencionar que el K-NN coseno tiene un valor semejante usando el mismo tamaño de ventana. Por último, es apreciable que a medida que la ventana se hace más pequeña la precisión también se reduce en la mayoría de los clasificadores.

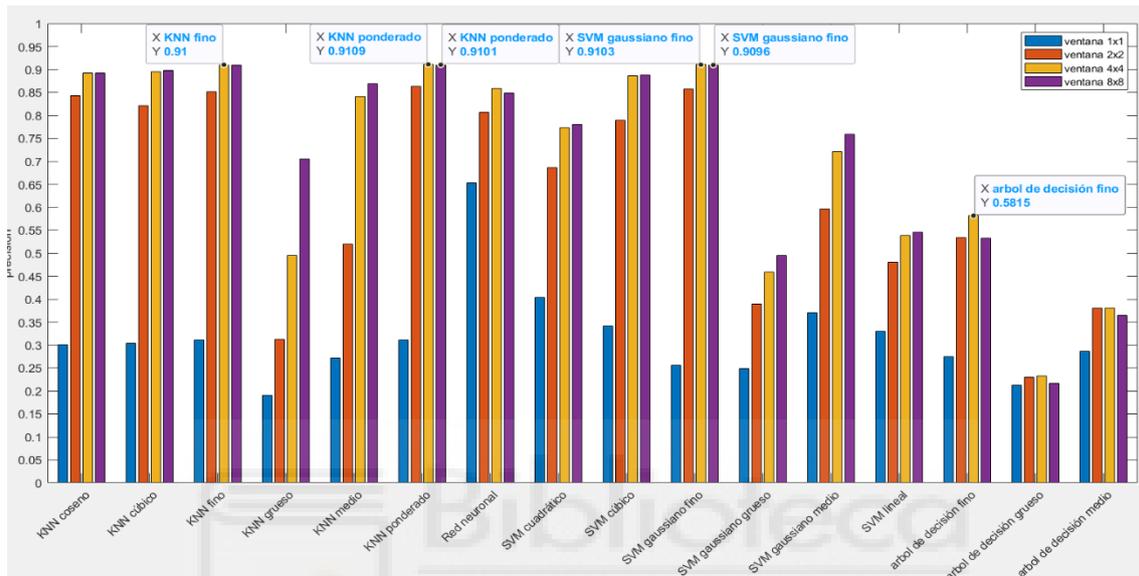


Gráfica 336. Validación del modelo elegido de la gráfica 335

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en colores opuestos para ventanas en columnas, es del clasificador K-NN cúbico de la gráfica 336.

Visto los resultados anteriores, el clasificador K-NN ponderado es el que mejor se comporta usando LBP invariante a rotación con radio 5 en colores opuestos y una ventana de 2x2.

#### 4.1.8 Comparación en HSV con el tercer data set



Gráfica 337. Comparación clasificadores para ventanas cuadradas para momentos de histograma en HSV

En la gráfica 337, usando los momentos de histograma en HSV para ventanas cuadradas vemos que el mejor resultado de cada clasificador suele darse en la ventana de 4x4. También se puede observar que resultado más alto viene por parte del clasificador K-NN ponderado con una ventana de 4x4. Cabe destacar que el clasificador SVM gaussiano fino alcanza un valor elevado y cercano al anterior.

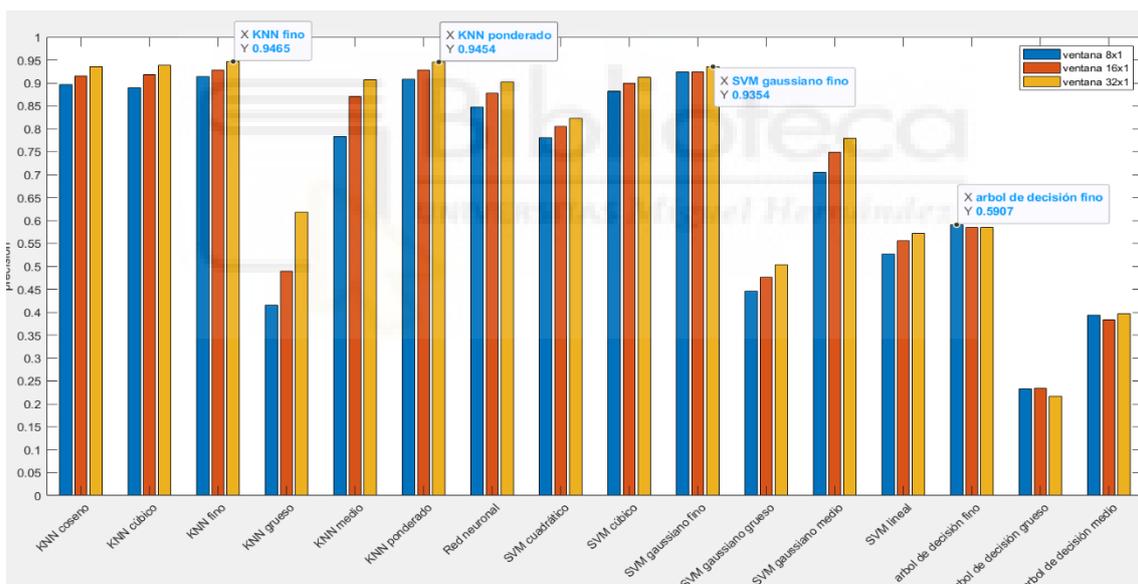
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9643	0.0053	0.9391	0.9643	0.9515
2	0.9435	0.0023	0.9724	0.9435	0.9577
3	0.9435	0.0138	0.8522	0.9435	0.8955
4	0.9435	0.0085	0.9031	0.9435	0.9229
5	0.8988	0.0118	0.8653	0.8988	0.8818
6	0.9107	0.0075	0.9107	0.9107	0.9107
7	0.9911	0.0020	0.9765	0.9911	0.9838
8	0.9107	0.0093	0.8921	0.9107	0.9013
9	0.9107	0.0108	0.8768	0.9107	0.8934
10	0.7857	0.0073	0.9010	0.7857	0.8394
11	0.8065	0.0053	0.9281	0.8065	0.8631
12	0.8958	0.0030	0.9617	0.8958	0.9276
13	0.9345	0.0111	0.8771	0.9345	0.9049

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	324	1	1	6					1	1	1	1	
2	5	317	2	2					2	2	1	5	
3		1	317	7			1	1	2	2	3		2
4	5		6	317	2	1	3						2
5			5	1	302	2		9	4	1	2	4	6
6			7	4	5	306		3	6	1		2	2
7			1				333				2		
8			4	1	7	4		306	6	5	2		1
9	1		2		5	2	1	4	306	4	3		8
10	5	1	11	10	10	8		8	4	264	5	2	8
11	5	3	11	3	6	2	4	8	9	7	271	1	6
12		2	2		6	8		3	6	4	1	301	3
13		1	3		6	2		1	6	2		1	314

Gráfica 338. Validación del modelo elegido de la gráfica 337

Esta representación de la matriz de confusión y las tasas de acierto y error, para los momentos de histograma en HSV para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 338.



Gráfica 339. Comparación clasificadores para ventanas en filas para momentos de histograma en HSV

En la gráfica 339, siguiendo con el análisis en ventanas en filas, vemos que el K-NN fino para ventanas de 32x1 es el que mejor precisión tiene usando momentos de histograma en HSV, pero hay que mencionar que el valor del K-NN ponderado para ventana de 32x1 está muy próximo. También vemos que los mejores resultados de los clasificadores, generalmente, se produce en las ventanas de 32x1.

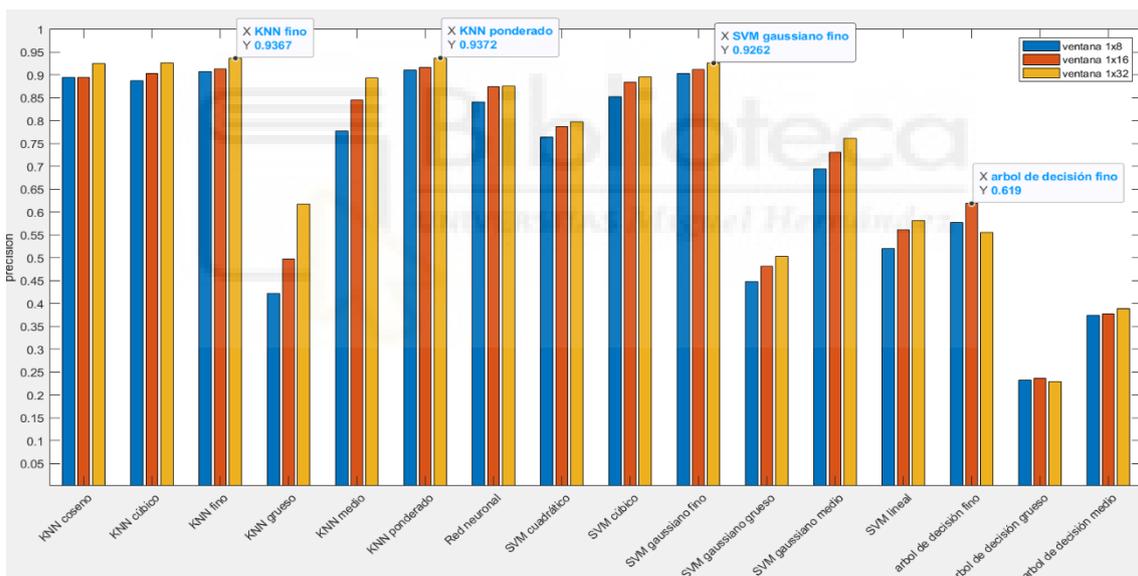
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9524	0.0173	0.8195	0.9524	0.8809
2	0.9494	0.0042	0.9494	0.9494	0.9494
3	0.9271	0.0051	0.9368	0.9271	0.9319
4	0.9241	0.0058	0.9296	0.9241	0.9269
5	0.9271	0.0034	0.9570	0.9271	0.9418
6	0.9033	0.0061	0.9239	0.9033	0.9135
7	0.9717	0.0012	0.9849	0.9717	0.9783
8	0.9375	0.0054	0.9347	0.9375	0.9361
9	0.9554	0.0045	0.9455	0.9554	0.9504
10	0.8854	0.0064	0.9196	0.8854	0.9022
11	0.9375	0.0038	0.9531	0.9375	0.9452
12	0.9345	0.0023	0.9706	0.9345	0.9522
13	0.9420	0.0047	0.9434	0.9420	0.9427

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	640	3	2	10	2	3		4		3	2	1	2
2	10	638	2	6		5	4	1	1	2	1	1	1
3	13	1	623	1	2	2	1	1	2	4	8	2	12
4	24	4	1	621		6		2	2	10	1	1	
5	10	2	2		623	2		8	2	2	6	5	10
6	7	2	9	3	2	607		9	14	11	1	2	5
7	11	3	1				653	1		1	1	1	
8	8	2	2	2	6	8	1	630	3	7	1	1	1
9	7	2	1		3	4		3	642	1	2	2	5
10	12	4	8	16	6	9	1	7	3	595	6	3	2
11	14	4	4	4		5	1	3	3	4	630		
12	12	6	3	2	2	5	1	2	6	3	2	628	
13	13	1	7	3	5	1	1	3	1	4			633

Gráfica 340. Validación del modelo elegido de la gráfica 339

Usaremos el clasificador con más precisión, el K-NN fino, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en HSV para ventanas en columna de la gráfica 440.



Gráfica 341. Comparación clasificadores para ventanas en columnas para momentos de histograma en HSV

vemos en la gráfica 441 que el clasificador que más precisión tiene, usando momentos de histograma en HSV, es el K-NN ponderado para ventanas de 1x32, seguido muy de cerca por el K-NN fino para la misma ventana. En la mayoría de los clasificadores, es en esta ventana en la que mejor precisión alcanzan.

	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.8914	0.0145	0.8354	0.8914	0.8625
2	0.9539	0.0034	0.9581	0.9539	0.9560
3	0.9583	0.0080	0.9083	0.9583	0.9327
4	0.9509	0.0078	0.9103	0.9509	0.9301
5	0.9330	0.0042	0.9486	0.9330	0.9407
6	0.8854	0.0069	0.9140	0.8854	0.8995
7	0.9777	7.3892e-04	0.9910	0.9777	0.9843
8	0.9375	0.0054	0.9347	0.9375	0.9361
9	0.9509	0.0049	0.9411	0.9509	0.9460
10	0.8140	0.0084	0.8894	0.8140	0.8500
11	0.9152	0.0047	0.9418	0.9152	0.9283
12	0.9524	0.0028	0.9653	0.9524	0.9588
13	0.9628	0.0041	0.9515	0.9628	0.9571

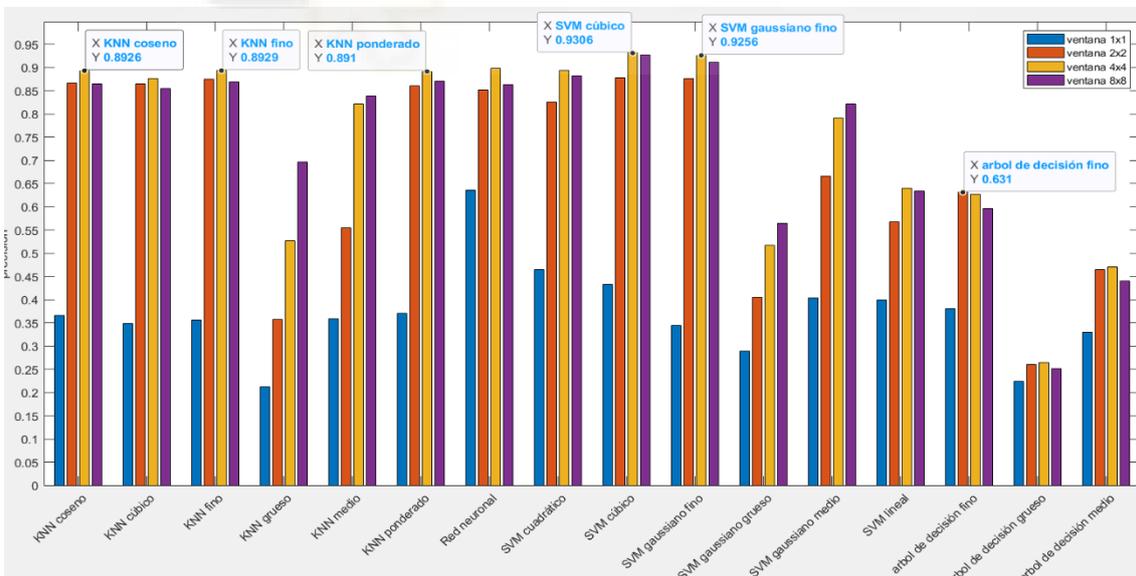
  

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	599	9	2	25	2	7	1	3		19	3		2
2	9	641	7	2		2	2			3	4	2	
3	7	3	644		1	2	2	1	6	1	1	2	2
4	18	2		639		4				4	2		1
5	7	2	2	2	627	2		5	3	5	3	1	13
6	11		7	11	5	595		17	8	8	3	4	3
7	12		1				657			1	1		
8	6	2	3		4	12		630	6	3	1	3	2
9	4	2	4	1	2	4		3	639	2	1	7	3
10	24	1	17	18	10	18		7	5	547	18	3	4
11	12	5	8	3	6			1	2	17	615	1	2
12	3	2	2		2	5	1	3	9	3	1	640	1
13	5		12	1	2			2	1	2			647

Gráfica 342. Validación del modelo elegido de la gráfica 341

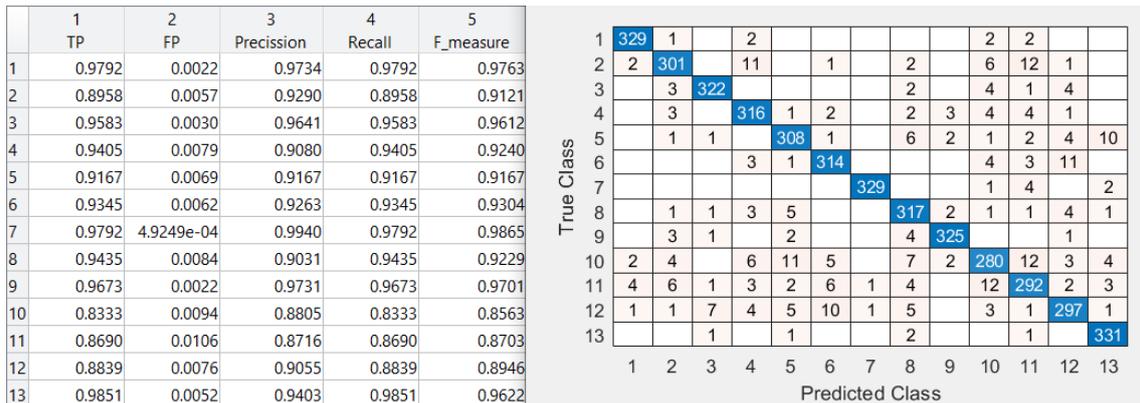
Usaremos el clasificador con más precisión, el K-NN ponderado, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en HSV para ventanas en columna de la gráfica 342.

Después de ver todas las gráficas, el clasificador K-NN fino para ventanas de 32x1 es el que mayor precisión nos da, pero el K-NN ponderado ha demostrado tener un comportamiento bueno en todas la ventanas y un valor cercano para la 32x1.



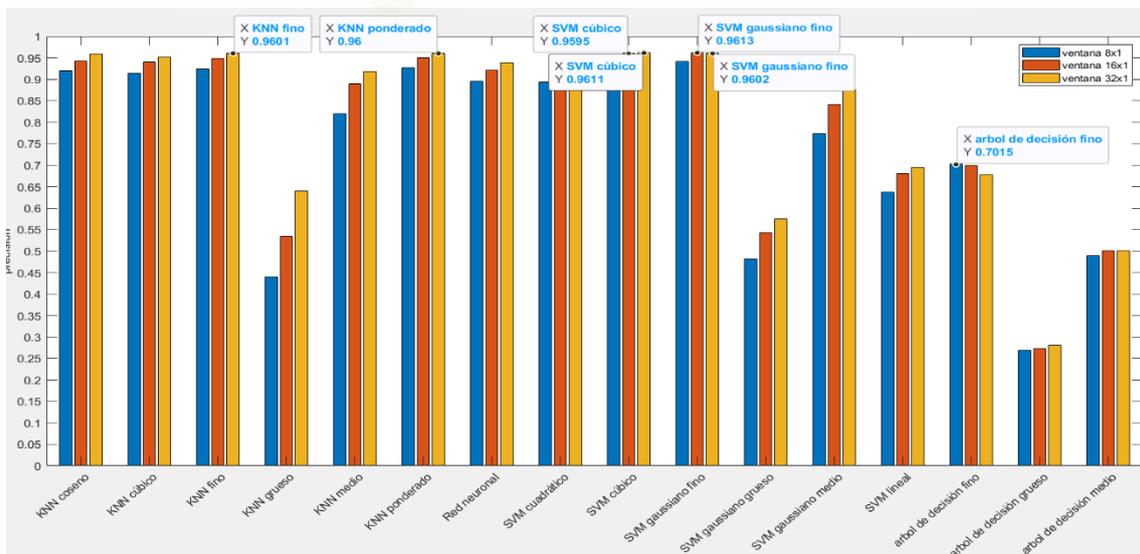
Gráfica 343. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en HSV

Generalmente en la gráfica 343, el mejor resultado se suele producir en la ventana 4x4, dependiendo del clasificador. Entonces, usando la matriz de coocurrencia en HSV, el clasificador SVM cúbico para la ventana de 4x4 es el que mejor resultado nos ofrece, sin embargo, cabe destacar que para el SVM gaussiano fino usando ventanas 4x4 el valor es muy próximo al anterior.



Gráfica 344. Validación del modelo elegido de la gráfica 343

Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en HSV para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 344.



Gráfica 345. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en HSV

Vemos en la gráfica 345 que usando la matriz de coocurrencia en HSV el clasificador SVM gaussiano fino es el que mejor se comporta cuando escogemos

la ventana 16x1. Pero este valor máximo no difiere mucho del conseguido con el mismo clasificador, pero para ventana de 32x1 o para el SVM cúbico para 32x1.

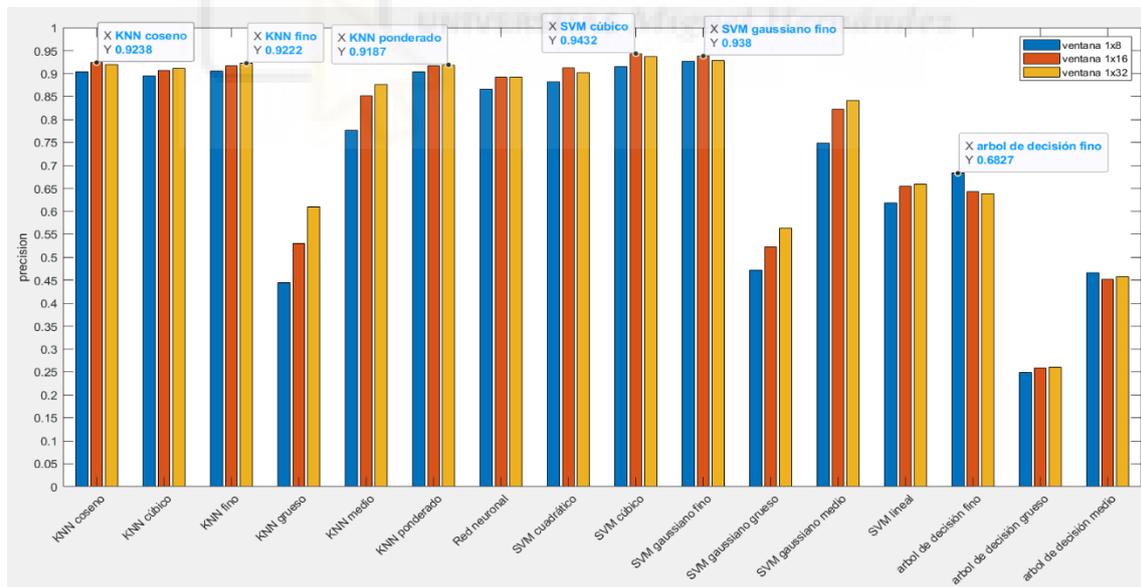
	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	0.9792	0.0022	0.9734	0.9792	0.9763
2	0.8958	0.0057	0.9290	0.8958	0.9121
3	0.9583	0.0030	0.9641	0.9583	0.9612
4	0.9405	0.0079	0.9080	0.9405	0.9240
5	0.9167	0.0069	0.9167	0.9167	0.9167
6	0.9345	0.0062	0.9263	0.9345	0.9304
7	0.9792	4.9249e-04	0.9940	0.9792	0.9865
8	0.9435	0.0084	0.9031	0.9435	0.9229
9	0.9673	0.0022	0.9731	0.9673	0.9701
10	0.8333	0.0094	0.8805	0.8333	0.8563
11	0.8690	0.0106	0.8716	0.8690	0.8703
12	0.8839	0.0076	0.9055	0.8839	0.8946
13	0.9851	0.0052	0.9403	0.9851	0.9622

True Class \ Predicted Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	329	1	2						2	2			
2	2	301		11			1		2		6	12	1
3	3	322							2		4	1	4
4		3	316	1	2			2	3	4	4	1	
5		1	1		308	1		6	2	1	2	4	10
6				3	1	314				4	3	11	
7							329			1	4		2
8		1	1	3	5			317	2	1	1	4	1
9		3	1		2			4	325				1
10	2	4		6	11	5		7	2	280	12	3	4
11	4	6	1	3	2	6	1	4		12	292	2	3
12	1	1	7	4	5	10	1	5		3	1	297	1
13			1	1	1			2					331

Gráfica 346. Validación del modelo elegido de la gráfica 345

Sacamos del clasificador SVM gaussiano fino esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en HSV para ventanas en filas de la gráfica 346.



Gráfica 347. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en HSV

La gráfica 347 muestra el comportamiento de los clasificadores cuando usamos las ventanas en columna con la matriz de coocurrencia en HSV, vemos que el

mejor resultado nos lo da el SVM cúbico para ventanas de 1x16 seguido muy de cerca por el resultado del mismo clasificador para ventanas de 1x32 y el SVM gaussiano fino para ventanas de 1x16.

	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	0.9286	0.0022	0.9720	0.9286	0.9498
2	0.8958	0.0041	0.9465	0.8958	0.9205
3	0.9762	0.0041	0.9507	0.9762	0.9633
4	0.9613	0.0041	0.9500	0.9613	0.9556
5	0.9613	0.0024	0.9700	0.9613	0.9656
6	0.9018	0.0068	0.9154	0.9018	0.9085
7	0.9702	0.0015	0.9819	0.9702	0.9760
8	0.9702	0.0058	0.9314	0.9702	0.9504
9	0.9881	0.0022	0.9736	0.9881	0.9808
10	0.8452	0.0099	0.8738	0.8452	0.8593
11	0.9464	0.0097	0.8883	0.9464	0.9164
12	0.9613	0.0041	0.9500	0.9613	0.9556
13	0.9702	0.0019	0.9760	0.9702	0.9731

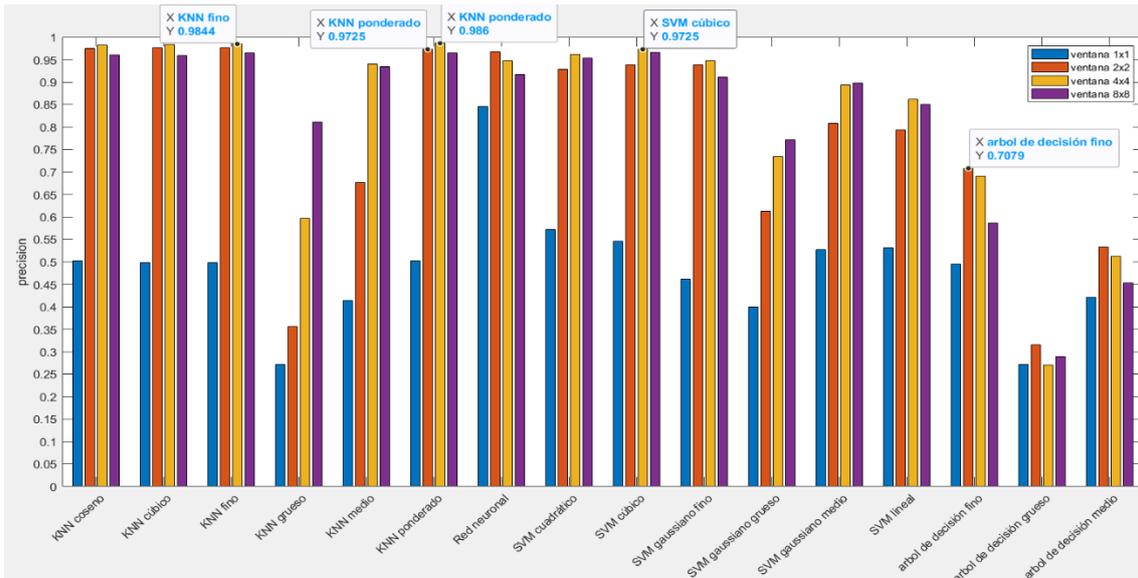
  

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	312	1	3	2		3	1			7	4	2	1
2	1	301		2		8		5		6	13		
3	2	2	328							2	1		1
4		1		323		2			4	4	2		
5			3		323	3		1	2	2			2
6	2	1	1	3	3	303		2		11	4	6	
7	3		3			1	326				2		1
8		3	1	1	1			326	2			1	1
9		2						2	332				
10	4	3	4	1	5	1	11			284	14	8	1
11	1		4	1	3	1		1	6	318			1
12		2	2	1	2	1	3	1		1		323	
13	1		1		2	2		2		2			326
	1	2	3	4	5	6	7	8	9	10	11	12	13
	Predicted Class												

Gráfica 348. Validación del modelo elegido de la gráfica 347

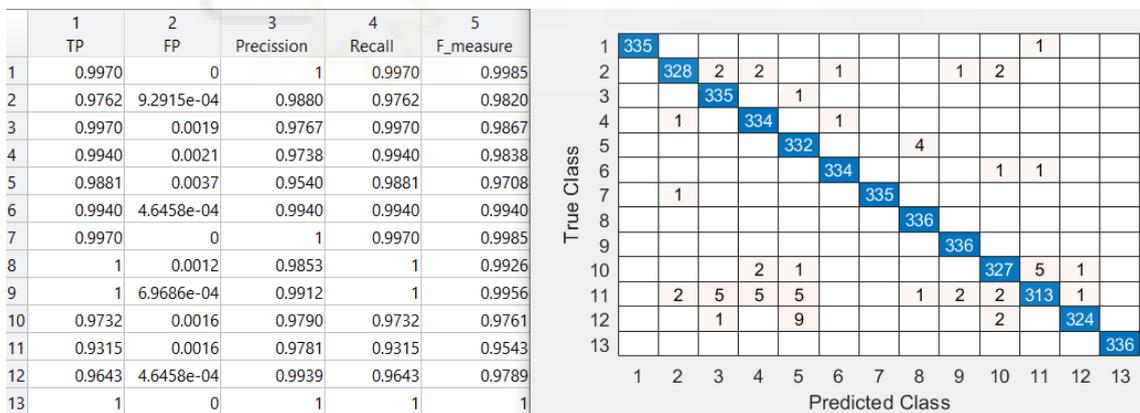
Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en HSV para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 348.

Una vez vistos los resultados anteriores, el clasificador con el valor más alto es el SVM gaussiano fino con ventana de 16x1, cabe destacar que es el SVM cúbico él se comporta muy bien, incluso, en el resto de tipos de ventanas.



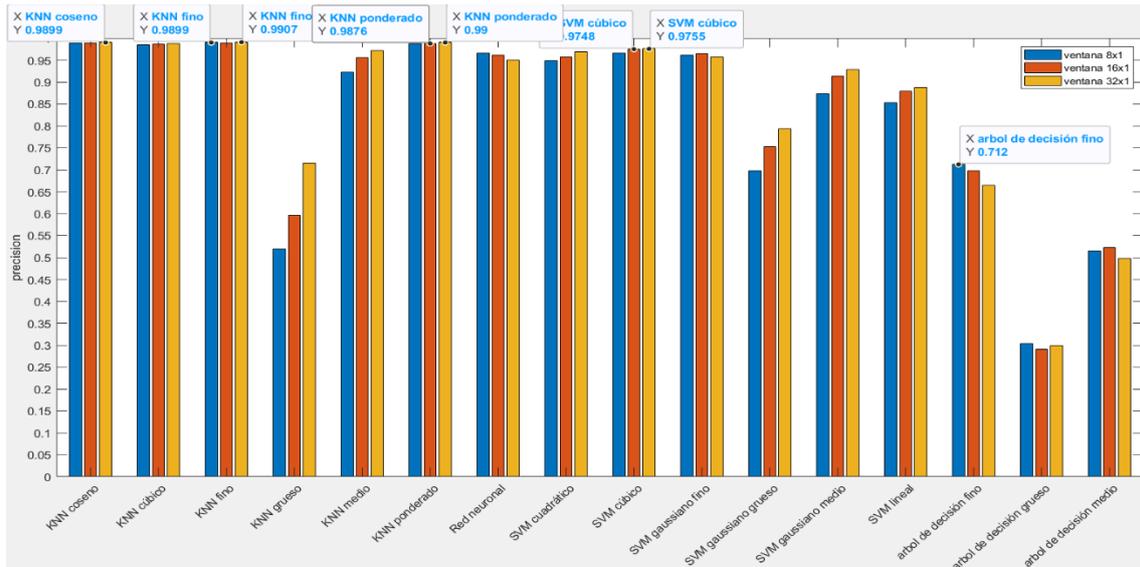
Gráfica 349. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en HSV

En la gráfica 349, usando LBP variante a rotación en HSV vemos que, en la mayoría de los clasificadores, la ventana 4x4 es con la que mejor precisión se obtiene, siendo el clasificador K-NN ponderado el que mayor precisión tiene usando la ventana de 4x4.



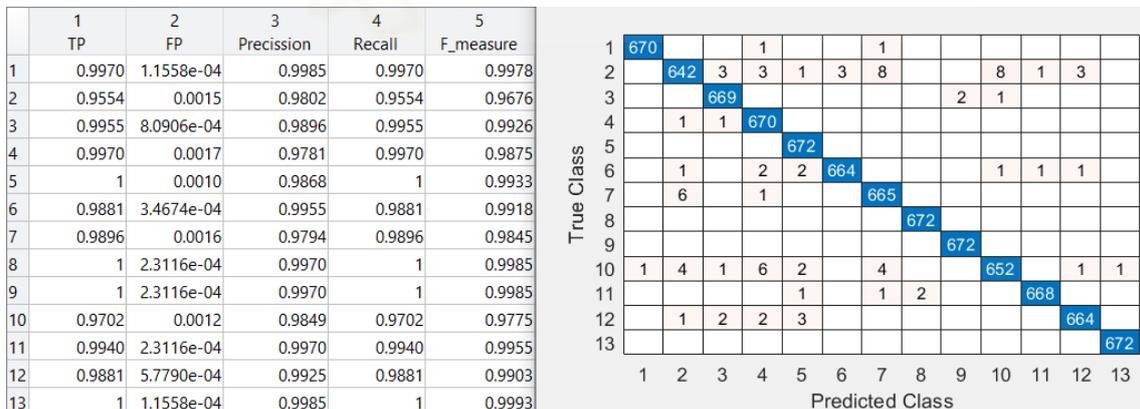
Gráfica 350. Validación del modelo elegido de la gráfica 349

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en HSV para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 350.



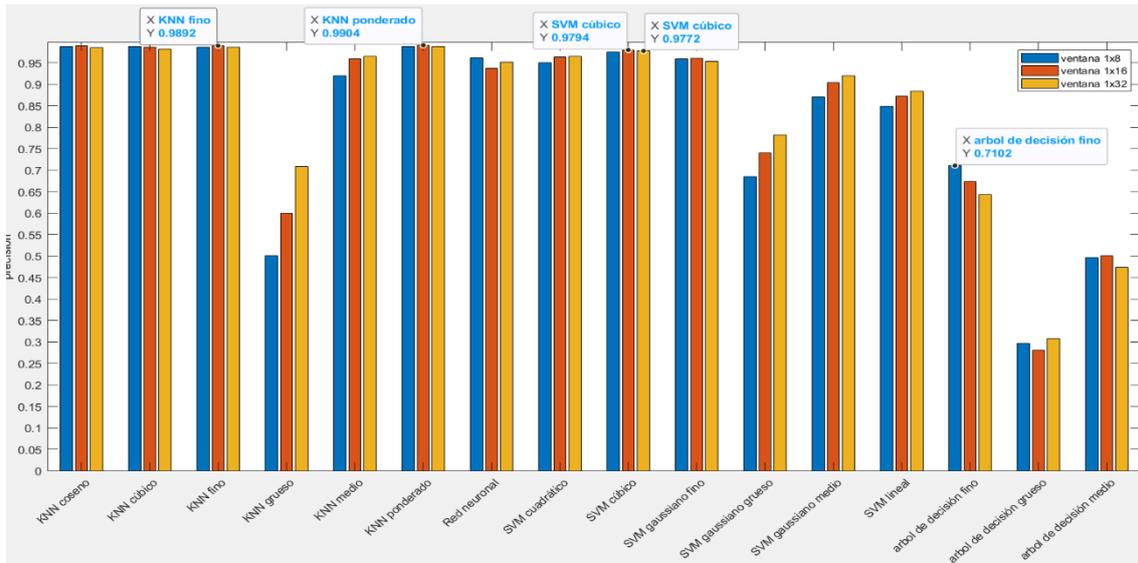
Gráfica 351. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 1 en HSV

La mayoría de los clasificadores tienen valores similares para las distintas ventanas. Tenemos en la gráfica 351 que, usando LBP variante a rotación con radio 1, el K-NN fino es el de mayor precisión con ventana de 32x1, pero el valor de este es muy cercano al ofrecido por el K-NN ponderado o por el K-NN coseno para el mismo tamaño de ventana.



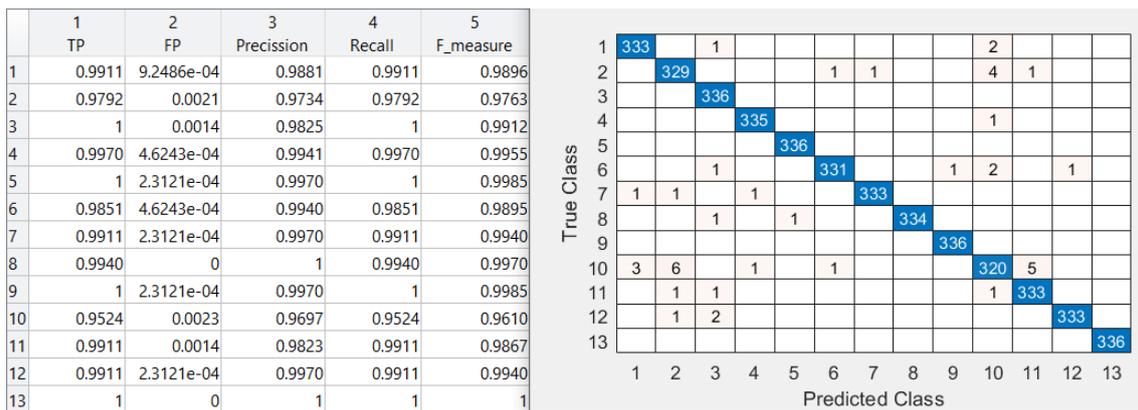
Gráfica 352. Validación del modelo elegido de la gráfica 351

Sacamos del clasificador K-NN fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en HSV para ventanas en filas de la gráfica 352.



Gráfica 353. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en HSV

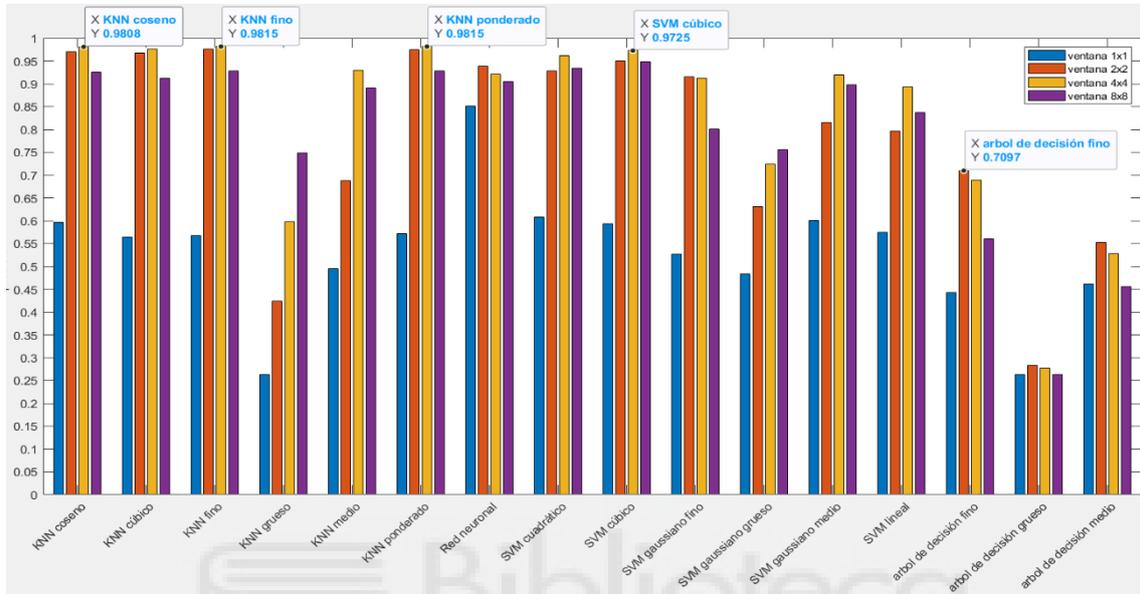
Vemos en la gráfica 353 que al analizar las ventanas en columna para LBP variante a rotación con radio 1 en HSV los valores de un mismo clasificador las diferentes ventanas tienen valores cercanos, hay excepciones. El mejor resultado es alcanzado por el clasificador K-NN ponderado para ventana de 1x16, seguido muy de cerca por el K-NN fino para la misma ventana, ya que es en esa en la que la mayoría de los clasificadores adquieren su valor máximo.



Gráfica 354. Validación del modelo elegido de la gráfica 353

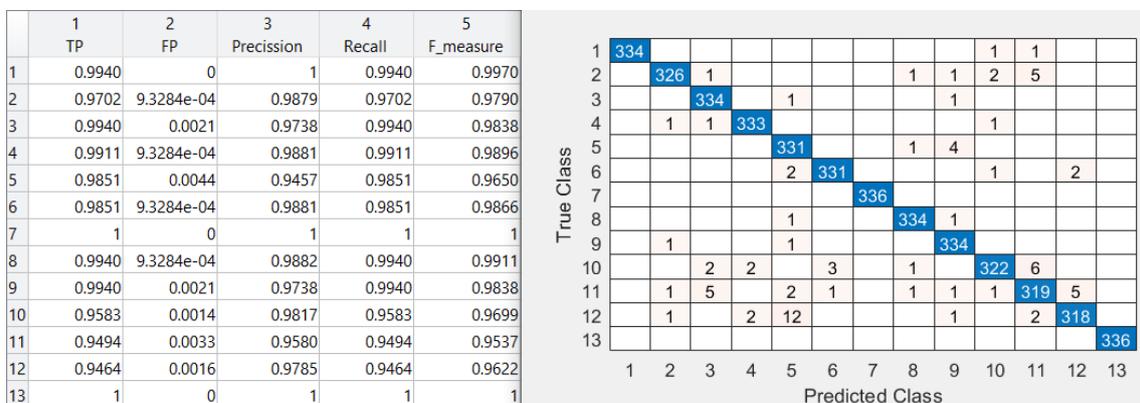
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en HSV para ventanas en columnas, es del clasificador K-NN ponderado de la gráfica 354.

Queda claro que el clasificador K-NN fino es el que, independientemente de la ventana, siempre alcanza un resultado muy bueno respecto al resto de clasificadores. Siendo para la ventana 32x1 el de mayor valor para LBP variante a rotación con radio 1 en HSV.



Gráfica 355. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en HSV

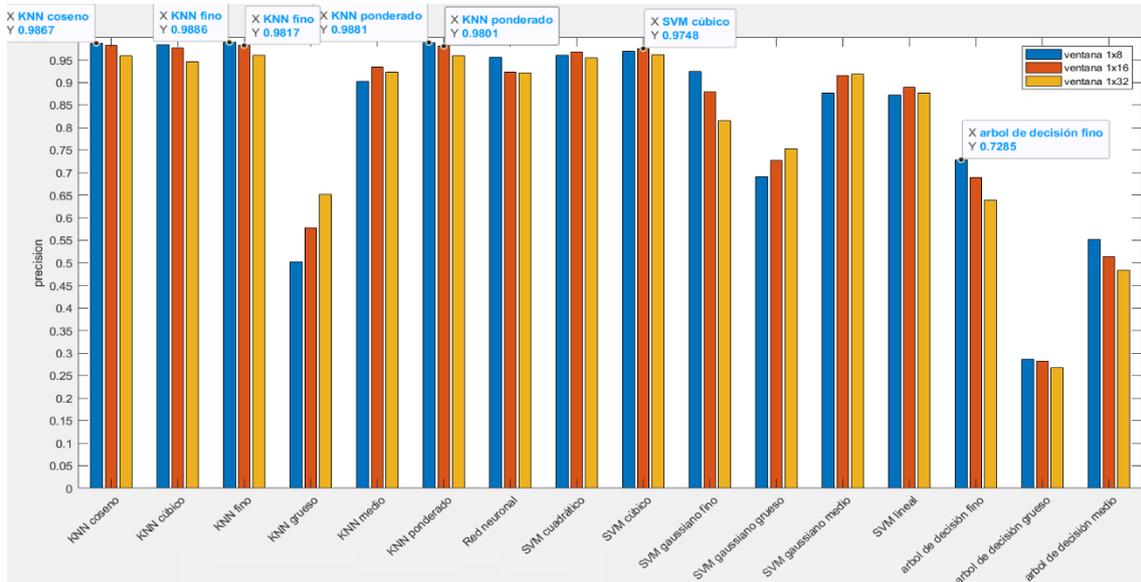
En la gráfica 355, usando LBP variante a rotación con radio 3 en HSV los valores más altos en general se encuentran cuando usamos ventanas de 4x4, siendo esta ventana la que logran la mayor precisión con el clasificador K-NN fino y K-NN ponderado, seguidos muy de cerca por el K-NN coseno.



Gráfica 356. Validación del modelo elegido de la gráfica 355

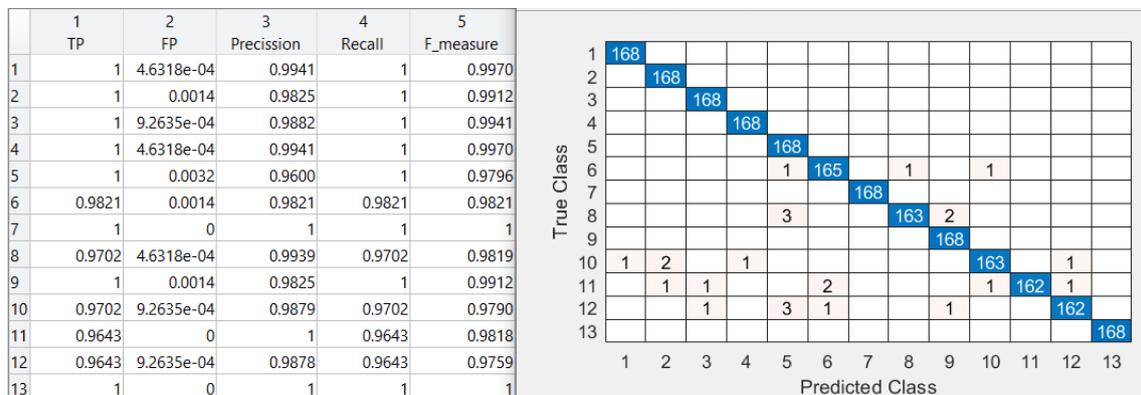


Sacamos del clasificador fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en HSV para ventanas en filas de la gráfica 358.



Gráfica 359. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en HSV

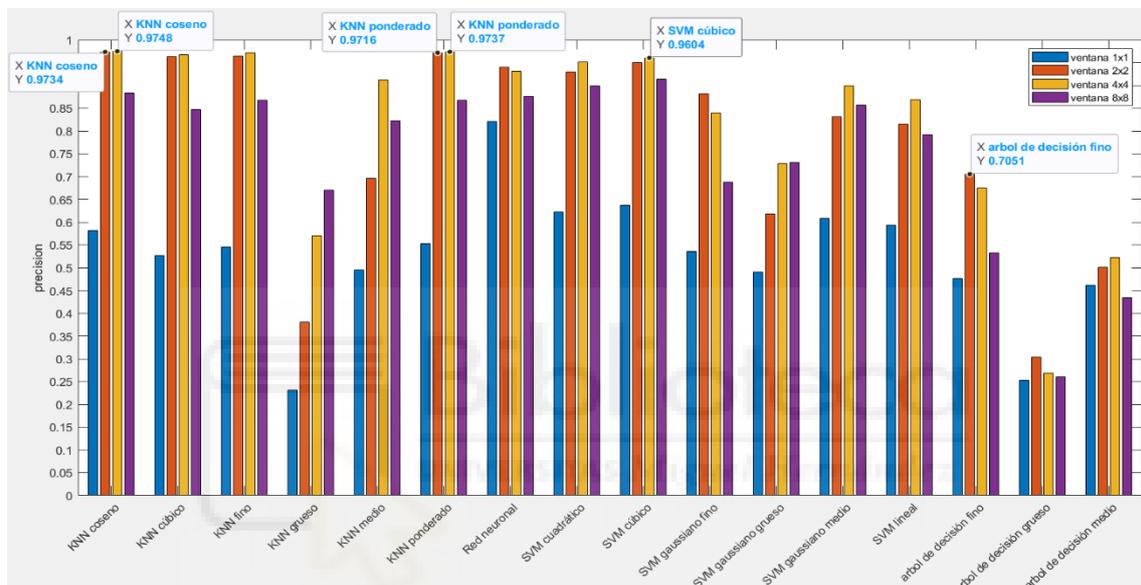
Podemos observar en la gráfica 359 que los resultados para los diferentes tamaños de ventana, usando LBP variante a rotación con radio 3 en HSV, son muy cercanos en la mayoría de clasificadores. Para estas ventanas el clasificador K-NN fino es el que mayor valor alcanza, seguido de cerca por el K-NN coseno y el K-NN ponderado con ventana de 1x8.



Gráfica 360. Validación del modelo elegido de la gráfica 359

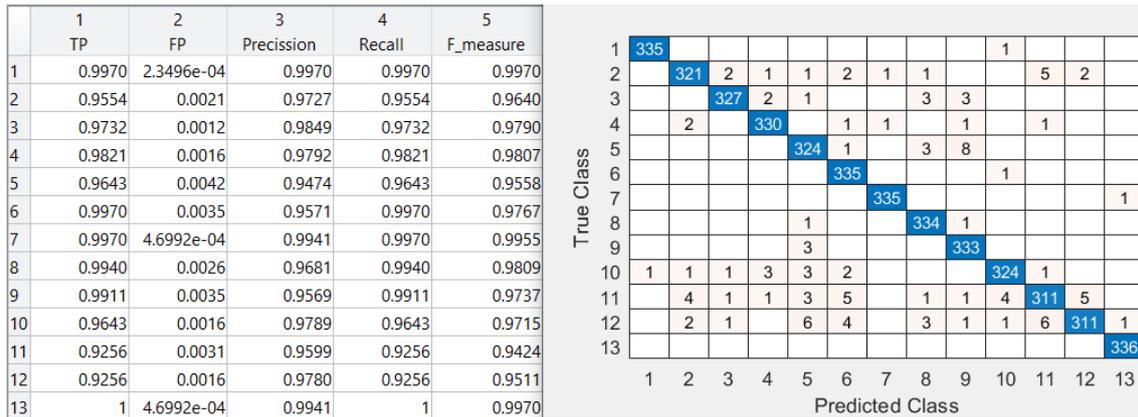
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en HSV para ventanas en columnas, es del clasificador K-NN fino de la gráfica 360.

Hemos comprobado que para LBP variante a rotación con radio 3 en HSV el clasificador K-NN fino es el que mejor se comporta con una ventana de 1x8, aunque no solo lo hace para un tipo de ventana. Es por eso que se considera este clasificador el mejor para este caso.



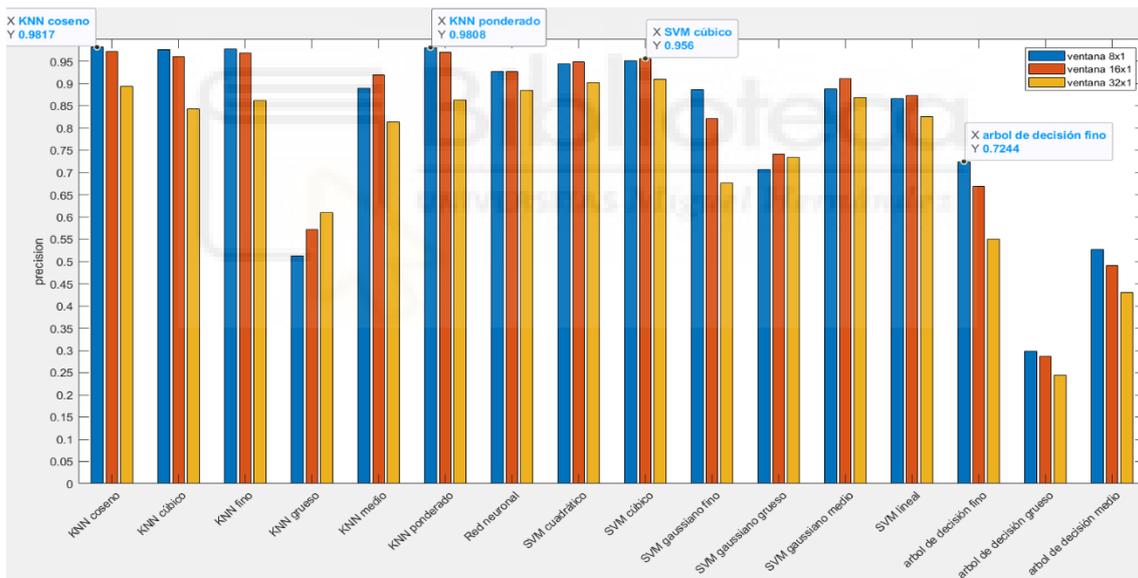
Gráfica 361. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en HSV

Ahora analizaremos en la gráfica 361 para ventanas cuadradas el uso de LBP variante a rotación con radio 5 en HSV, el valor más alto está localizado en la ventana 4x4 del clasificador K-NN coseno. Hay que mencionar, que este valor máximo es muy cercano al valor ofrecido por el mismo clasificador para ventana de 2x2 y por el K-NN ponderado usando una ventana de 4x4.



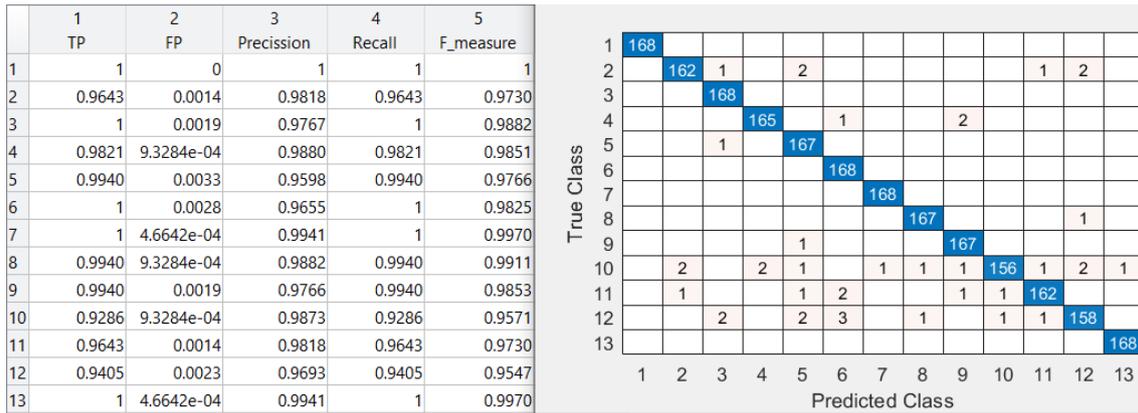
Gráfica 362. Validación del modelo elegido de la gráfica 361

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en HSV para ventanas cuadradas, es del clasificador K-NN coseno de la gráfica 361.



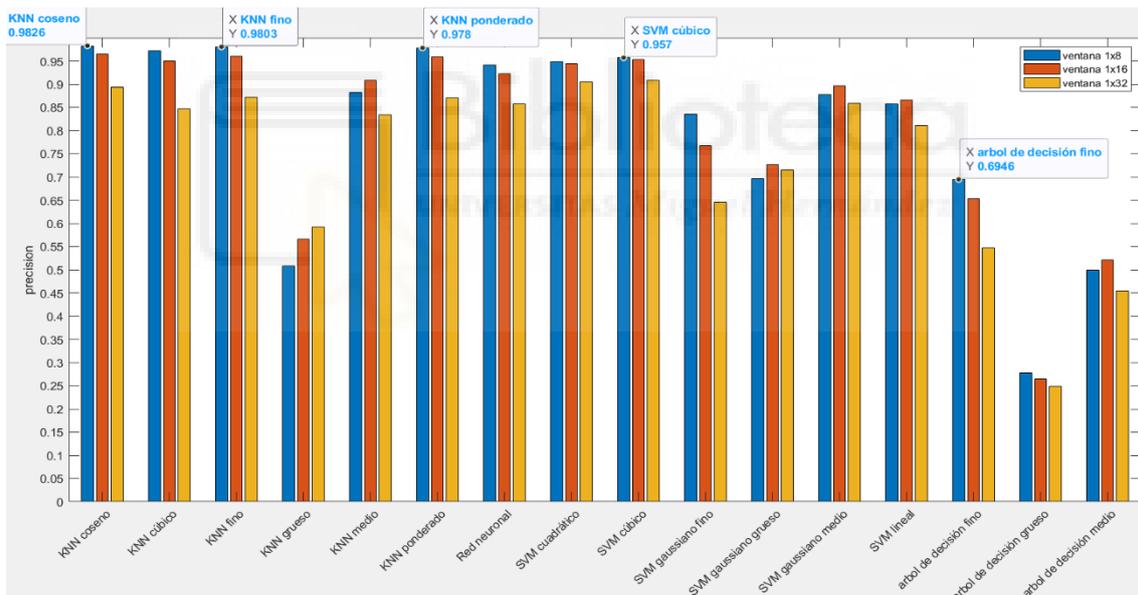
Gráfica 363. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en HSV

En la gráfica 363 el mejor clasificador, usando LBP variante a rotación con radio 5 en HSV con ventanas en fila, es el K-NN coseno para ventanas de 8x1, seguido con muy poca diferencia del K-NN ponderado. También, podemos ver como a medida que se disminuye el tamaño de la ventana también disminuye la precisión del clasificador.



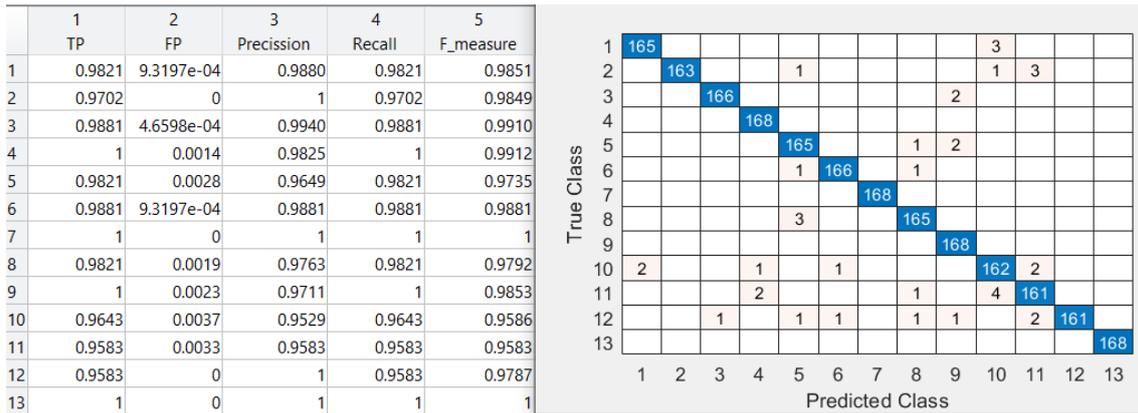
Gráfica 364. Validación del modelo elegido de la gráfica 363

Sacamos del clasificador K-NN coseno esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en HSV para ventanas en filas de la gráfica 364.



Gráfica 365. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en HSV

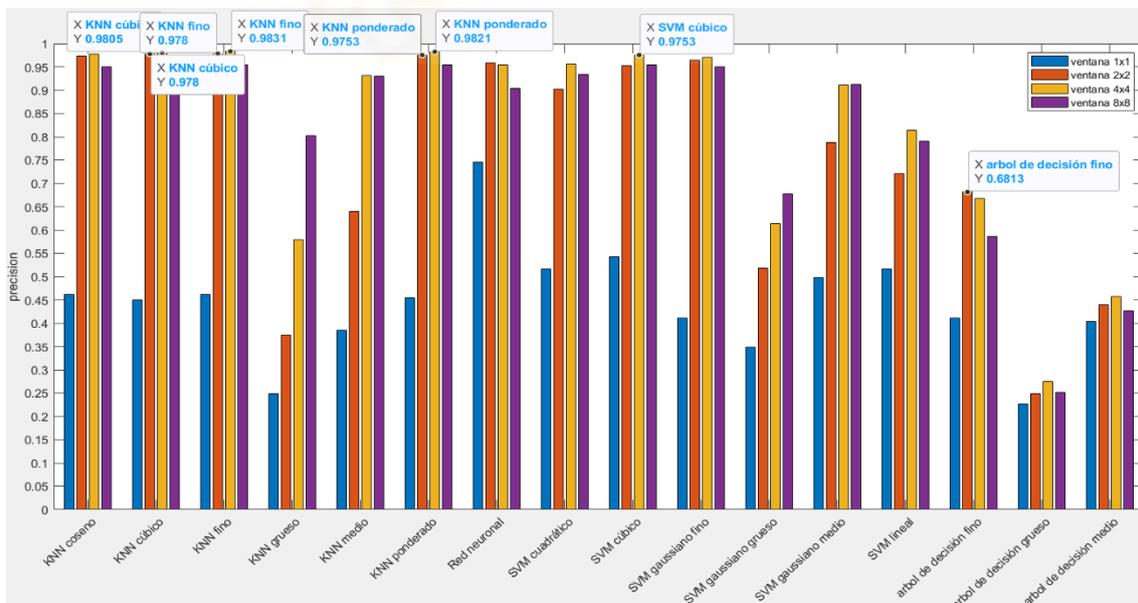
Terminando de analizar el LBP variante a rotación con radio 5 en HSV, vemos en la gráfica 365 que, en general, para ventanas en columnas los clasificadores se comportan mejor para el tamaño de 1x8 y conforme este tamaño disminuye, el resultado empeora. El mejor resultado lo encontramos en el clasificador K-NN coseno para la ventana de 1x8.



Gráfica 366. Validación del modelo elegido de la gráfica 365

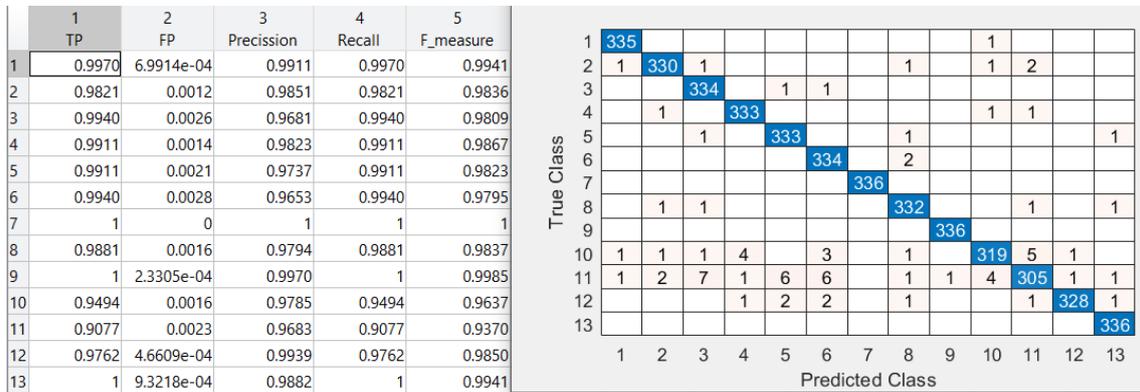
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en HSV para ventanas en columnas, es del clasificador K-NN coseno de la gráfica 366.

Viendo el comportamiento de los clasificadores usando LBP variante a rotación con radio 5 en HSV, que el clasificador K-NN coseno es el que por lo general mejor se comporta, y, específicamente, para la ventana de 1x8 es el resultado más alto.



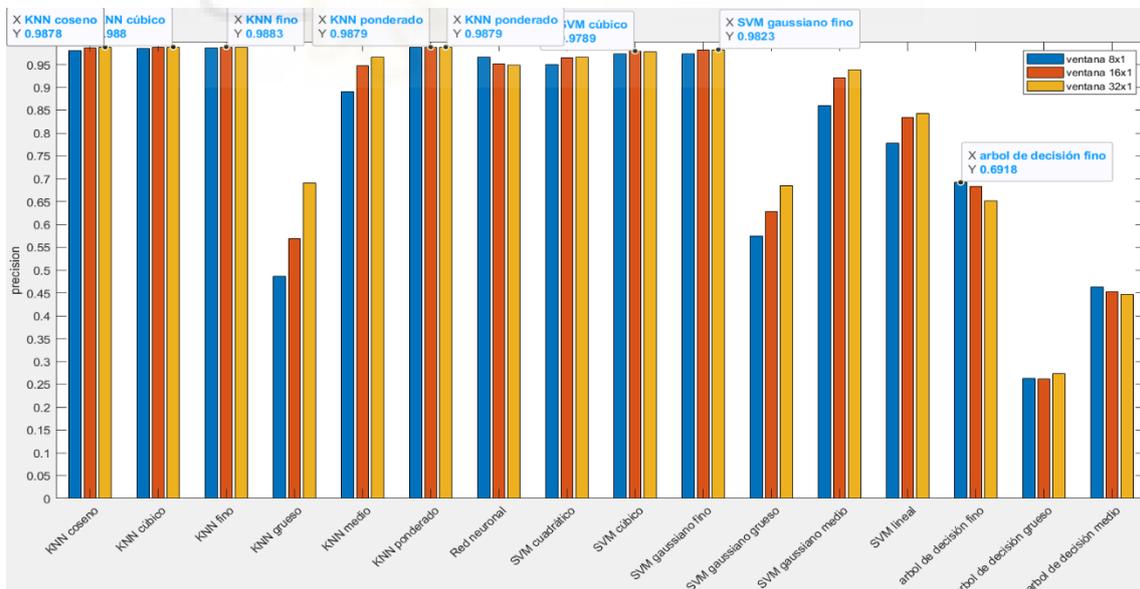
Gráfica 367. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en HSV

Ahora, usando LBP invariante a rotación con radio 1 en HSV, vemos en la gráfica 367 que la mayoría los clasificadores adquieren una mayor precisión cuando se usa la ventana de 4x4, siendo el K-NN fino el que mayor precisión alcanza, seguido muy de cerca del K-NN ponderado para una ventana de 4x4.



Gráfica 368. Validación del modelo elegido de la gráfica 367

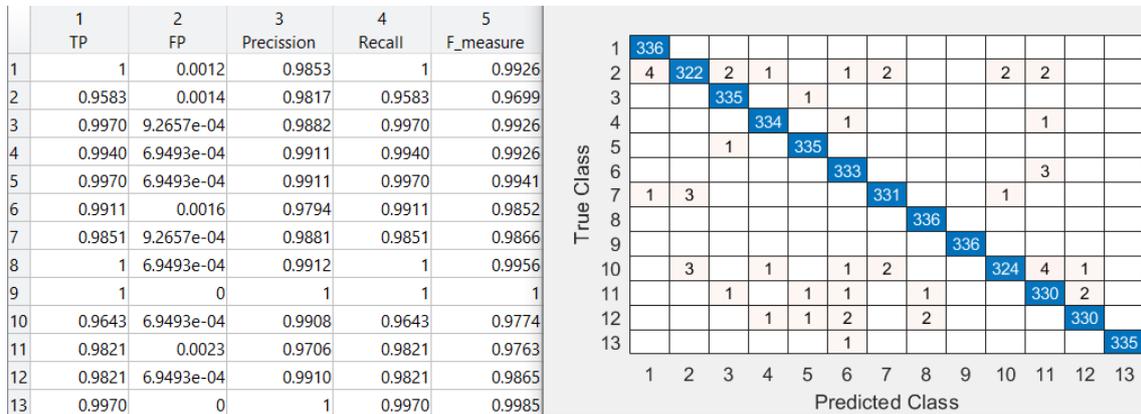
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en HSV para ventanas cuadradas, es del clasificador K-NN fino de la gráfica 368.



Gráfica 369. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en HSV

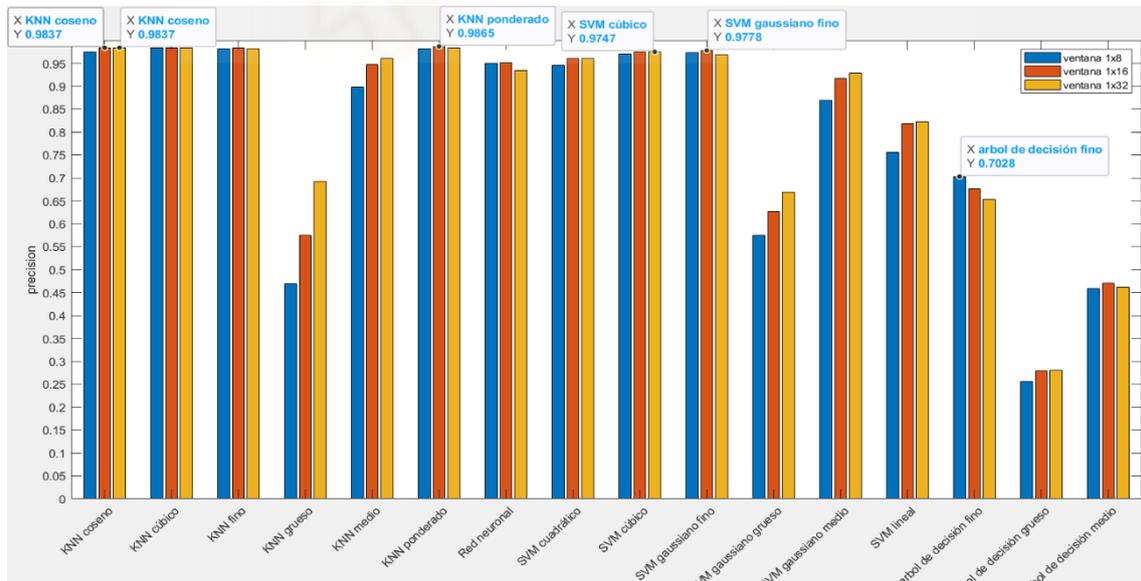
En muchos clasificadores vemos en la gráfica 369 que los valores en cada ventana son muy parecidos entre sí. Por eso, el clasificador que, usando LBP

invariante a rotación con radio 1 en HSV, tiene la mayor precisión dista muy poco del mismo clasificador, pero para otra ventana. El K-NN fino para ventana de 16x1 es el de mayor precisión y, seguido muy de cerca, por los valores de otros clasificadores como K-NN cúbico o K-NN coseno para ventana de 32x1.



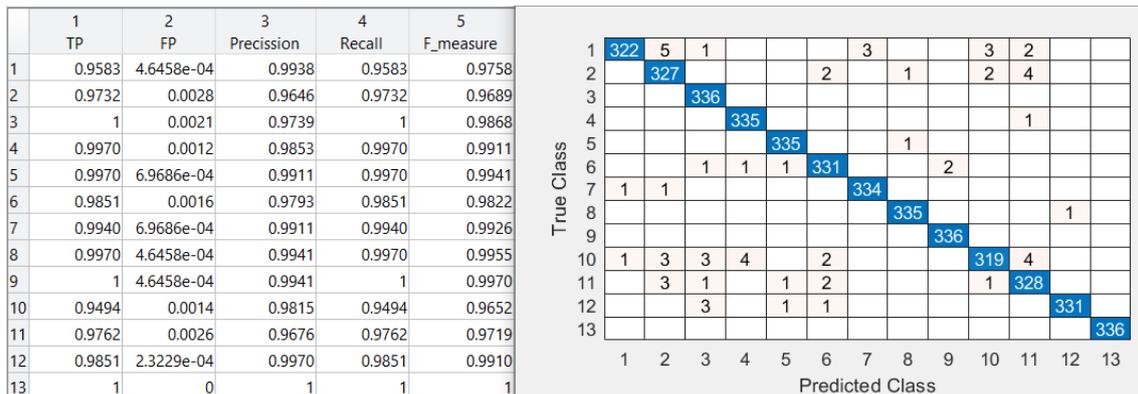
Gráfica 370. Validación del modelo elegido de la gráfica 369

Sacamos del clasificador K-NN fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en HSV para ventanas en filas de la gráfica 370.



Gráfica 371. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en HSV

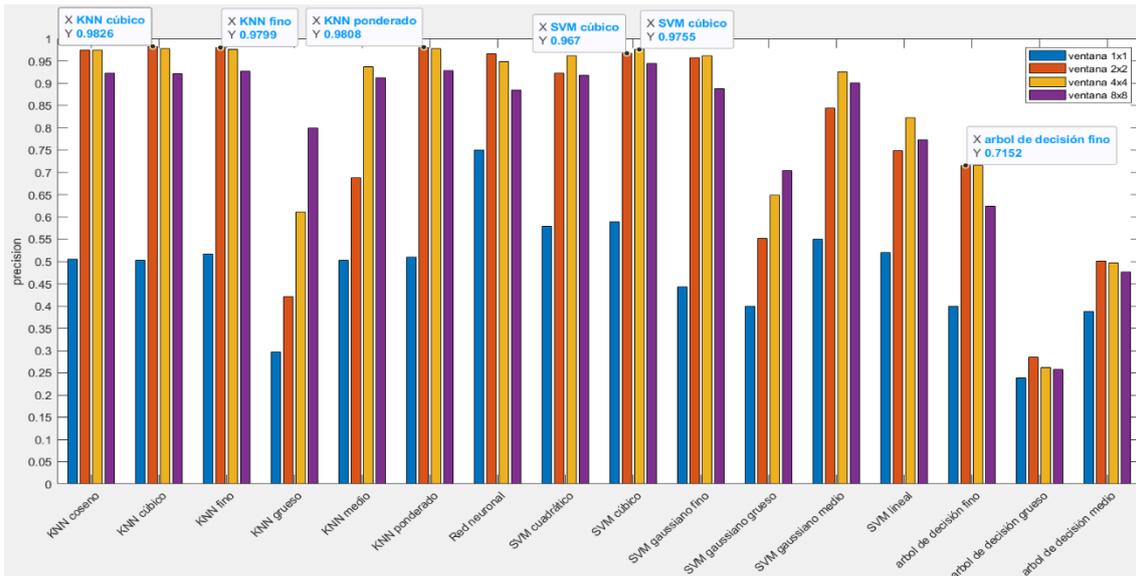
Generalmente en la gráfica 371, los clasificadores tienen unos valores semejantes para los distintos tipos de ventana. Por ello, usando LBP invariante a rotación con radio 1 en HSV, el clasificador K-NN ponderado con ventana de 1x16 es el que mejor resultado proporciona, pero dista poco del K-NN coseno con ventana de 1x32 o 1x16.



Gráfica 372. Validación del modelo elegido de la gráfica 371

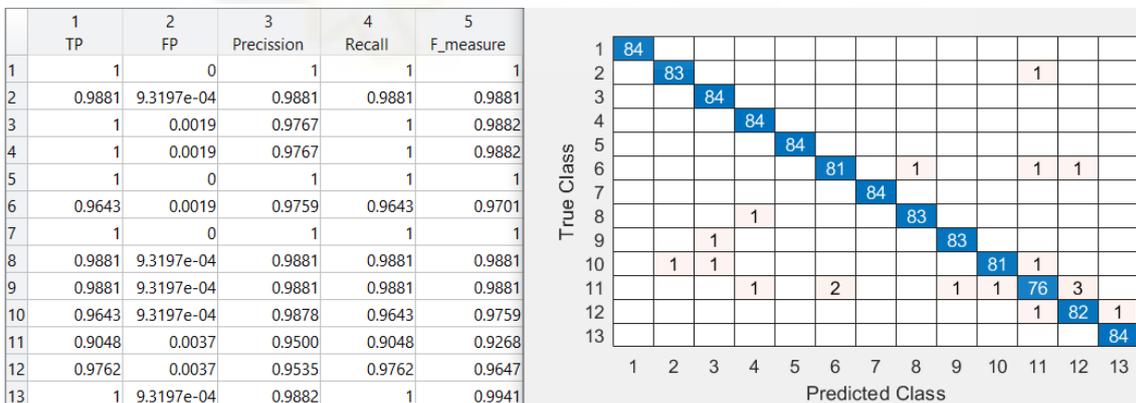
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en HSV para ventanas en columnas, es del clasificador K-NN ponderado de la gráfica 372.

Una vez vistas las tres graficas (gráfica 367, 369 y 371) usando LBP invariante a rotación con radio 1 en HSV el clasificador K-NN fino para ventanas de 16x1 es el que mejor resultado nos ofrece.



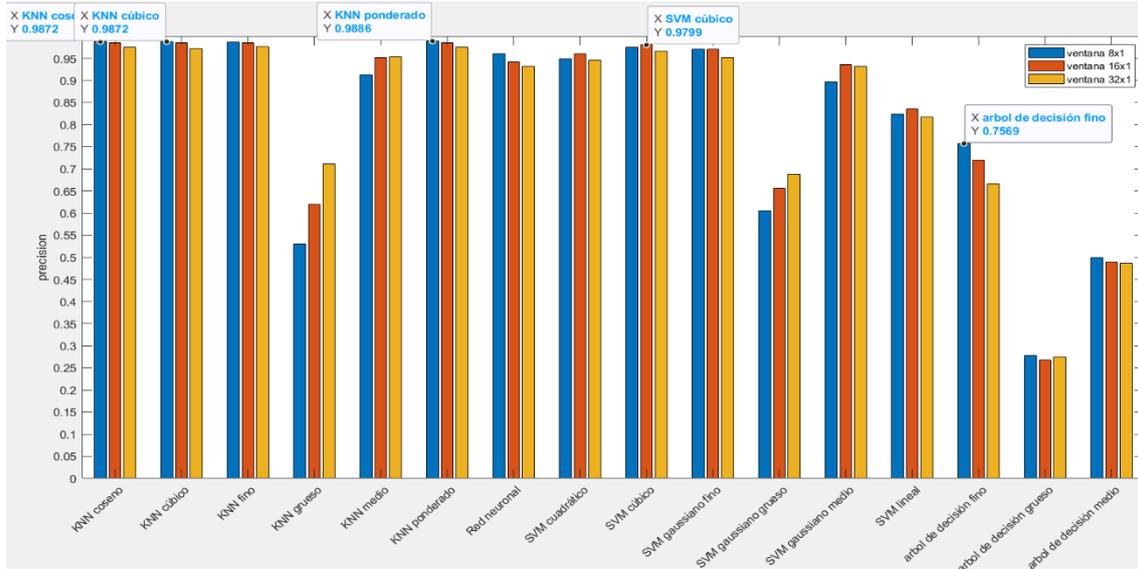
Gráfica 373. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en HSV

Con LBP invariante a rotación con radio 3 en HSV, el clasificador K-NN cúbico alcanza la más alta precisión de toda la gráfica para la ventana de 2x2. Generalmente en la gráfica 373, es en esta ventana en la que mayoría de los clasificadores tienen mejores resultados.



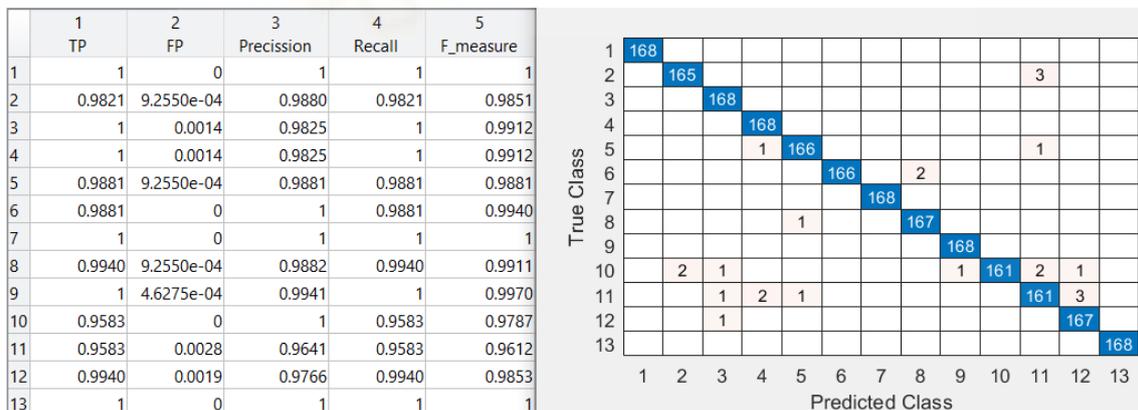
Gráfica 374. Validación del modelo elegido de la gráfica 373

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en HSV para ventanas cuadradas, es del clasificador K-NN cúbico de la gráfica 374.



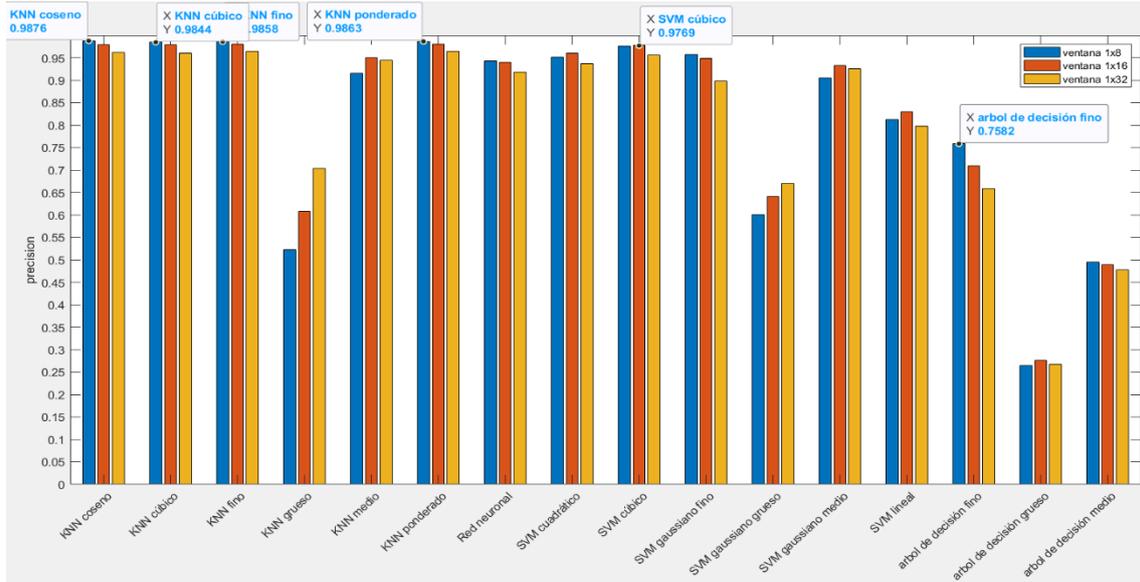
Gráfica 375. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en HSV

Podemos observar en la gráfica 375 que los mejores resultados, de la mayoría de los clasificadores, aparece cuando usamos ventanas de 8x1. El mejor resultado viene por el clasificador K-NN ponderado para ventana de 8x1, sin embargo, el K-NN coseno y el K-NN cúbico para ventana de 8x1 tiene un valor también muy elevado y cercano al anterior.



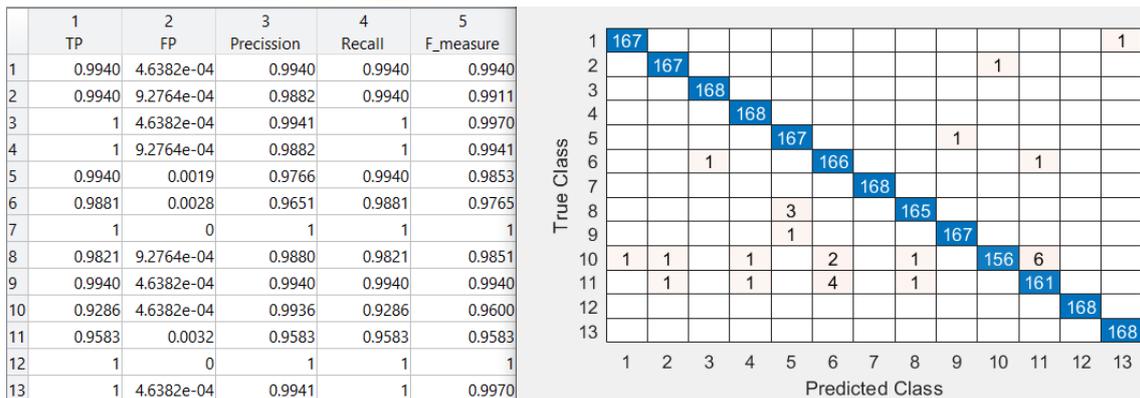
Gráfica 376. Validación del modelo elegido de la gráfica 375

Sacamos del clasificador K-NN ponderado esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en HSV para ventanas en filas de la gráfica 376.



Gráfica 377. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en HSV

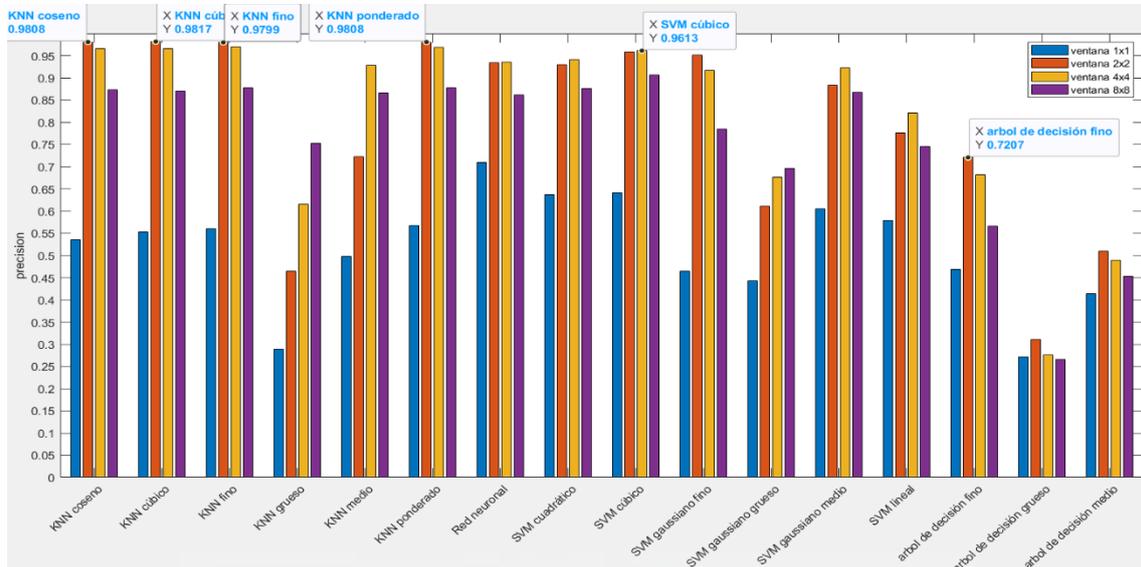
En la gráfica 377 para LBP invariante a rotación con radio 3 en HSV, la ventana de 1x8 es la que provoca, generalmente, los mejores resultados de muchos clasificadores y, conforme la ventana se hace más pequeña, la precisión disminuye. El que mejor resultado ofrece en este caso es el K-NN coseno con ventana de 1x8.



Gráfica 378. Validación del modelo elegido de la gráfica 377

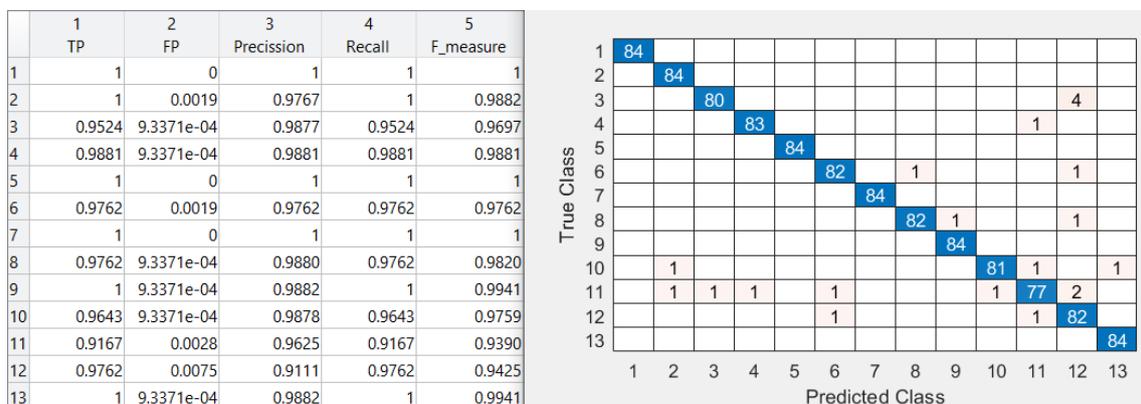
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en HSV para ventanas en columnas, es del clasificador K-NN coseno de la gráfica 378.

Una vez visto todos los resultados usando LBP invariante a rotación con radio 3 en HSV, el clasificador K-NN ponderado es el que mejores resultados ha ofrecido en los tres casos, siendo el mayor de todos para ventana de 8x1.



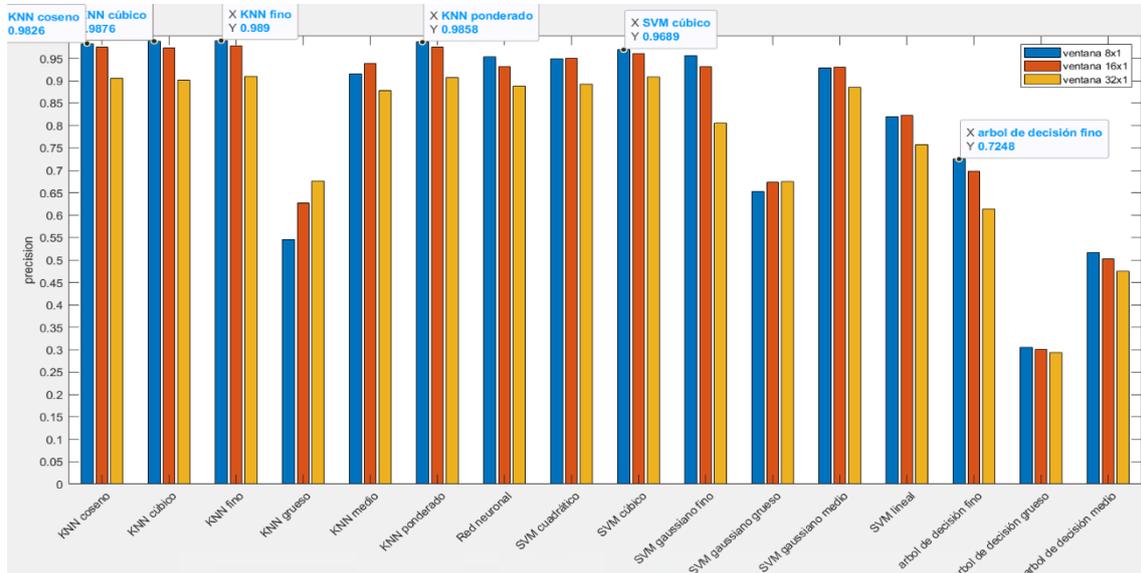
Gráfica 379. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en HSV

En la gráfica 379, continuando con LBP invariante a rotación con radio 5 en HSV, vemos en la mayoría de los clasificadores es la ventana de 2x2 la que ofrece los mejores resultados. El valor más alto viene por parte del clasificador K-NN cúbico con ventana de 2x2, y los siguientes son, con la misma ventana, el K-NN ponderado y el K-NN coseno.



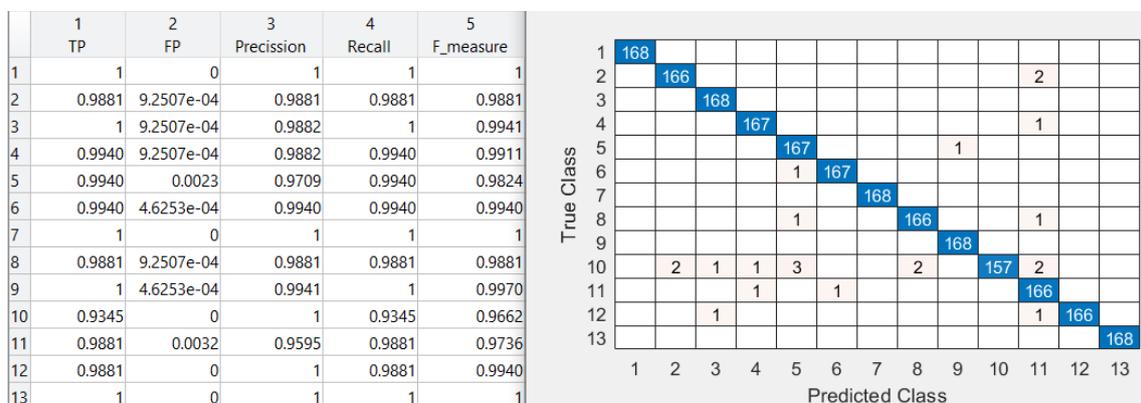
Gráfica 380. Validación del modelo elegido de la gráfica 379

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en HSV para ventanas cuadradas, es del clasificador K-NN cúbico de la gráfica 380.



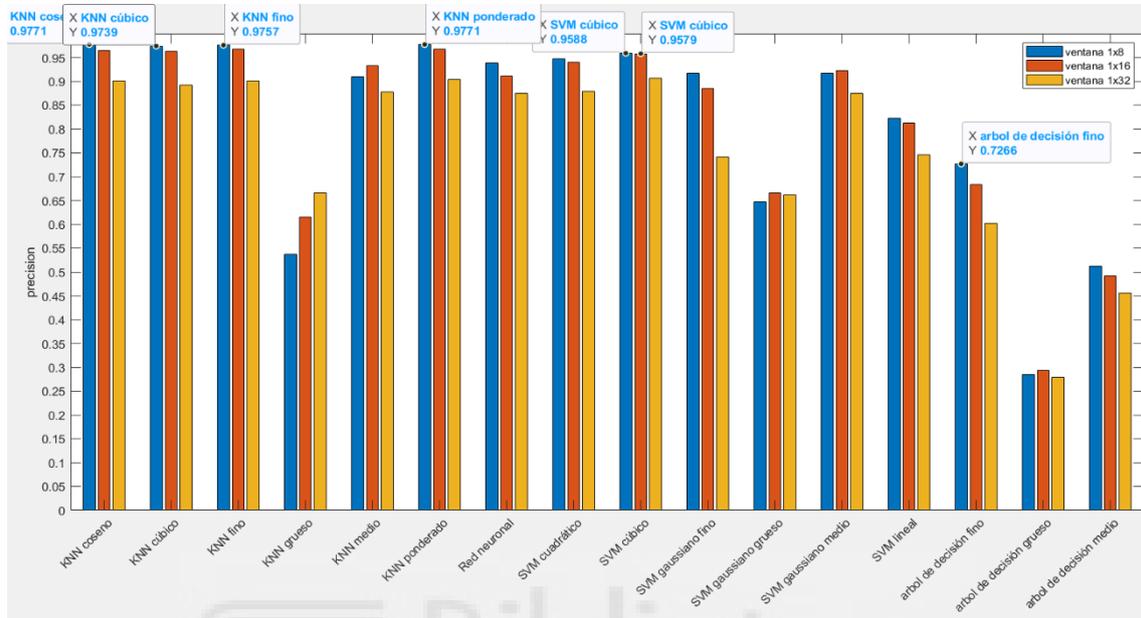
Gráfica 381. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en HSV

En la gráfica 381 la ventana de 8x1 es la que consigue el mejor resultado en la mayoría de los clasificadores usando LBP invariante a rotación con radio 5 en HSV y, si la ventana cambia su tamaño a uno menor la precisión se ve reducida. El mejor clasificador es el K-NN fino para ventana de 8x1 y, el siguiente valor más alto viene por el clasificador K-NN cúbico.



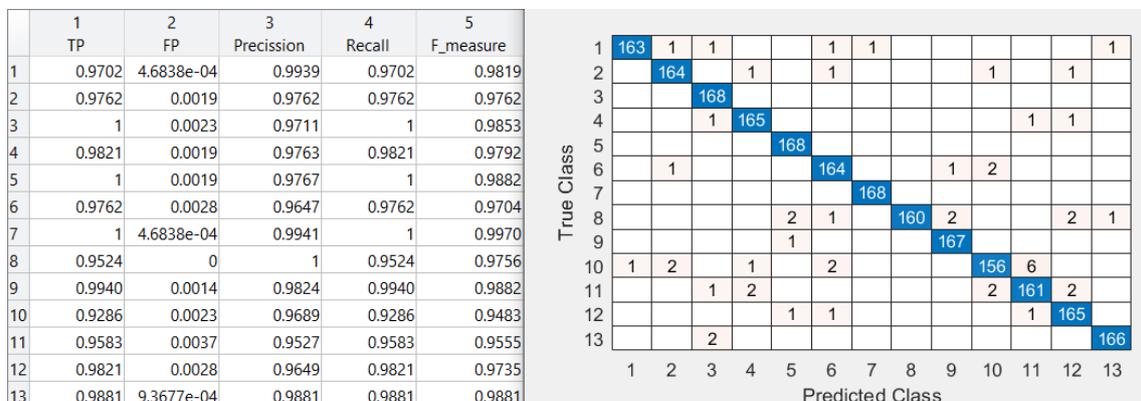
Gráfica 382. Validación del modelo elegido de la gráfica 381

Sacamos del clasificador K-NN fino esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en HSV para ventanas en filas de la gráfica 382.



Gráfica 383. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en HSV

En la gráfica 383 el mejor resultado nos lo da tanto el clasificador K-NN coseno como el K-NN ponderado para ventana de 1x8 usando LBP invariante a rotación con radio 5 en HSV. Es apreciable que a medida que la ventana se hace más pequeña la precisión también se reduce en la mayoría de clasificadores y que la distancia del valor máximo obtenido con los siguientes no es muy amplia.

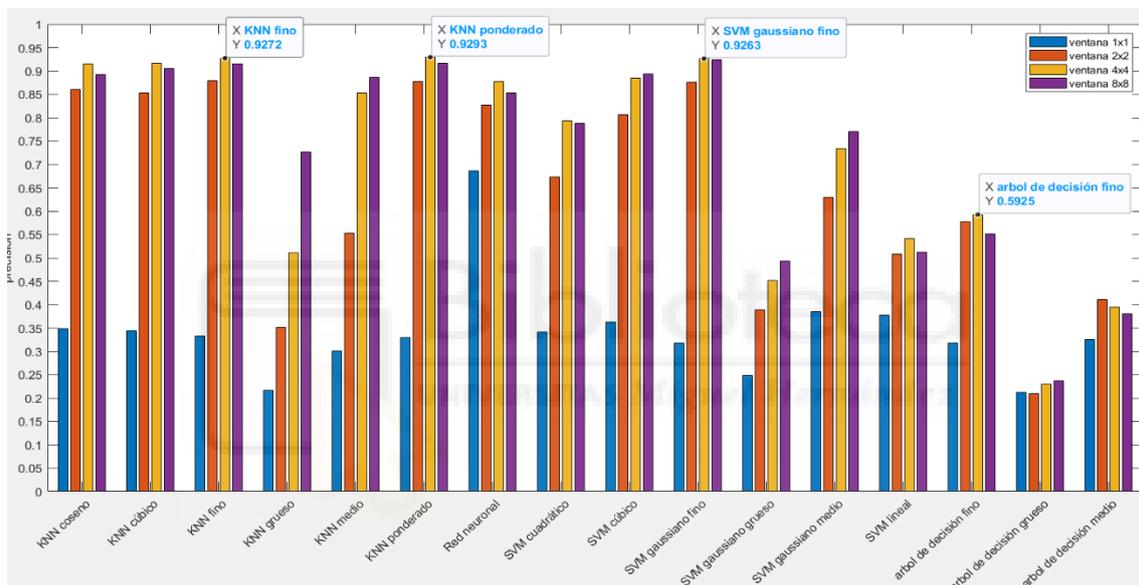


Gráfica 384. Validación del modelo elegido de la gráfica 383

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en HSV para ventanas en columnas, es del clasificador K-NN ponderado de la gráfica 384.

Visto los resultados anteriores, el clasificador K-NN cúbico es el que mejor se comporta usando LBP invariante a rotación con radio 5 en HSV y una ventana de 8x1.

#### 4.1.9 Comparación en LAB con el tercer data set



Gráfica 385. Comparación clasificadores para ventanas cuadradas para momentos de histograma en LAB

En la gráfica 385, usando los momentos de histograma en LAB para ventanas cuadradas vemos que el mejor resultado de cada clasificador suele darse para la ventana de 4x4 en la mayoría de clasificadores. También se puede observar que resultado más alto viene por parte del clasificador K-NN ponderado para ventana de 4x4. También cabe destacar que el clasificador K-NN fino alcanza un valor elevado y cercano al anterior.

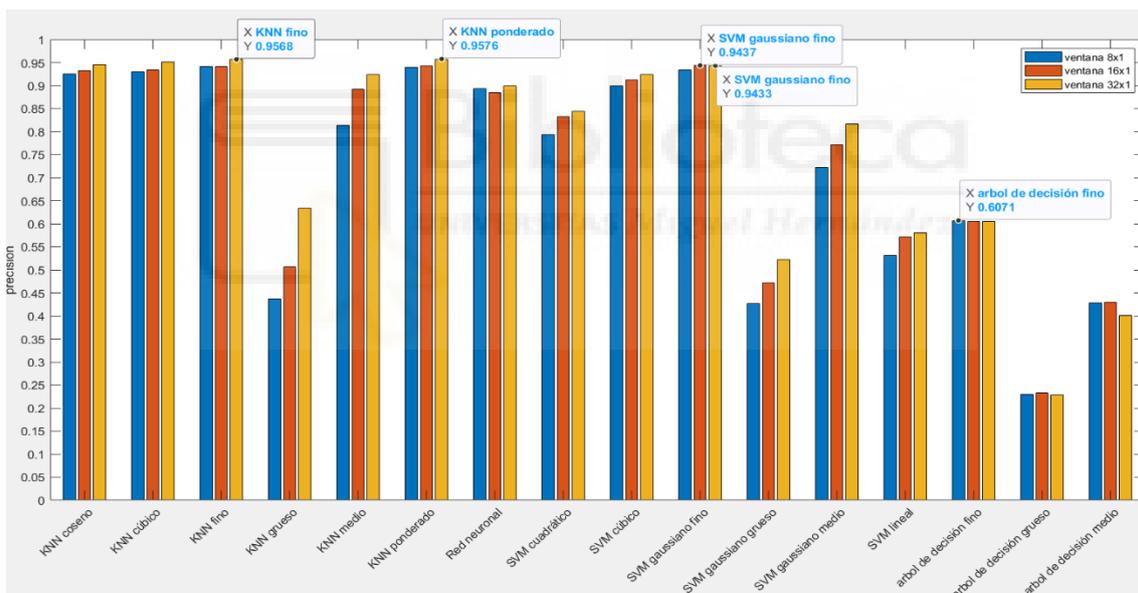
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9881	7.3873e-04	0.9910	0.9881	0.9896
2	0.9554	0.0042	0.9497	0.9554	0.9525
3	0.9345	0.0116	0.8698	0.9345	0.9010
4	0.9286	0.0037	0.9541	0.9286	0.9412
5	0.9226	0.0108	0.8757	0.9226	0.8986
6	0.9256	0.0039	0.9511	0.9256	0.9382
7	0.9970	0.0017	0.9795	0.9970	0.9882
8	0.9435	0.0066	0.9215	0.9435	0.9324
9	0.9375	0.0059	0.9292	0.9375	0.9333
10	0.8274	0.0069	0.9085	0.8274	0.8660
11	0.8452	0.0071	0.9073	0.8452	0.8752
12	0.9345	0.0039	0.9515	0.9345	0.9429
13	0.9464	0.0084	0.9034	0.9464	0.9244

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	332		1	1					1	1			
2		321	4	1	1		1	1		2	4	1	
3			314	2	3	3	1	1	4	1	3		4
4	1	2	6	312		4	2	3		4	2		
5		1	2		310				4	4	4	2	3
6			8	2	1	311		5	3	2		3	1
7			1				335						
8			2		3	2		317	3	2	1	2	4
9		1	3		8	1		2	315	1			5
10	1	5	9	4	5	3		7	2	278	13	3	6
11	1	7	5	5	10	1	3	2		10	284	3	5
12		1	1		9	1		1	5		1	314	3
13			5		4	1		1	3	1	2	1	318

Gráfica 386. Validación del modelo elegido de la gráfica 385

Esta representación de la matriz de confusión y las tasas de acierto y error, para los momentos de histograma en LAB para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 386.



Gráfica 387. Comparación clasificadores para ventanas en filas para momentos de histograma en LAB

En la gráfica 387, siguiendo con el análisis en ventanas en filas, vemos que el clasificador K-NN ponderado para ventanas de 32x1 es el que mejor precisión tiene usando momentos de histograma en LAB. También vemos que los mejores resultados de los clasificadores, generalmente, se produce en las ventanas de 32x1.

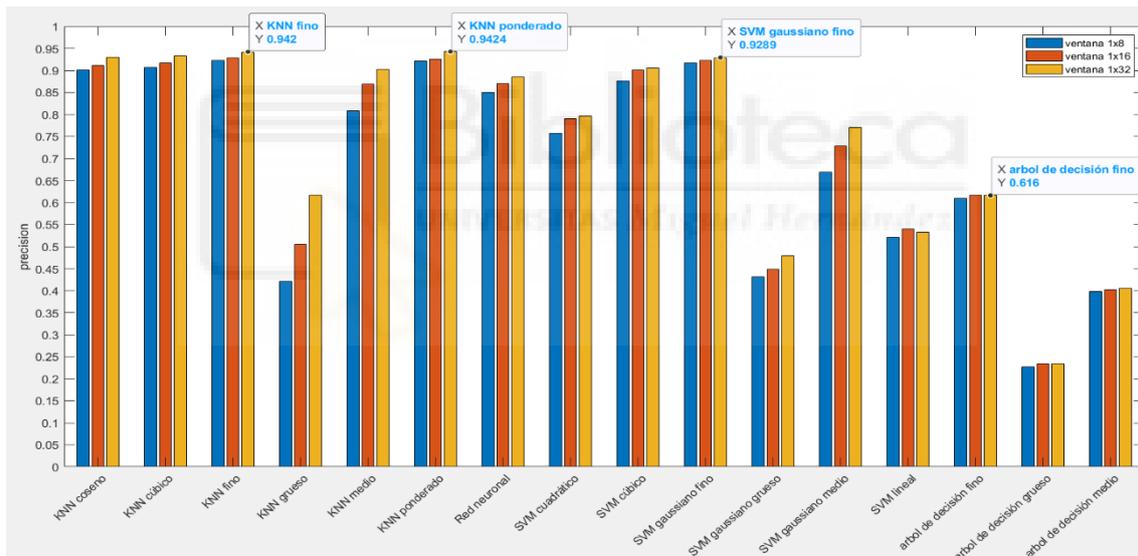
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9673	0.0160	0.8312	0.9673	0.8941
2	0.9673	0.0025	0.9687	0.9673	0.9680
3	0.9286	0.0044	0.9455	0.9286	0.9369
4	0.9494	0.0025	0.9681	0.9494	0.9587
5	0.9390	0.0046	0.9432	0.9390	0.9411
6	0.9241	0.0039	0.9510	0.9241	0.9374
7	0.9747	9.6946e-04	0.9879	0.9747	0.9813
8	0.9509	0.0033	0.9595	0.9509	0.9552
9	0.9554	0.0055	0.9345	0.9554	0.9448
10	0.9077	0.0044	0.9443	0.9077	0.9256
11	0.9375	0.0038	0.9531	0.9375	0.9452
12	0.9375	0.0028	0.9648	0.9375	0.9509
13	0.9405	0.0041	0.9489	0.9405	0.9447

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	650	1	1	3	2	5		1	3		2	4	
2	8	650	1	2		1	2	1		2	2	3	
3	16	1	624	4	2	4	1	2	6	2	5	1	4
4	9	2	4	638		6	1	1		3	4	1	3
5	11	2	2		631	2		2	9	3	3	5	2
6	7		13	2	3	621		2	3	8	3	2	8
7	11	3		1			655		1		1		
8	9			1	5	3		639	3	5	3		4
9	7	1	4	1	6	1	1	3	642			2	4
10	11	3	7	4	7	3		7	9	610	5	2	4
11	15	3	2	1	4	2	2	4	2	4	630	2	1
12	15	3	1	1	6	4		2	3	3		630	4
13	13	2	1	1	3	1	1	2	6	6	3	1	632

Gráfica 388. Validación del modelo elegido de la gráfica 387

Usaremos el clasificador con más precisión, el K-NN ponderado, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en LAB para ventanas en fila de la gráfica 388.



Gráfica 389. Comparación clasificadores para ventanas en columnas para momentos de histograma en LAB

Generalmente en la gráfica 389, vemos que el clasificador que más precisión tiene, usando momentos de histograma en LAB, es el K-NN ponderado para ventana de 1x32 y, el siguiente valor más alto vienen dado por el K-NN fino para ventana de 1x32. Que los dos resultados más altos se den para distintos tipos de ventana, refleja que no hay ninguna que sea mejor para distintos clasificadores.

	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.8750	0.0132	0.8448	0.8750	0.8596
2	0.9524	0.0037	0.9552	0.9524	0.9538
3	0.9435	0.0073	0.9135	0.9435	0.9283
4	0.9583	0.0038	0.9541	0.9583	0.9562
5	0.9464	0.0053	0.9367	0.9464	0.9415
6	0.9033	0.0067	0.9169	0.9033	0.9100
7	0.9747	0.0012	0.9850	0.9747	0.9798
8	0.9494	0.0038	0.9537	0.9494	0.9515
9	0.9554	0.0047	0.9441	0.9554	0.9497
10	0.8170	0.0077	0.8971	0.8170	0.8551
11	0.9375	0.0053	0.9361	0.9375	0.9368
12	0.9717	0.0027	0.9674	0.9717	0.9696
13	0.9658	0.0045	0.9461	0.9658	0.9558

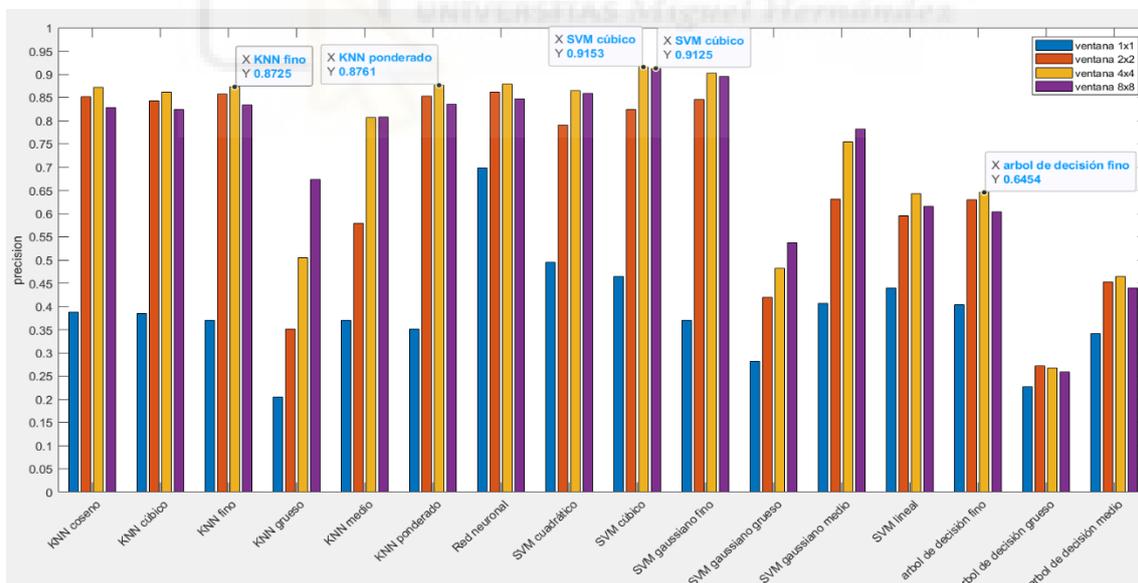
  

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	588	9	7	15	2	13	6	1	1	17	7	4	2
2	12	640	3	4	3	4	1	1		3	1		
3	7	3	634	3		4	1			8	6		5
4	11	1	3	644		4				1	5	3	
5	6	1	2		636	1			7	7	3	4	2
6	10	3	6	2	5	607			7	4	15	4	6
7	12		1				655			2	1	1	
8	8	1	3		6	3		638	3	3	1		6
9	4		10	1	6	1	1	1	642	1			5
10	16	6	17	3	12	19		8	7	549	20	4	11
11	13	3	2	2	3	3	1	3		7	630	4	1
12	5	2	3		4	1		1	1	1		653	1
13	4	1	3	1	2	2		2	4	1	2	1	649

Gráfica 390. Validación del modelo elegido de la gráfica 389

Usaremos el clasificador con más precisión, el K-NN ponderado, para representar la matriz de confusión y las tasas de acierto y error para momentos de histograma en LAB para ventanas en columna de la gráfica 390.

Después de ver todas las gráficas, el clasificador K-NN ponderado para ventanas de 32x1 es el que mayor precisión nos da, y en general para los tres tipos de ventana es el que mejor se comporta.



Gráfica 391. Comparación clasificadores para ventanas cuadradas para matriz de coocurrencia en LAB

Generalmente en la gráfica 391, el mejor resultado suele darse para la ventana de 4x4. Entonces, usando la matriz de coocurrencia en LAB, el clasificador SVM cúbico para la ventana de 4x4 es el que mejor resultado nos ofrece, sin

embargo, cabe destacar que para el mismo clasificador usando ventanas 8x8, el valor es muy próximo al anterior.

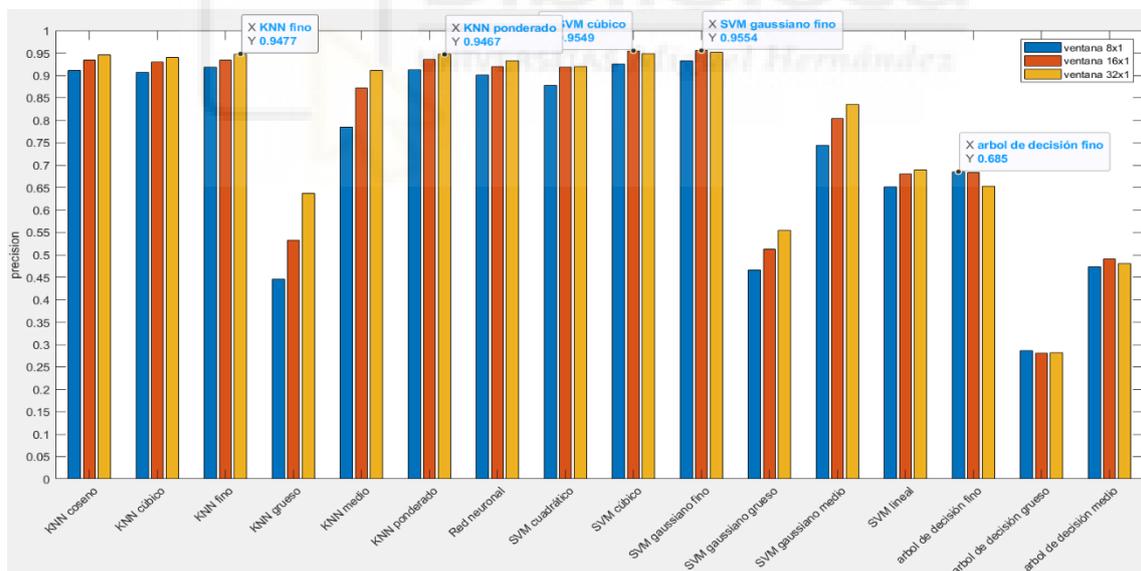
	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	0.9881	0.0015	0.9822	0.9881	0.9852
2	0.8512	0.0025	0.9662	0.8512	0.9051
3	0.9286	0.0048	0.9426	0.9286	0.9355
4	0.9226	0.0073	0.9145	0.9226	0.9185
5	0.9077	0.0095	0.8892	0.9077	0.8984
6	0.9226	0.0078	0.9091	0.9226	0.9158
7	0.9613	0.0023	0.9729	0.9613	0.9671
8	0.9643	0.0075	0.9153	0.9643	0.9391
9	0.9583	0.0055	0.9360	0.9583	0.9471
10	0.8214	0.0140	0.8313	0.8214	0.8263
11	0.8393	0.0175	0.8011	0.8393	0.8198
12	0.8720	0.0098	0.8825	0.8720	0.8772
13	0.9464	0.0040	0.9521	0.9464	0.9493

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	332			3							1		
2		286	5	5	1	1	1	3	4	6	14	7	3
3	4		312	1	3				2		7	7	
4		4	1	310		6	2		4	7	2		
5			1	1	305	1		10	3	3	1	8	3
6				5	2	310		1		6	6	4	2
7							323				13		
8				3	2	3		324	1	1		1	1
9			2		3			5	322	3		1	
10		2	2	8	5	10		4	1	276	20	5	3
11	1	2	2	2	13	4	4			23	282	1	2
12		2	6	1	7	1	2	7	3	5	7	293	2
13	1				2	5			4	1		5	318

Gráfica 392. Validación del modelo elegido de la gráfica 391

Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en LAB para ventanas cuadradas, es del clasificador SVM cúbico de la gráfica 392.



Gráfica 393. Comparación clasificadores para ventanas en filas para matriz de coocurrencia en LAB

Vemos en la gráfica 393 que usando la matriz de coocurrencia en LAB el clasificador SVM gaussiano fino es el que mejor se comporta cuando escogemos la ventana 16x1 y, con muy poca diferencia, el siguiente es el clasificador SVM

cúbico con la misma ventana. También se puede apreciar que los clasificadores, generalmente, ofrecen el mejor resultado para ese tipo de ventana.

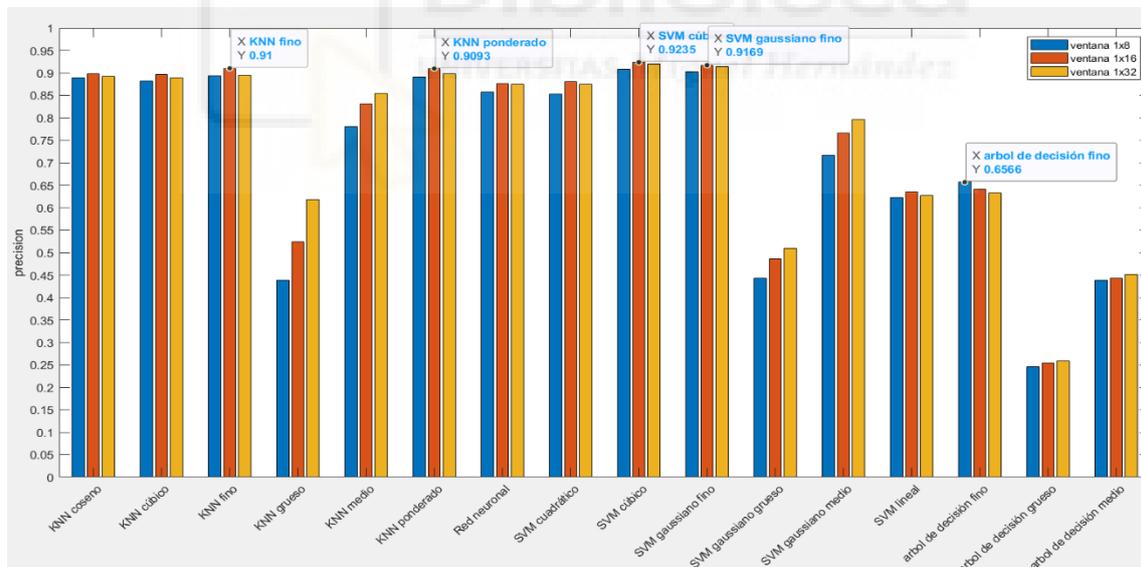
	1 TP	2 FP	3 Precision	4 Recall	5 F_measure
1	0.9821	2.3923e-04	0.9970	0.9821	0.9895
2	0.9494	0.0033	0.9580	0.9494	0.9537
3	0.9673	0.0014	0.9819	0.9673	0.9745
4	0.9643	0.0108	0.8780	0.9643	0.9191
5	0.9315	0.0041	0.9485	0.9315	0.9399
6	0.9048	0.0036	0.9530	0.9048	0.9282
7	0.9673	2.3923e-04	0.9969	0.9673	0.9819
8	0.9583	9.5694e-04	0.9877	0.9583	0.9728
9	0.9940	9.5694e-04	0.9882	0.9940	0.9911
10	0.9315	0.0055	0.9315	0.9315	0.9315
11	0.9702	0.0062	0.9261	0.9702	0.9477
12	0.9464	0.0053	0.9353	0.9464	0.9408
13	0.9732	0.0024	0.9703	0.9732	0.9718

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	330			4						2			
2		319	2	2				1	1	2	1	7	1
3			325	4	2				1		2		
4		5		324		1				3		3	
5			1	3	313	5		3		3		6	2
6		1		13		304				6	4	2	6
7		1		2			325				7		1
8		1		4	2	1		322	1	1	2	2	
9			1	1					334				
10		1		7	7	3			1	313	4		
11			1	2	3	1				2	326	1	
12	1	3	1	2	1	1				3	6	318	
13				1	2	4				1		1	327

Gráfica 394. Validación del modelo elegido de la gráfica 393

Sacamos del clasificador SVM gaussiano fino esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en LAB para ventanas en filas de la gráfica 394.



Gráfica 395. Comparación clasificadores para ventanas en columnas para matriz de coocurrencia en LAB

La gráfica 395 muestra el comportamiento de los clasificadores cuando usamos las ventanas en columna con la matriz de coocurrencia en LAB, vemos que el mejor resultado nos lo da el SVM cúbico para ventanas de 1x16 seguido muy de cerca por SVM gaussiano fino para ventanas de 1x16.

	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	0.9345	0.0035	0.9573	0.9345	0.9458
2	0.8482	0.0035	0.9532	0.8482	0.8976
3	0.9881	0.0037	0.9568	0.9881	0.9722
4	0.9464	0.0049	0.9408	0.9464	0.9436
5	0.9673	0.0094	0.8953	0.9673	0.9299
6	0.8810	0.0131	0.8481	0.8810	0.8642
7	0.9673	0.0017	0.9789	0.9673	0.9731
8	0.9673	0.0032	0.9615	0.9673	0.9644
9	0.9851	0.0037	0.9566	0.9851	0.9707
10	0.7649	0.0133	0.8264	0.7649	0.7944
11	0.9226	0.0111	0.8732	0.9226	0.8973
12	0.9315	0.0054	0.9343	0.9315	0.9329
13	0.9375	0.0030	0.9633	0.9375	0.9502

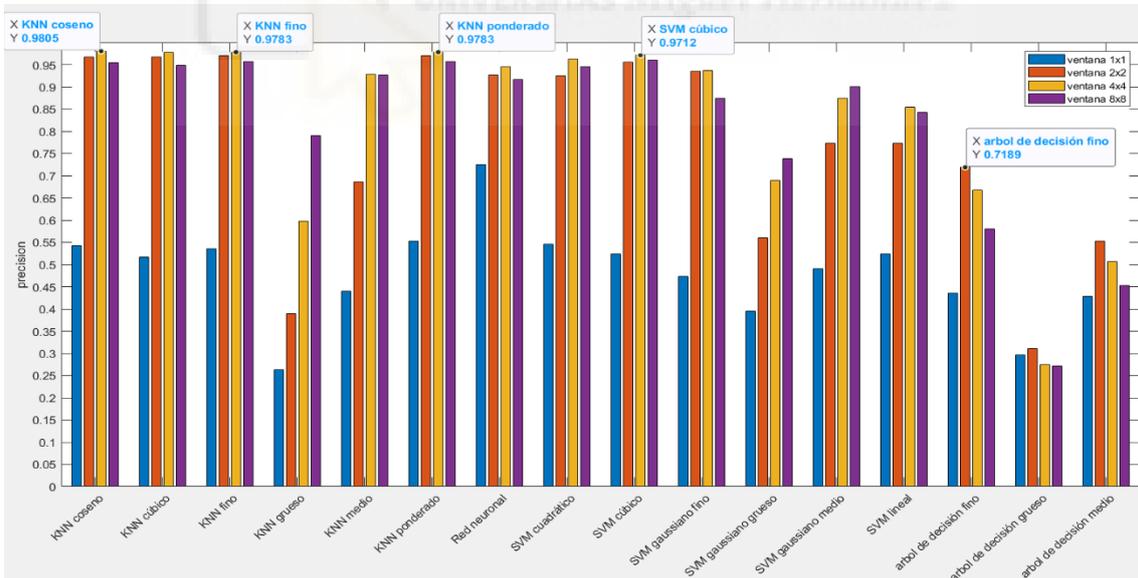
  

True Class	1	2	3	4	5	6	7	8	9	10	11	12	13
1	314	4	1	1		3	5			6		1	1
2	1	285		7	2	14		3		4	11	7	2
3	2	1	332										1
4		1		318		5			3	7	2		
5				1	325	3		2		2		2	1
6	3		2	6	1	296		1		16	4	4	3
7	4	1					325					6	
8				1	6	2		325	1	1			
9			1			2			331				1
10	2	5	6	4	8	18	1	2	8	257	18	3	4
11	1	2	1		2	1	1			15	310	3	
12			4		6	1		3	1	3	4	313	1
13	1				13	4		1	2				315

Gráfica 396. Validación del modelo elegido de la gráfica 395

Esta representación de la matriz de confusión y las tasas de acierto y error, para la matriz de coocurrencia en LAB para ventanas en columnas, es del clasificador SVM cúbico de la gráfica 396.

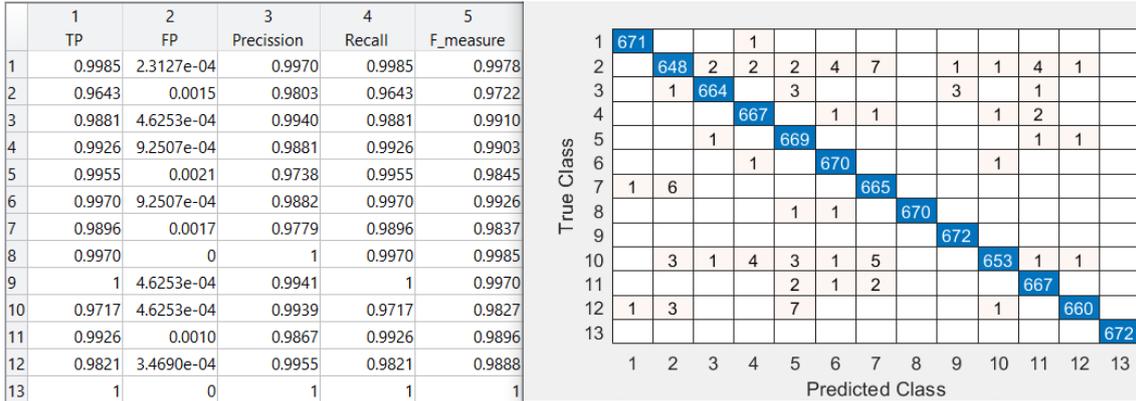
Una vez vistos los resultados anteriores, el mejor clasificador es el SVM gaussiano fino con ventana de 16x1, cabe destacar que este clasificador se comporta muy bien, incluso, en el resto de tipos de ventanas.



Gráfica 397. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 1 en LAB

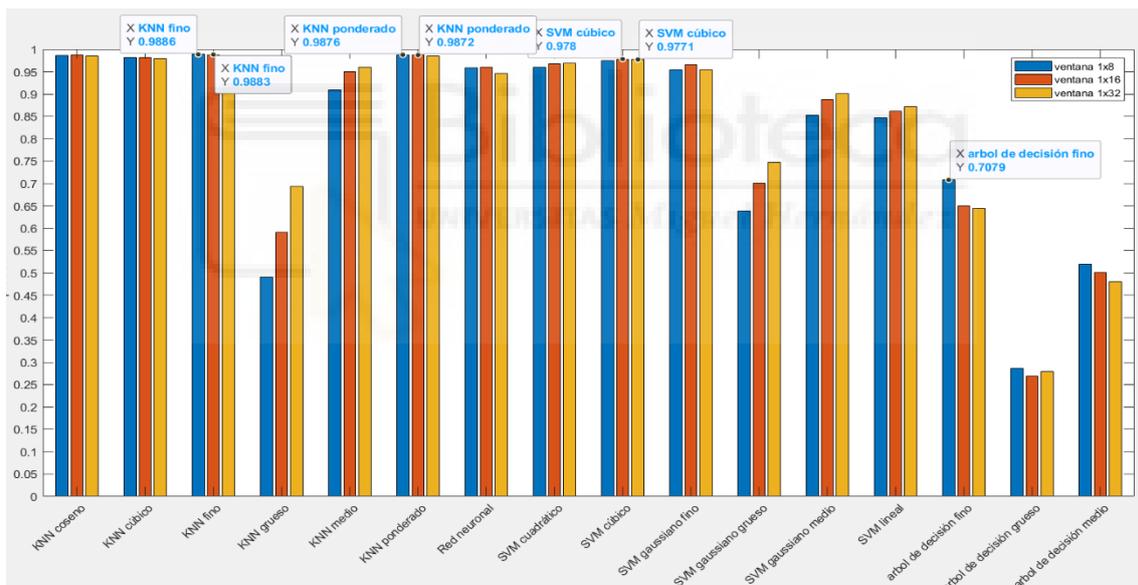
En la gráfica 397, usando LBP variante a rotación en LAB vemos que, en la mayoría de los clasificadores, en la ventana de 4x4 es en la que alcanzan los valores más altos. El clasificador K-NN coseno es el que mayor precisión tiene





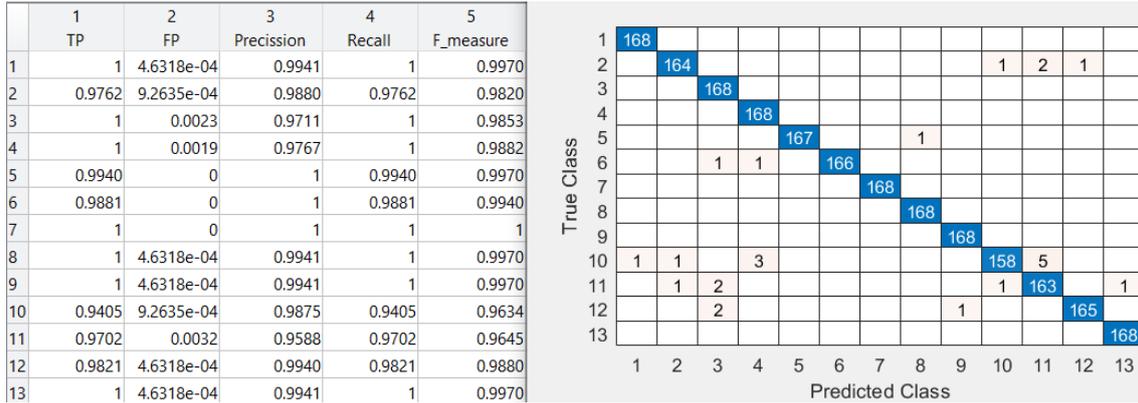
Gráfica 400. Validación del modelo elegido de la gráfica 399

Sacamos del clasificador K-NN ponderado esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en LAB para ventanas en filas de la gráfica 400.



Gráfica 401. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 1 en LAB

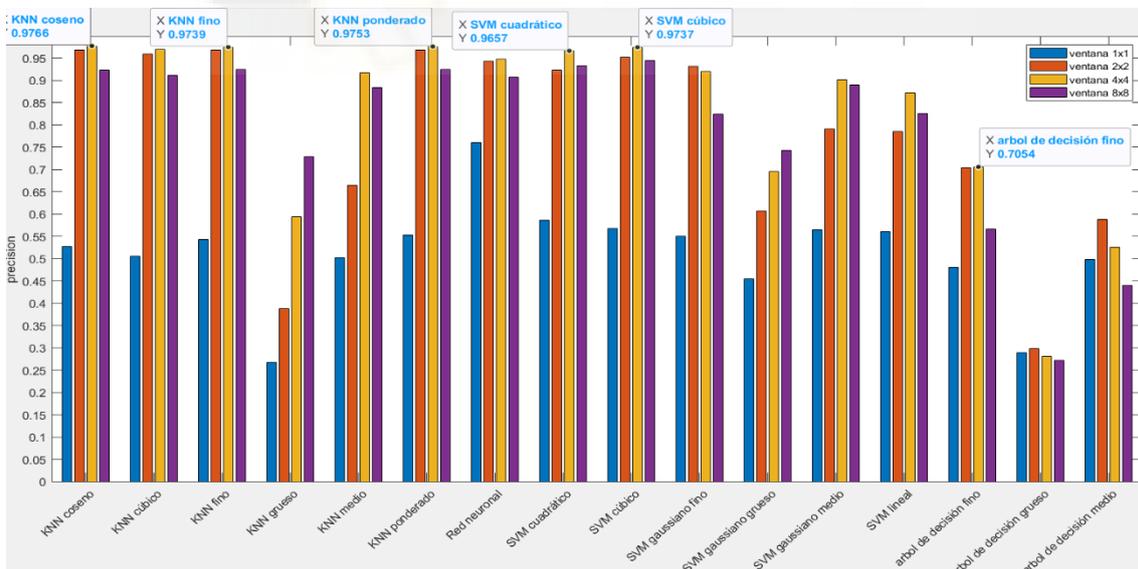
Vemos en la gráfica 401 que al analizar las ventanas en columna para LBP variante a rotación con radio 1 en LAB los valores de un mismo clasificador las diferentes ventanas tienen valores cercanos, hay excepciones. El mejor resultado es alcanzado por el clasificador K-NN fino para ventana de 1x8, y para el mismo clasificador, pero con ventana 1x16 el valor es muy cercano al anterior.



Gráfica 402. Validación del modelo elegido de la gráfica 401

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 1 en LAB para ventanas en columnas, es del clasificador K-NN fino de la gráfica 402.

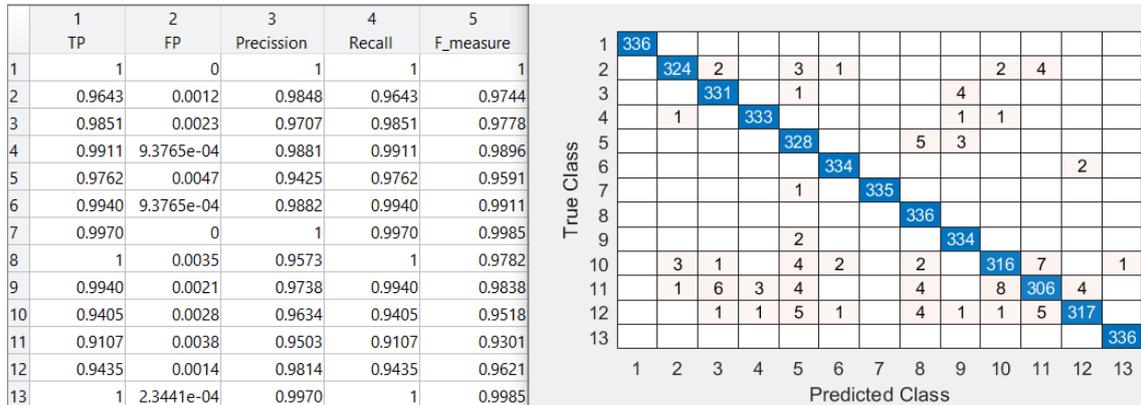
Queda claro que el clasificador K-NN ponderado es el que, independientemente de la ventana, siempre alcanza un resultado muy bueno respecto al resto de clasificadores. Siendo para la ventana 32x1 el de mayor valor para LBP variante a rotación con radio 1 en LAB.



Gráfica 403. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 3 en LAB

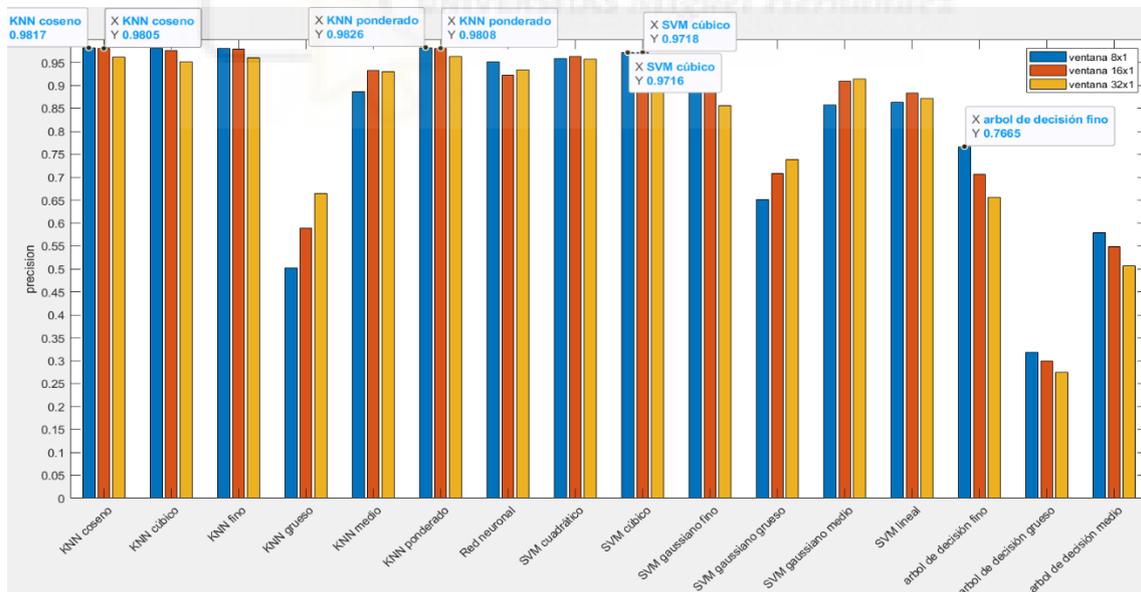
En la gráfica 403, usando LBP variante a rotación con radio 3 en LAB los valores más altos en general se encuentran cuando usamos ventanas de 4x4, siendo

esta ventana en la que con el clasificador K-NN coseno se alcanza el valor máximo, pero este valor difiere poco del valor del K-NN ponderado para la misma ventana.



Gráfica 404. Validación del modelo elegido de la gráfica 403

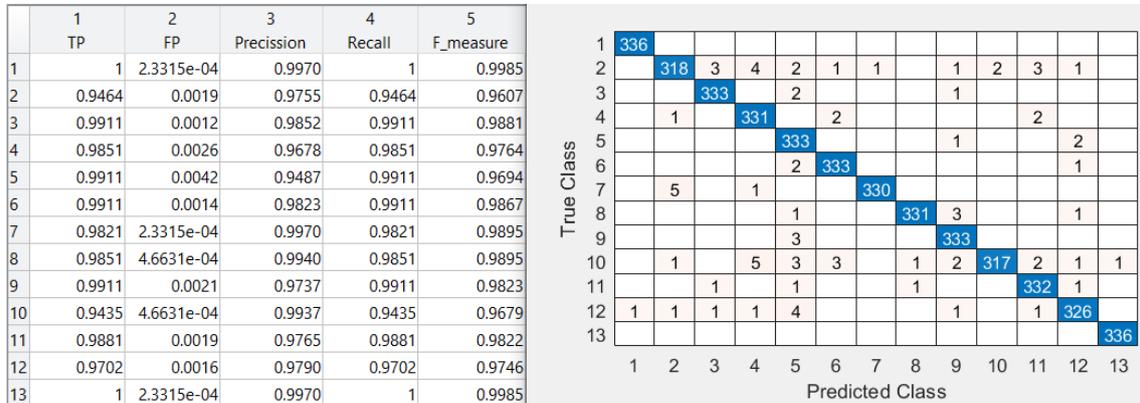
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en LAB para ventanas cuadradas, es del clasificador K-NN coseno de la gráfica 404.



Gráfica 405. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 3 en LAB

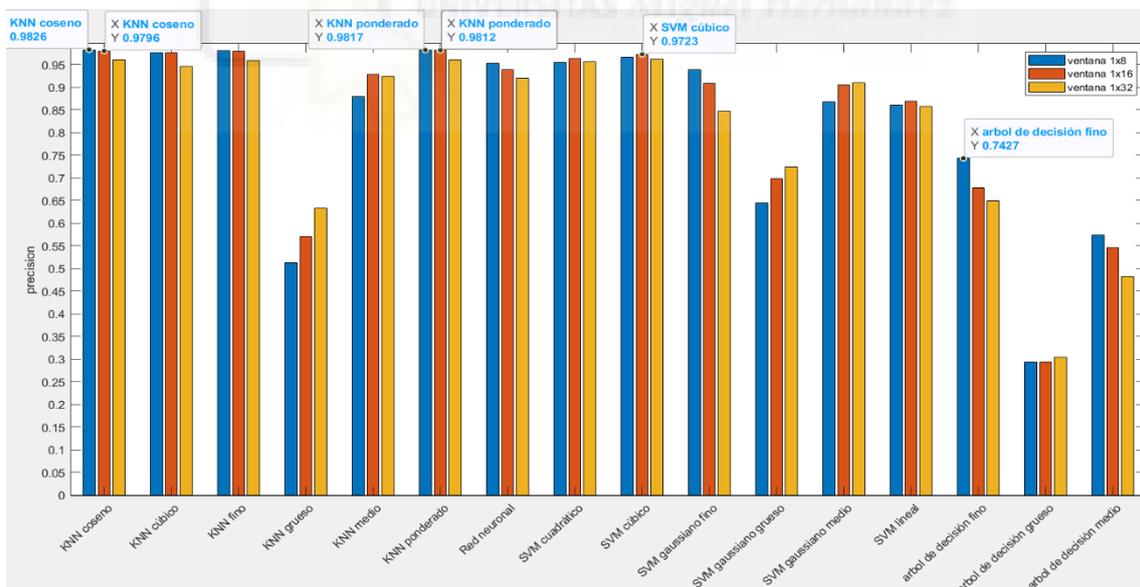
Analizando las ventanas en filas para LBP variante a rotación con radio 3 en LAB, vemos en la gráfica 405 que la gran mayoría de los clasificadores

estudiados alcanzan su valor más alto para las ventanas de 8x1, siendo el clasificador K-NN ponderado el que alcanza el valor más alto, aunque el clasificador K-NN coseno consigue un valor semejante con la misma ventana.



Gráfica 406. Validación del modelo elegido de la gráfica 405

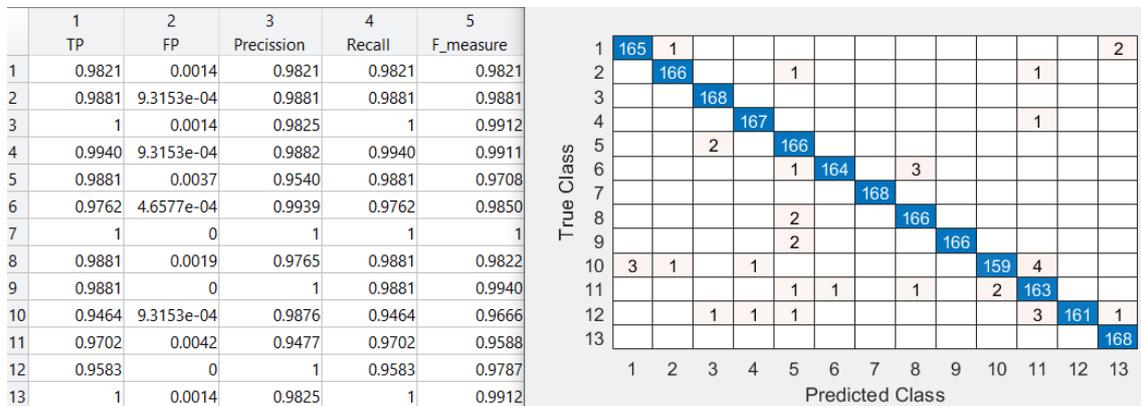
Sacamos del clasificador K-NN ponderado esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en LAB para ventanas en filas de la gráfica 406.



Gráfica 407. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 3 en LAB

Podemos observar en la gráfica 407 que los resultados para los diferentes tamaños de ventana, usando LBP variante a rotación con radio 3 en LAB, son muy cercanos en la mayoría de clasificadores. Para la ventana de 1x8 el

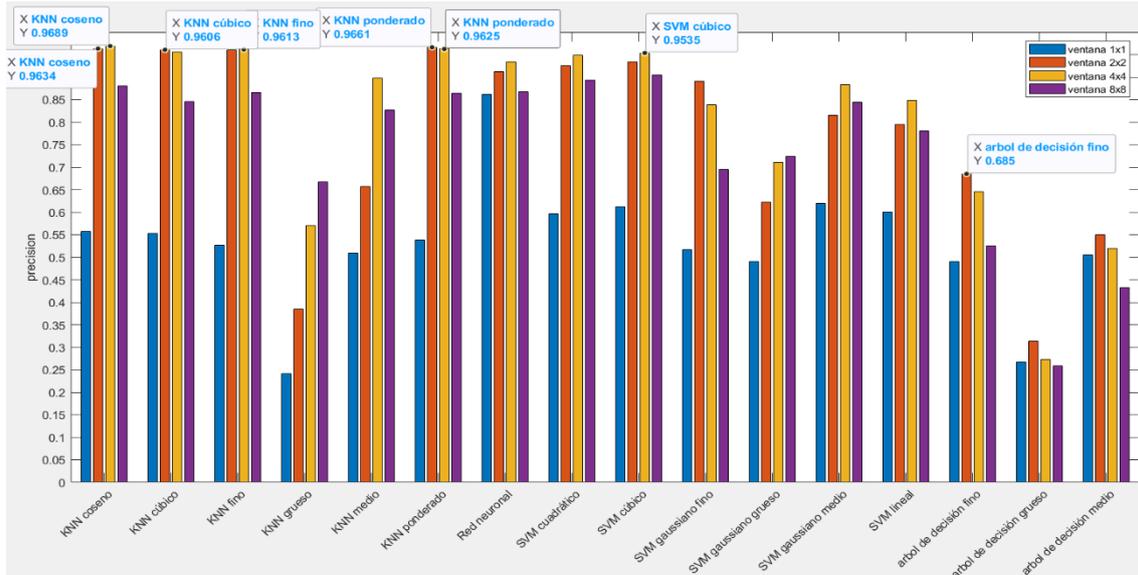
clasificador K-NN coseno es el que mayor valor alcanza, seguido de cerca por el K-NN ponderado con ventana de 1x8.



Gráfica 408. Validación del modelo elegido de la gráfica 407

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 3 en LAB para ventanas en columnas, es del clasificador K-NN coseno de la gráfica 408.

Hemos comprobado que para LBP variante a rotación con radio 3 en LAB, tenemos un empate en cuanto el valor más elevado, ya que obtenemos el mismo tanto para el clasificador K-NN ponderado con ventana de 8x1 como por el K-NN coseno con ventana de 1x8, pero si analizamos de forma más general, es el K-NN coseno el que mejor se comporta en las diferentes ventanas.



Gráfica 409. Comparación clasificadores para ventanas cuadradas para LBP variante a rotación con radio 5 en LAB

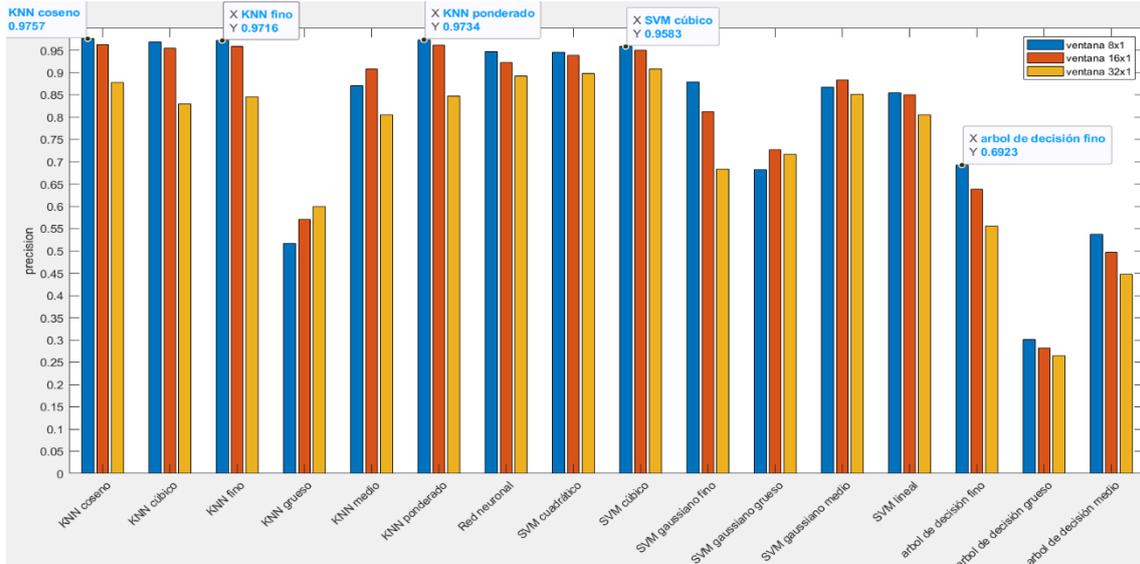
Ahora analizaremos en la gráfica 409 para ventanas cuadradas el uso de LBP variante a rotación con radio 5 en LAB, el valor más alto está localizado en la ventana 4x4 del clasificador K-NN coseno. Hay que mencionar, que este valor máximo es muy cercano al valor ofrecido por el K-NN ponderado para una ventana de 2x2.

	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	0.9970	0	1	0.9970	0.9985
2	0.9554	0.0014	0.9817	0.9554	0.9683
3	0.9583	0.0014	0.9817	0.9583	0.9699
4	0.9762	9.4742e-04	0.9880	0.9762	0.9820
5	0.9494	0.0085	0.8986	0.9494	0.9233
6	0.9911	0.0045	0.9460	0.9911	0.9680
7	1	0	1	1	1
8	0.9881	0.0054	0.9352	0.9881	0.9609
9	0.9554	0.0043	0.9469	0.9554	0.9511
10	0.9315	9.4742e-04	0.9874	0.9315	0.9587
11	0.9375	0.0047	0.9403	0.9375	0.9389
12	0.9256	0.0021	0.9719	0.9256	0.9482
13	1	2.3685e-04	0.9970	1	0.9985

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	335										1		
2		321	2		1	4		2		1	5		
3			322		6			2	5				1
4		2		328		2			3				1
5			1		319			10	4		1	1	
6					1	333		2					
7							336						
8				1	1			332	2				
9			1		14				321				
10		2			2	7		5		313	5	1	1
11		2	2	2	3	3		2	2		315	5	
12				2	8	2		2	2		9	311	
13													336

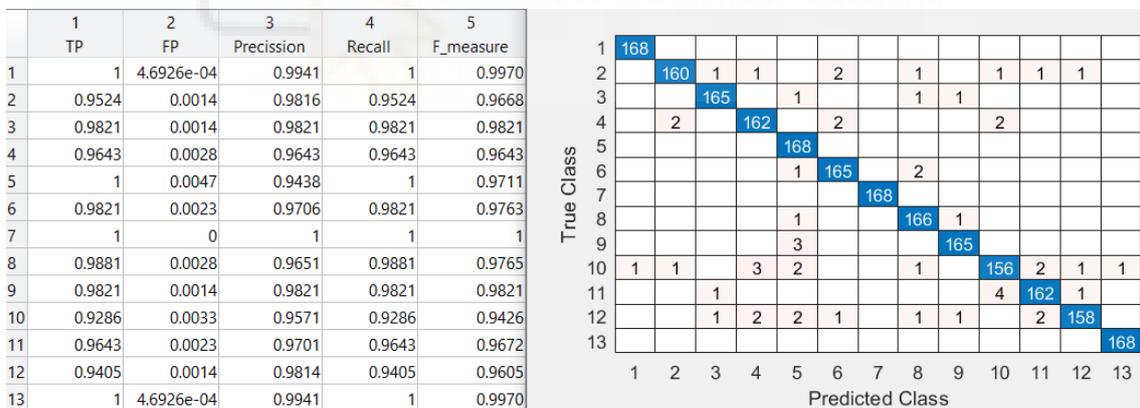
Gráfica 410. Validación del modelo elegido de la gráfica 409

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en LAB para ventanas cuadradas, es del clasificador K-NN coseno de la gráfica 410.



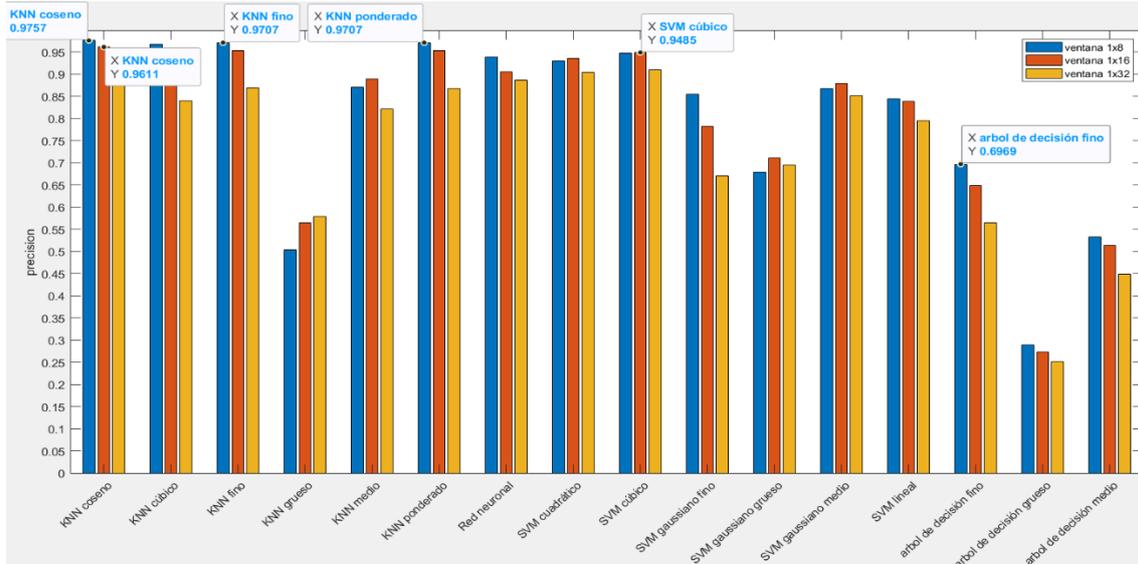
Gráfica 411. Comparación clasificadores para ventanas en filas para LBP variante a rotación con radio 5 en LAB

En la gráfica 411 el mejor clasificador, usando LBP variante a rotación con radio 5 en LAB con ventanas en fila, es el K-NN coseno para ventanas de 8x1. También, podemos ver como a medida que se disminuye el tamaño de la ventana también disminuye la precisión del clasificador.



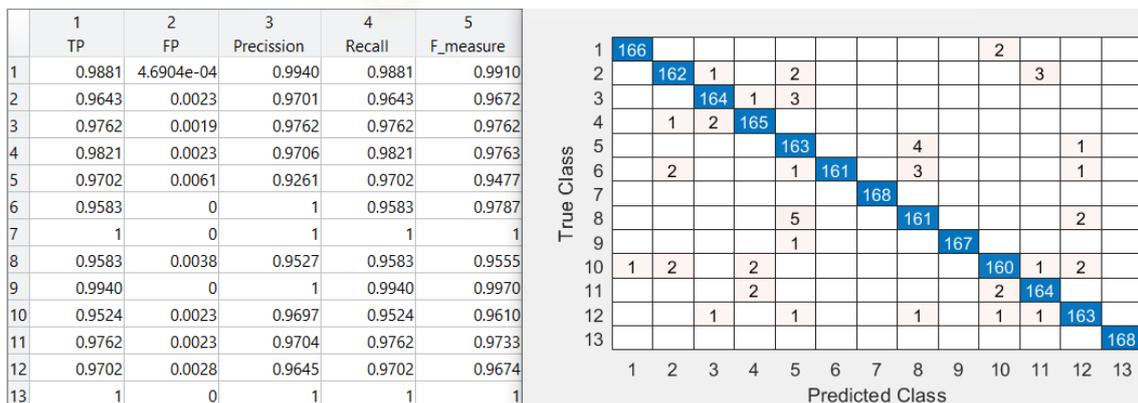
Gráfica 412. Validación del modelo elegido de la gráfica 411

Sacamos del clasificador K-NN coseno esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en LAB para ventanas en filas de la gráfica 412.



Gráfica 413. Comparación clasificadores para ventanas en columnas para LBP variante a rotación con radio 5 en LAB

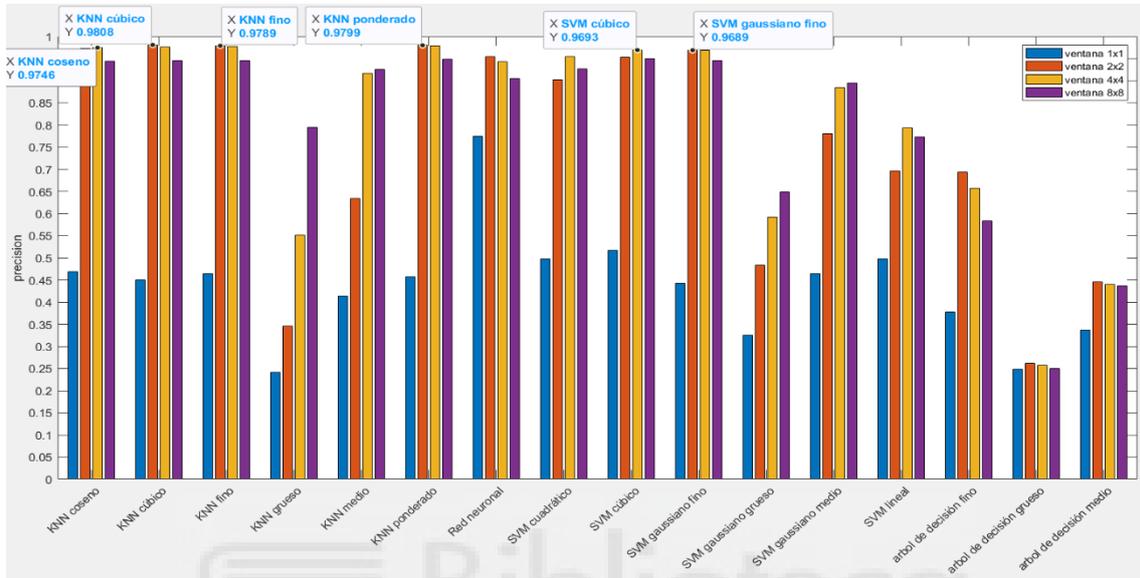
Terminando de analizar el LBP variante a rotación con radio 5 en LAB, vemos en la gráfica 413 que, en general, para ventanas en columnas los clasificadores se comportan mejor para el tamaño de 1x8 y conforme este tamaño disminuye, el resultado empeora. El mejor resultado lo encontramos en el clasificador K-NN coseno para la ventana de 1x8.



Gráfica 414. Validación del modelo elegido de la gráfica 413

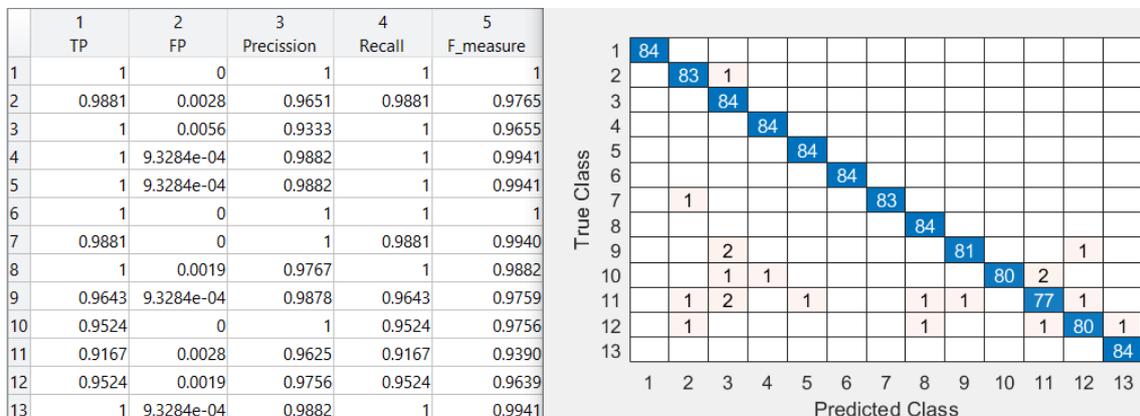
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP variante a rotación con radio 5 en LAB para ventanas en columnas, es del clasificador K-NN coseno de la gráfica 414.

Viendo el comportamiento de los clasificadores usando LBP variante a rotación con radio 5 en LAB, que el clasificador K-NN coseno es el que por lo general mejor se comporta, y el valor más elevado que alcanza lo hace tanto para la ventana de 8x1 como para la de 1x8.



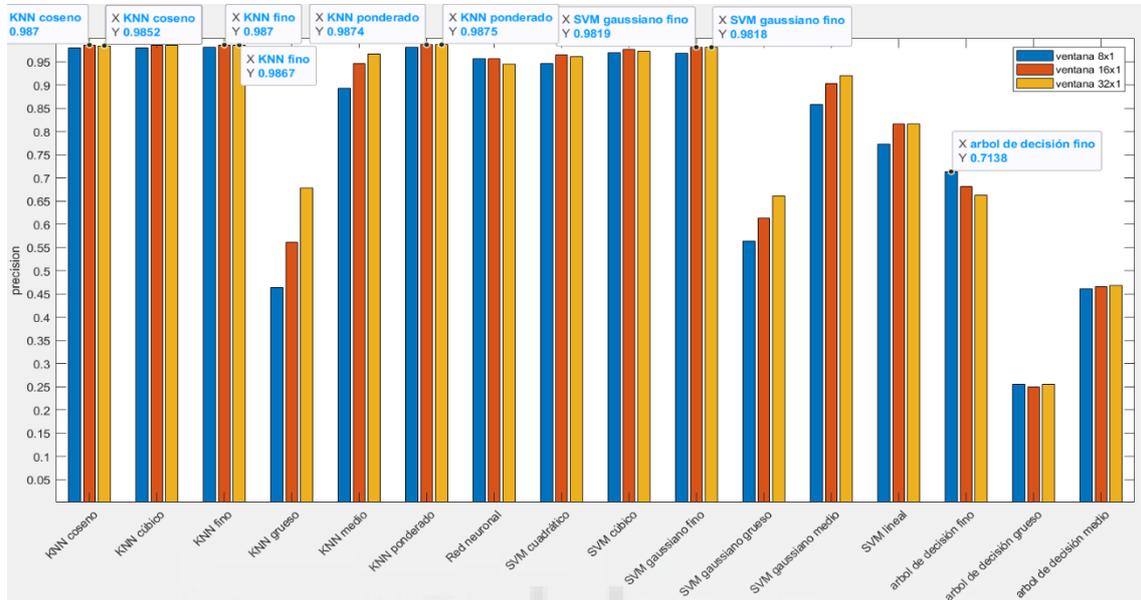
Gráfica 415. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 1 en LAB

Ahora, usando LBP invariante a rotación con radio 1 en LAB, vemos en la gráfica 415 que la mayoría los clasificadores adquieren una mayor precisión cuando se usa la ventana de 2x2, siendo el K-NN cúbico el que mayor precisión alcanza entre todos los clasificadores. Cabe destacar que el valor del K-NN ponderado para ventana de 2x2 es muy cercano al del K-NN cúbico.



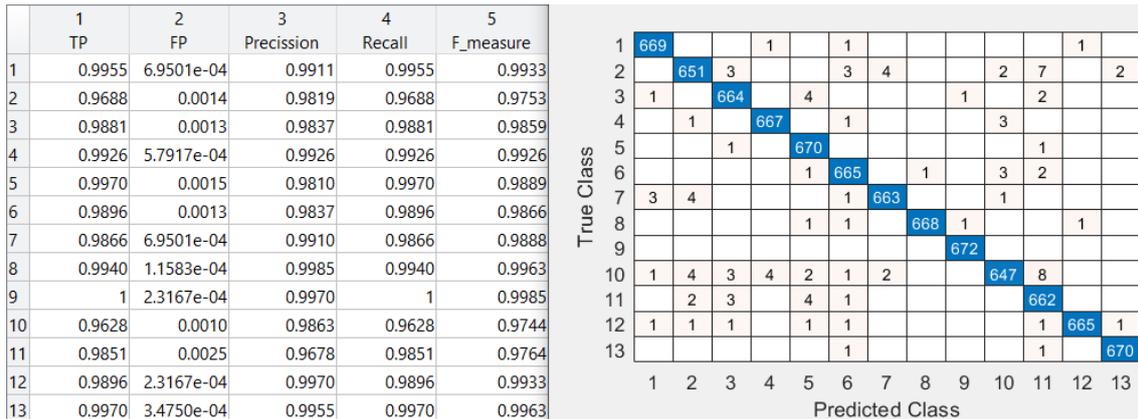
Gráfica 416. Validación del modelo elegido de la gráfica 415

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en LAB para ventanas cuadradas, es del clasificador K-NN cúbico de la gráfica 416.



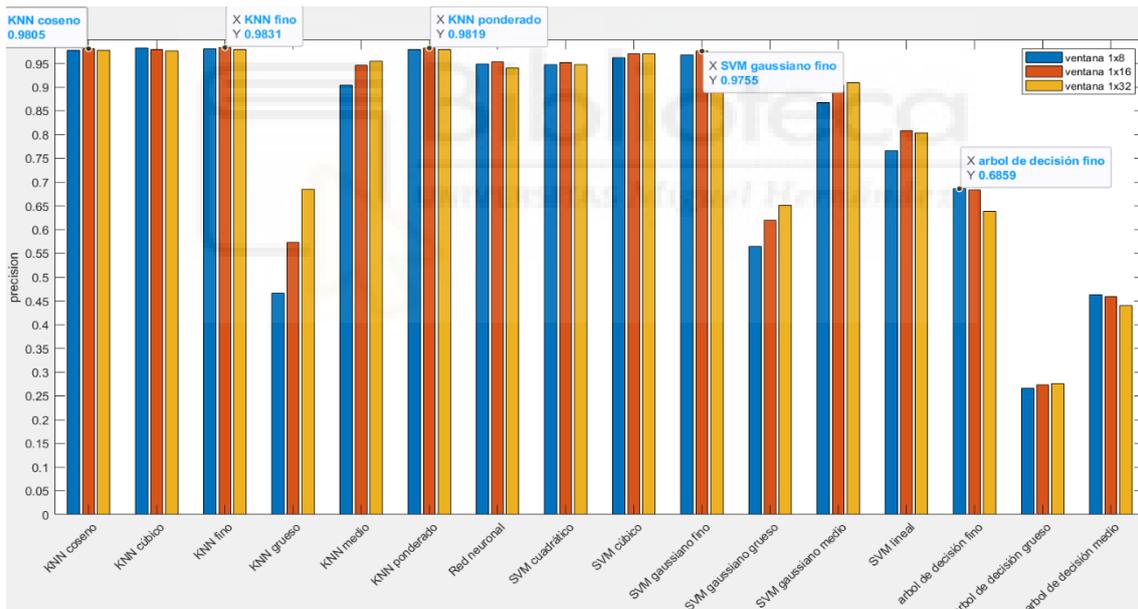
Gráfica 417. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 1 en LAB

En muchos clasificadores vemos en la gráfica 417 que los valores en cada ventana son muy parecidos entre sí. Entonces, el clasificador que, usando LBP invariante a rotación con radio 1 en LAB, tiene la mayor precisión es el K-NN ponderado con ventana 32x1, pero este valor dista muy poco del obtenido por el mismo clasificador, pero con ventana 16x1, el K-NN fino y el K-NN coseno para ventana de 32x1.



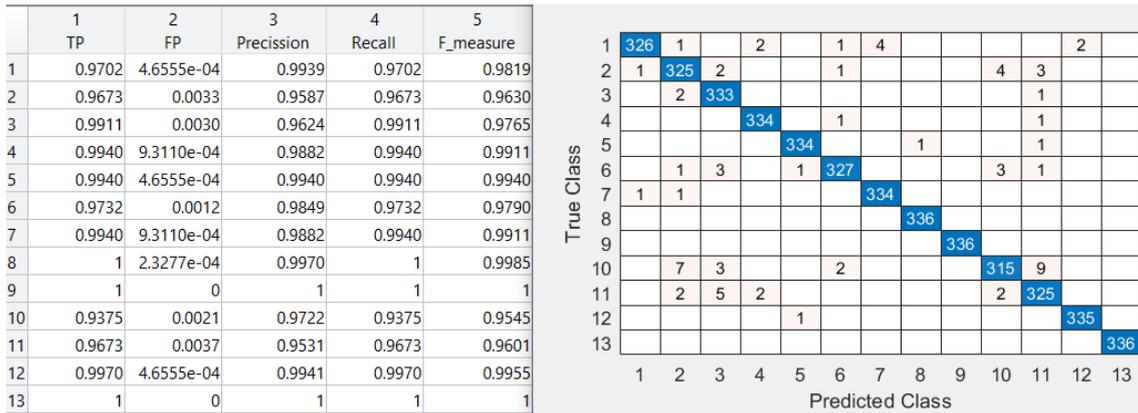
Gráfica 418. Validación del modelo elegido de la gráfica 417

Sacamos del clasificador K-NN ponderado esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en LAB para ventanas en filas de la gráfica 418.



Gráfica 419. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 1 en LAB

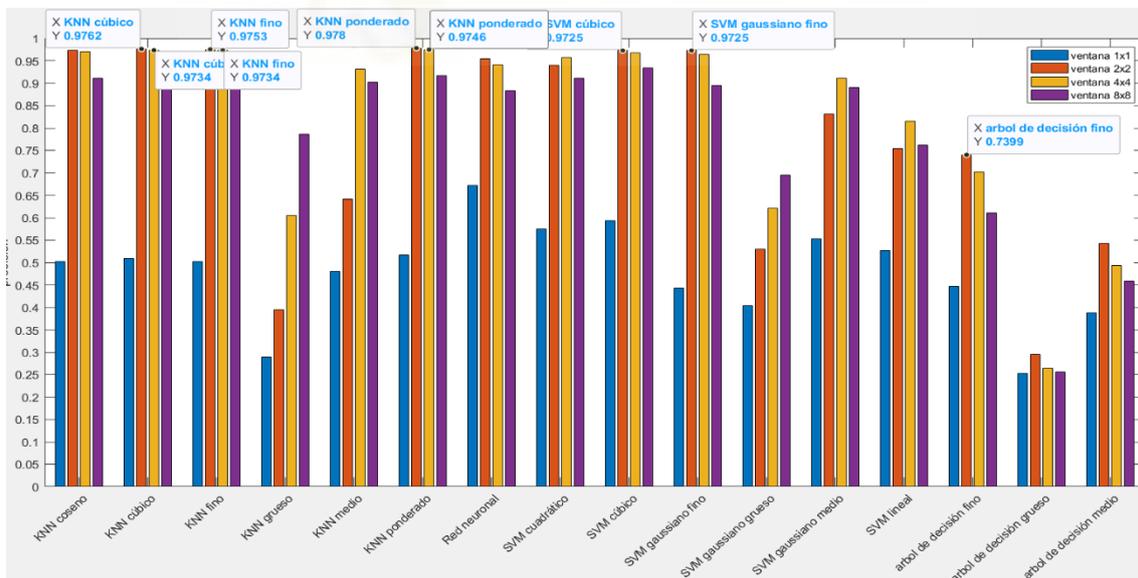
Generalmente en la gráfica 419, los clasificadores tienen unos valores semejantes para los distintos tipos de ventana. Por ello, usando LBP invariante a rotación con radio 1 en LAB, el clasificador K-NN fino con ventana de 1x16 es el que mejor resultado proporciona, pero dista muy poco del K-NN ponderado con ventana de 1x16.



Gráfica 420. Validación del modelo elegido de la gráfica 419

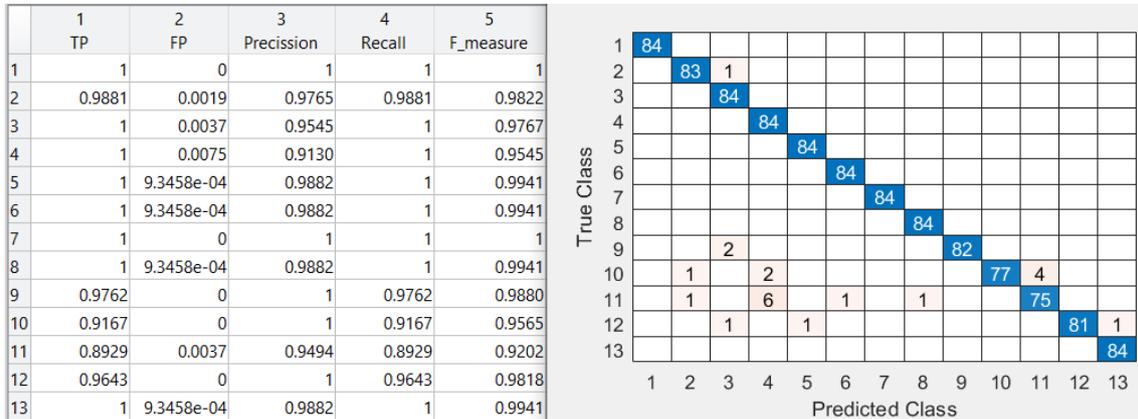
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 1 en LAB para ventanas en columnas, es del clasificador K-NN fino de la gráfica 420.

Una vez vistas las tres graficas (gráfica 415, 417 y 419) usando LBP invariante a rotación con radio 1 en LAB el clasificador K-NN ponderado para ventanas de 32x1 es el que mejor resultado nos ofrece y, en general, es el que mejor se comporta en los distintos tipos de ventanas.



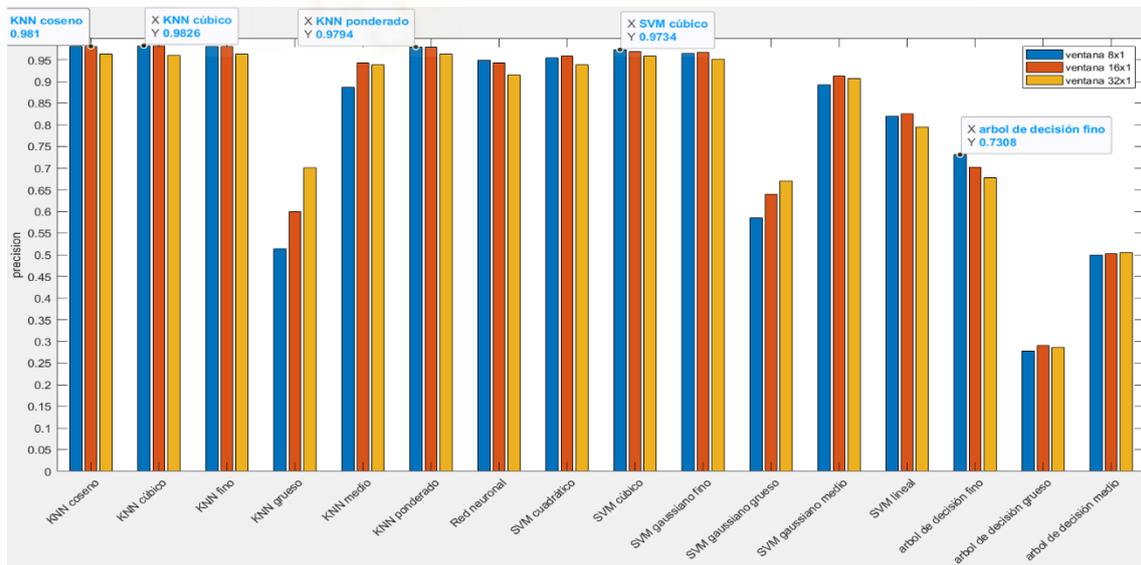
Gráfica 421. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 3 en LAB

En la gráfica 421, con LBP invariante a rotación con radio 3 en LAB, el clasificador K-NN ponderado alcanza la más alta precisión de toda la gráfica para la ventana de 2x2. Generalmente en la gráfica, es en esta ventana en la que la mayoría de los clasificadores tienen mejores resultados.



Gráfica 422. Validación del modelo elegido de la gráfica 421

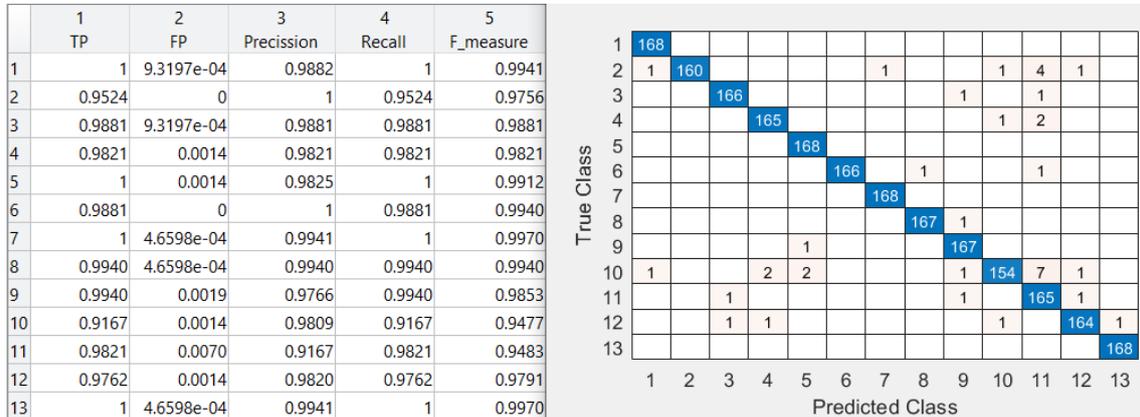
Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en LAB para ventanas cuadradas, es del clasificador K-NN ponderado de la gráfica 422.



Gráfica 423. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 3 en LAB

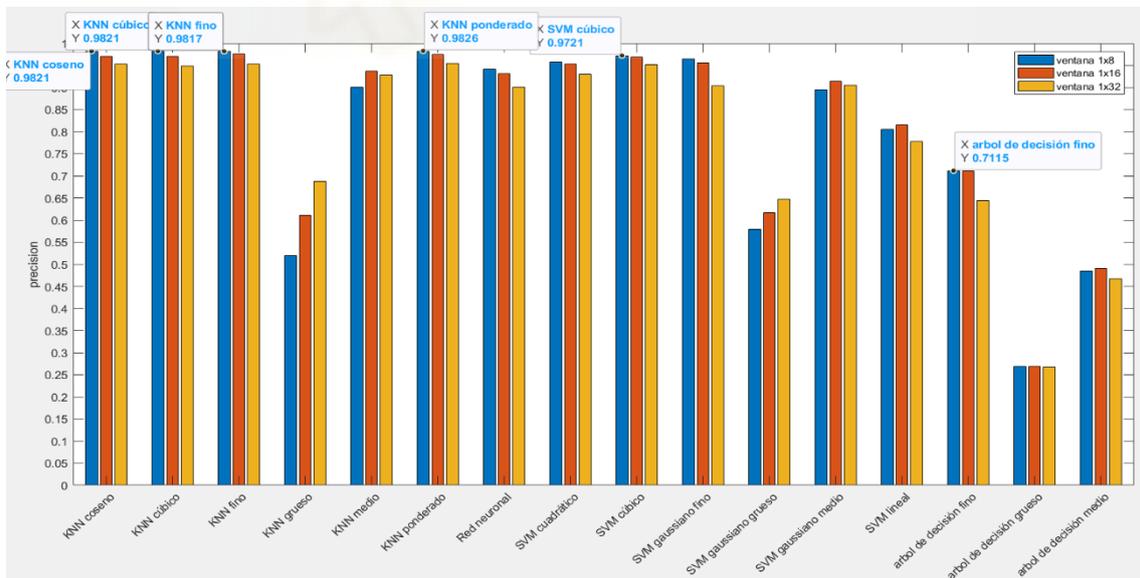
Podemos observar en la gráfica 423 que los mejores resultados, de la mayoría de los clasificadores, aparece cuando usamos ventanas de 8x1 y, a medida que

este tamaño decrece, también lo hace la precisión. El mejor resultado viene por el clasificador K-NN cúbico para ventana de 8x1, sin embargo, K-NN coseno para ventana de 16x1 tiene un valor también muy elevado y cercano al anterior.



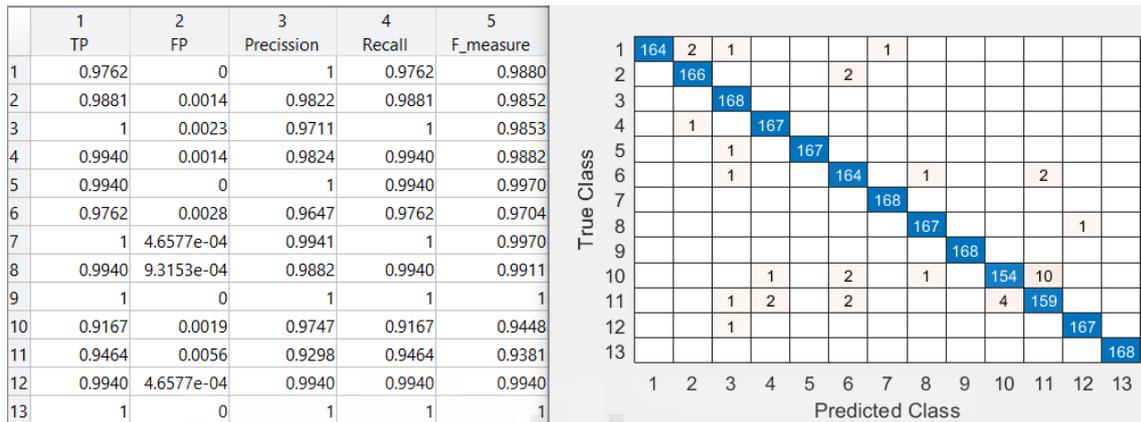
Gráfica 424. Validación del modelo elegido de la gráfica 423

Sacamos del clasificador K-NN cúbico esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en LAB para ventanas en filas de la gráfica 424.



Gráfica 425. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 3 en LAB

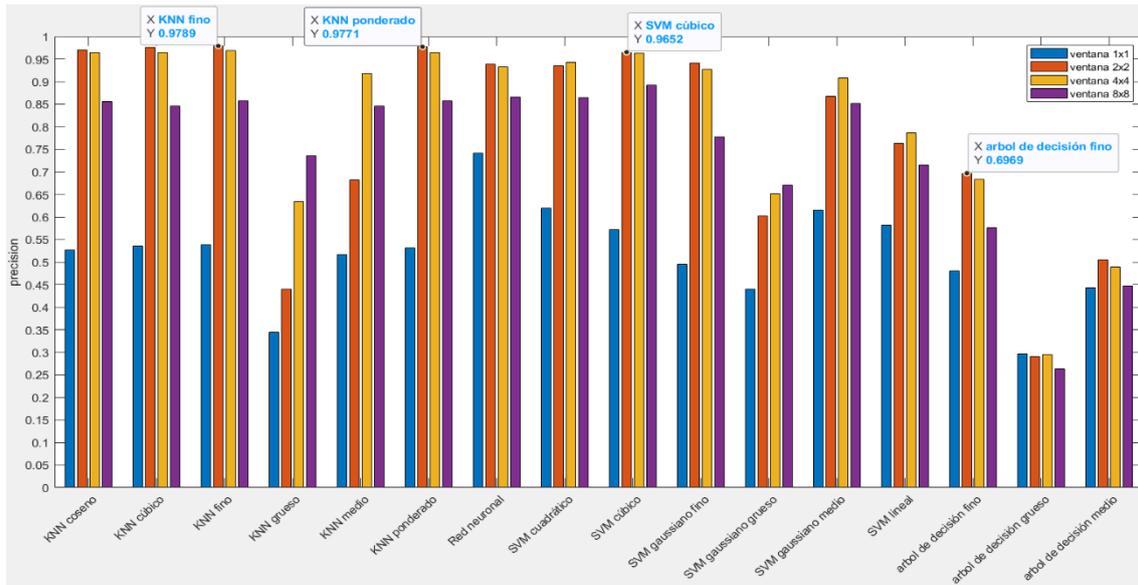
En la gráfica 425 para LBP invariante a rotación con radio 3 en LAB, la ventana de 1x8 es la que provoca, generalmente, los mejores resultados de muchos clasificadores y, conforme la ventana se hace más pequeña, la precisión disminuye. El que mejor resultado ofrece en este caso es el K-NN ponderado con ventana de 1x8, seguido muy de cerca por el valor del K-NN cúbico y del K-NN coseno para la misma ventana.



Gráfica 426. Validación del modelo elegido de la gráfica 425

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 3 en LAB para ventanas en columnas, es del clasificador K-NN ponderado de la gráfica 426.

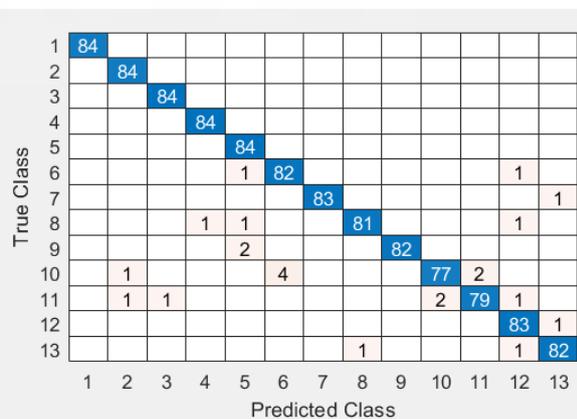
Una vez visto todos los resultados usando LBP invariante a rotación con radio 3 en LAB, el clasificador K-NN ponderado para ventana de 1x8 y el K-NN cúbico para ventana de 8x1 son que mejor precisión ofrecen.



Gráfica 427. Comparación clasificadores para ventanas cuadradas para LBP invariante a rotación con radio 5 en LAB

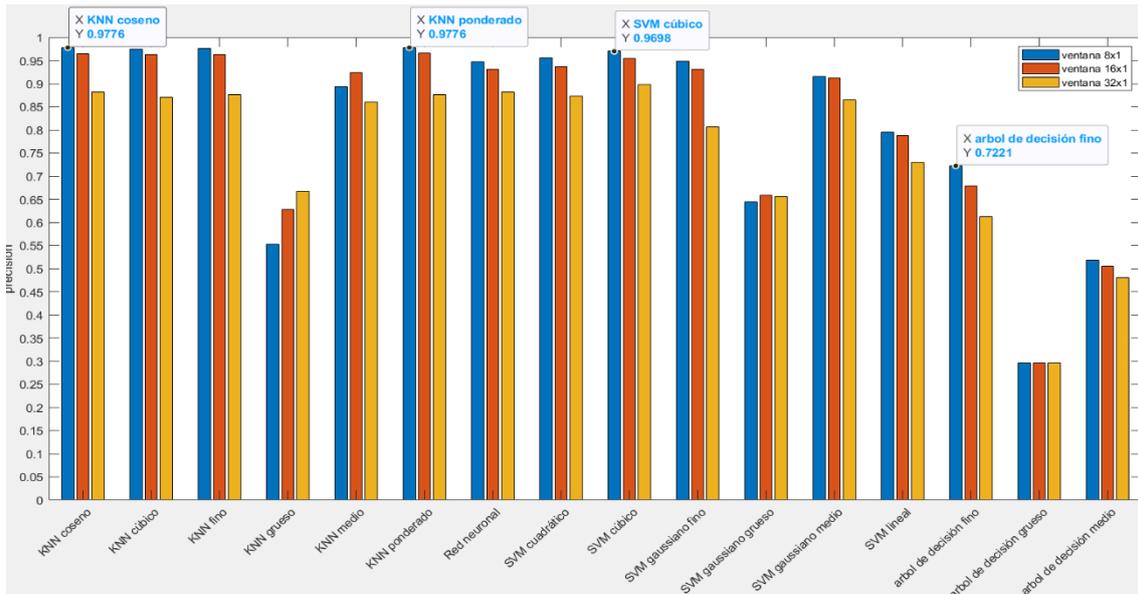
En la gráfica 427 continuando con LBP invariante a rotación con radio 5 en LAB, vemos en la mayoría de los clasificadores es la ventana de 2x2 la que ofrece los mejores resultados. El valor más alto viene por parte del clasificador K-NN fino con ventana de 2x2, y el siguiente es con la misma ventana el K-NN ponderado.

	1	2	3	4	5
	TP	FP	Precision	Recall	F_measure
1	1	0	1	1	1
2	1	0.0019	0.9767	1	0.9882
3	1	9.3545e-04	0.9882	1	0.9941
4	1	9.3545e-04	0.9882	1	0.9941
5	1	0.0037	0.9545	1	0.9767
6	0.9762	0.0037	0.9535	0.9762	0.9647
7	0.9881	0	1	0.9881	0.9940
8	0.9643	9.3545e-04	0.9878	0.9643	0.9759
9	0.9762	0	1	0.9762	0.9880
10	0.9167	0.0019	0.9747	0.9167	0.9448
11	0.9405	0.0019	0.9753	0.9405	0.9576
12	0.9881	0.0037	0.9540	0.9881	0.9708
13	0.9762	0.0019	0.9762	0.9762	0.9762



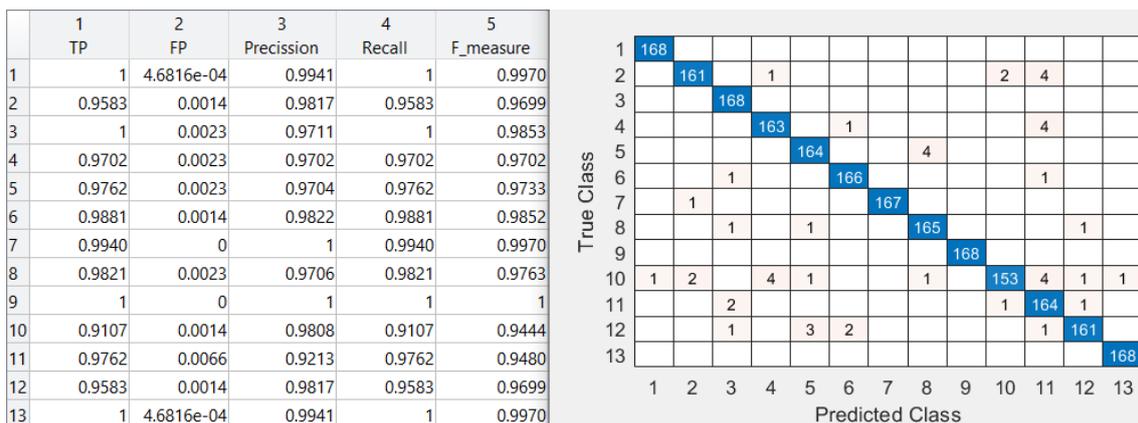
Gráfica 428. Validación del modelo elegido de la gráfica 427

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en LAB para ventanas cuadradas, es del clasificador K-NN fino de la gráfica 428.



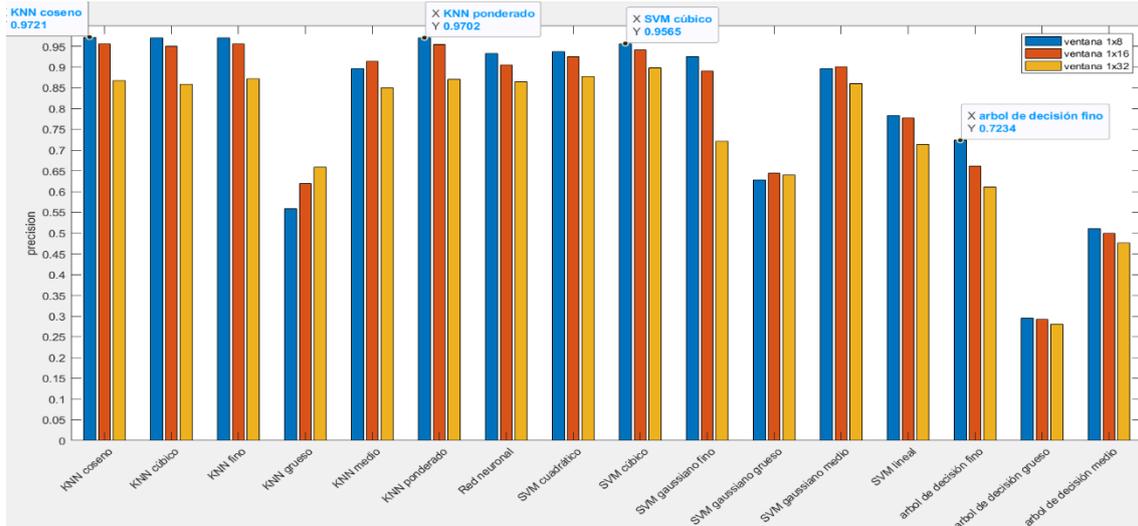
Gráfica 429. Comparación clasificadores para ventanas en filas para LBP invariante a rotación con radio 5 en LAB

En la gráfica 429 la ventana de 8x1 es la que consigue el mejor resultado en la mayoría de los clasificadores usando LBP invariante a rotación con radio 5 en LAB y, si la ventana cambia su tamaño a uno menor la precisión se ve reducida. Los mejores clasificadores son el K-NN coseno y el K-NN ponderado para ventana de 8x1.



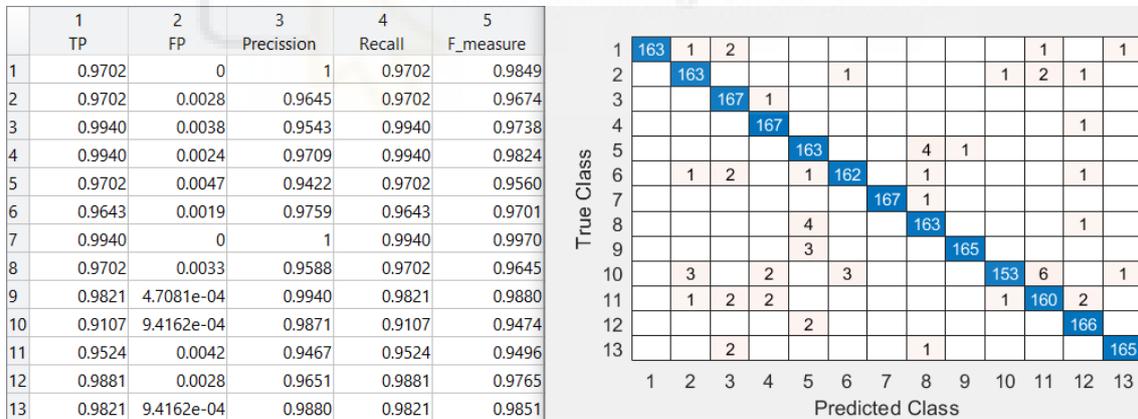
Gráfica 430. Validación del modelo elegido de la gráfica 429

Sacamos del clasificador K-NN ponderado esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en LAB para ventanas en filas de la gráfica 430.



Gráfica 431. Comparación clasificadores para ventanas en columnas para LBP invariante a rotación con radio 5 en LAB

En la gráfica 431 el mejor resultado nos lo da el clasificador K-NN coseno para ventana de 1x8 usando LBP invariante a rotación con radio 5 en LAB. Es apreciable que a medida que la ventana se hace más pequeña la precisión también se reduce en la mayoría de los clasificadores.



Gráfica 432. Validación del modelo elegido de la gráfica 431

Esta representación de la matriz de confusión y las tasas de acierto y error, para LBP invariante a rotación con radio 5 en LAB para ventanas en columnas, es del clasificador K-NN coseno de la gráfica 432.

Visto los resultados anteriores, el clasificador que nos proporciona la precisión más alta es el K-NN fino usando LBP invariante a rotación con radio 5 en LAB y una ventana de 2x2.

## 4.2 Resultados de la CNN

Ahora mostraremos los diferentes resultados ofrecidos por la red neuronal convolucional con distintas configuraciones.

La primera prueba se realizó con los valores por defecto de las distintas características:

Solver = SGDM

Momentum = 0.9

Mini batch size = 64

Max epoch = 30

Shuffle = once

Initial learnt rate = 0.001

Validation frequency = 50

Train data = 70%

Hardware resource = Single CPU

Validation data = 30%

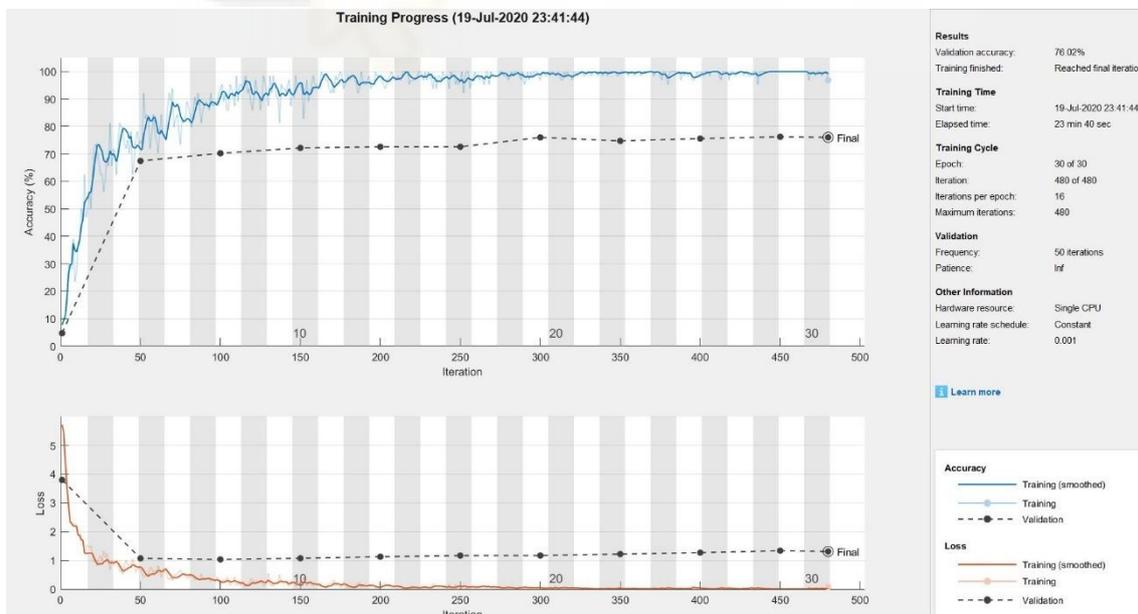


Ilustración 20. Primera configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:15	7.81%	4.71%	5.7089	3.7927	0.0010
4	50	00:02:43	75.00%	67.45%	0.6898	1.0668	0.0010
7	100	00:05:13	93.75%	70.24%	0.2019	1.0306	0.0010
10	150	00:07:41	95.31%	72.16%	0.1322	1.0707	0.0010
13	200	00:10:05	98.44%	72.59%	0.1153	1.1246	0.0010
16	250	00:12:29	96.88%	72.59%	0.0835	1.1647	0.0010
19	300	00:14:54	96.88%	76.02%	0.0744	1.1669	0.0010
22	350	00:17:20	100.00%	74.73%	0.0144	1.2165	0.0010
25	400	00:19:45	100.00%	75.59%	0.0027	1.2662	0.0010
29	450	00:22:11	100.00%	76.23%	0.0086	1.3333	0.0010
30	480	00:23:40	96.88%	76.02%	0.0812	1.3074	0.0010

Tabla 1. Tabla del entrenamiento de la CNN primera configuración

En la ilustración 18 podemos ver cómo ha transcurrido el entrenamiento para la configuración actual. Vemos que hemos obtenido un 76.02% de precisión y el reentrenamiento ha tardado 23 minutos 40 segundos. En la tabla 1 vemos en qué periodo se ha realizado una validación, ya que la validación se hace conforme al número de iteraciones. En esta tabla podemos ver el tiempo entre validación y tanto la precisión como la función a coste.

Solver = SGDM

Momentum = 0.9

Mini batch size = 128

Max epoch = 30

Shuffle = once

Initial learnt rate = 0.001

Validation frequency = 50

Train data = 70%

Hardware resource = Multiple CPU

Validation data = 30%

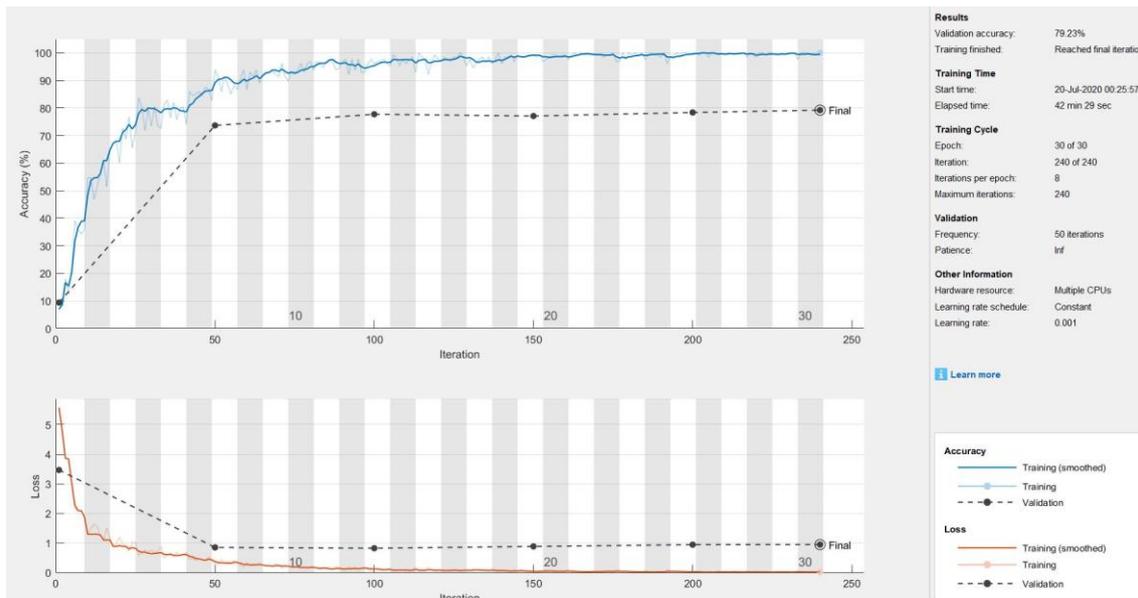


Ilustración 21. Segunda configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:01:25	7.03%	9.42%	5.5763	3.4656	0.0010
7	50	00:15:56	93.75%	73.66%	0.2801	0.8489	0.0010
13	100	00:23:38	96.09%	77.73%	0.1193	0.8220	0.0010
19	150	00:30:32	99.22%	77.09%	0.0393	0.8820	0.0010
25	200	00:37:18	100.00%	78.37%	0.0240	0.9413	0.0010
30	240	00:42:29	100.00%	79.23%	0.0160	0.9445	0.0010

Tabla 2. Tabla del entrenamiento de la CNN segunda configuración

En la ilustración 19 vemos que el entrenamiento ha mantenido unos valores estables y esta vez hemos alcanzado un poco más de precisión que en el caso anterior, un 79.23%. Esta vez el tiempo de entrenamiento ha sido de 42 min 29 segundos, cerca de duplicar el tiempo anterior. Viendo la tabla 2, comprobamos que la función de coste ha sido mejor optimizada esta vez.

Solver = SGDM

Momentum = 0.9

Mini batch size = 32

Max epoch = 30

Shuffle = once

Initial learnt rate = 0.001

Validation frequency = 50

Train data = 70%

Hardware resource = Multiple CPU

Validation data = 30%

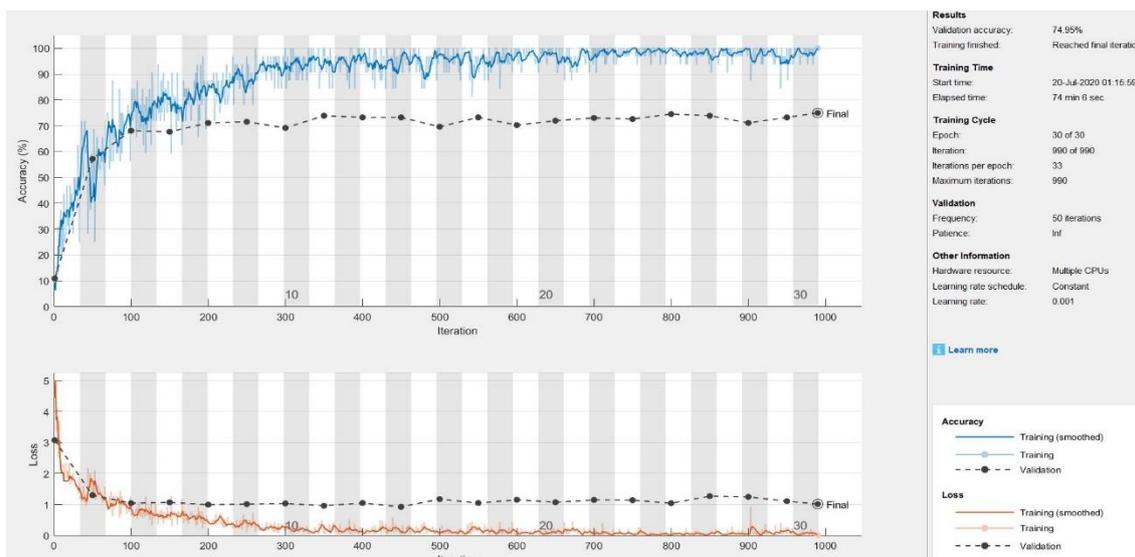


Ilustración 22. Tercera configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:01:10	9.38%	10.92%	4.4385	3.0761	0.0010
2	50	00:07:08	53.13%	57.17%	1.3768	1.3007	0.0010
4	100	00:10:48	78.13%	68.09%	0.6425	1.0421	0.0010
5	150	00:14:21	78.13%	67.67%	0.7382	1.0679	0.0010
7	200	00:17:53	84.38%	71.09%	0.4757	0.9928	0.0010
8	250	00:21:29	96.88%	71.52%	0.1095	1.0129	0.0010
10	300	00:25:07	100.00%	69.16%	0.0854	1.0327	0.0010
11	350	00:28:57	96.88%	73.88%	0.1310	0.9591	0.0010
13	400	00:32:28	96.88%	73.23%	0.0971	1.0478	0.0010
14	450	00:35:57	100.00%	73.23%	0.0455	0.9229	0.0010
16	500	00:39:25	100.00%	69.59%	0.0694	1.1725	0.0010
17	550	00:42:57	93.75%	73.23%	0.2668	1.0475	0.0010
19	600	00:46:24	96.88%	70.24%	0.0522	1.1505	0.0010
20	650	00:49:50	96.88%	71.95%	0.0865	1.0725	0.0010
22	700	00:53:21	100.00%	73.02%	0.0079	1.1468	0.0010
23	750	00:56:56	100.00%	72.59%	0.0231	1.1399	0.0010
25	800	01:00:53	100.00%	74.52%	0.0314	1.0405	0.0010
26	850	01:04:19	96.88%	73.88%	0.0539	1.2684	0.0010
28	900	01:07:45	100.00%	71.09%	0.0289	1.2456	0.0010
29	950	01:11:15	100.00%	73.23%	0.0373	1.1063	0.0010
30	990	01:14:06	100.00%	74.95%	0.0056	1.0130	0.0010

Tabla 3. Tabla del entrenamiento de la CNN tercera configuración

Con la nueva configuración podemos ver en la ilustración 20, que esta vez hemos obtenido un 73.95% de precisión con un tiempo de entrenamiento de 74 minutos 6 segundos. El tiempo ha sido demasiado elevado y el resultado conseguido es peor que los anteriores, lo que ya nos hace no considerar esta configuración. En la tabla 3 vemos que ha vuelto a empeorar la optimización de la función de coste.

Solver = SGDM

Momentum = 0.9

Mini batch size = 128

Max epoch = 15

Shuffle = once

Initial learnt rate = 0.001

Validation frequency = 50

Train data = 70%

Hardware resource = Multiple CPU

Validation data = 30%

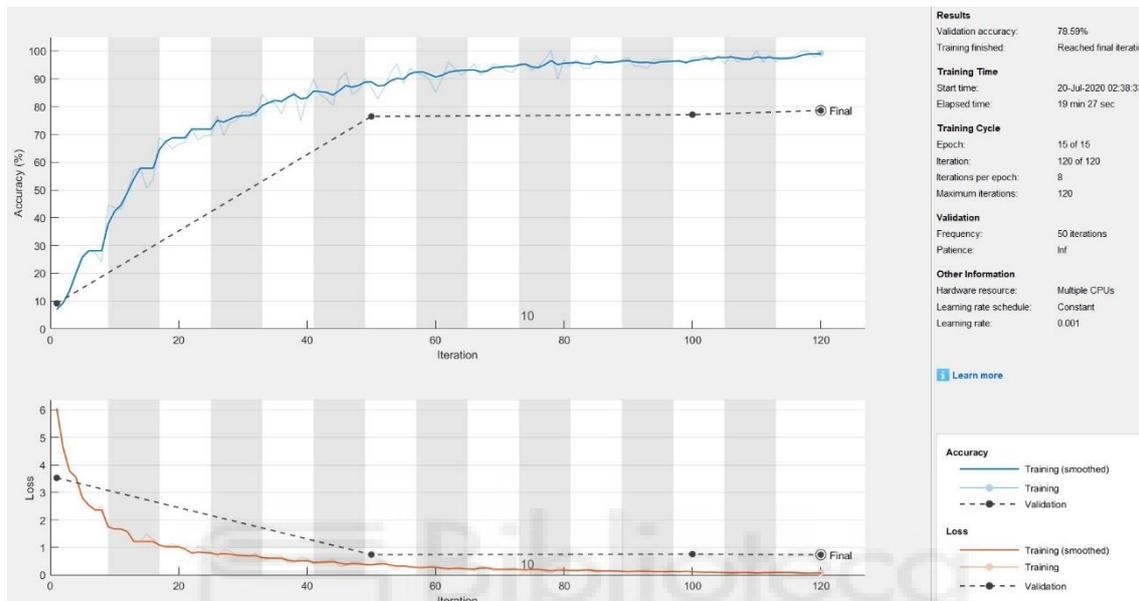


Ilustración 23. Cuarta configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:01:41	7.03%	9.21%	6.0489	3.5261	0.0010
7	50	00:10:44	86.72%	76.45%	0.3492	0.7389	0.0010
13	100	00:16:54	97.66%	77.09%	0.0947	0.7545	0.0010
15	120	00:19:27	99.22%	78.59%	0.0839	0.7353	0.0010

Tabla 4. Tabla del entrenamiento de la CNN cuarta configuración

En la ilustración 21 podemos ver como la precisión es de 78.59% con un tiempo de 19 minutos y 27 segundos. El tiempo está muy bien para el resultado obtenido. Al reducir el número de periodos ('epoch'), el número de iteraciones total disminuye y, al ser la frecuencia de validación 50 iteraciones, se producen pocas validaciones.

Solver = SGDM

Momentum = 0.9

Mini batch size = 128

Max epoch = 45

Shuffle = once

Initial learnt rate = 0.001

Validation frequency = 50

Train data = 70%

Hardware resource = Multiple CPU

Validation data = 30%

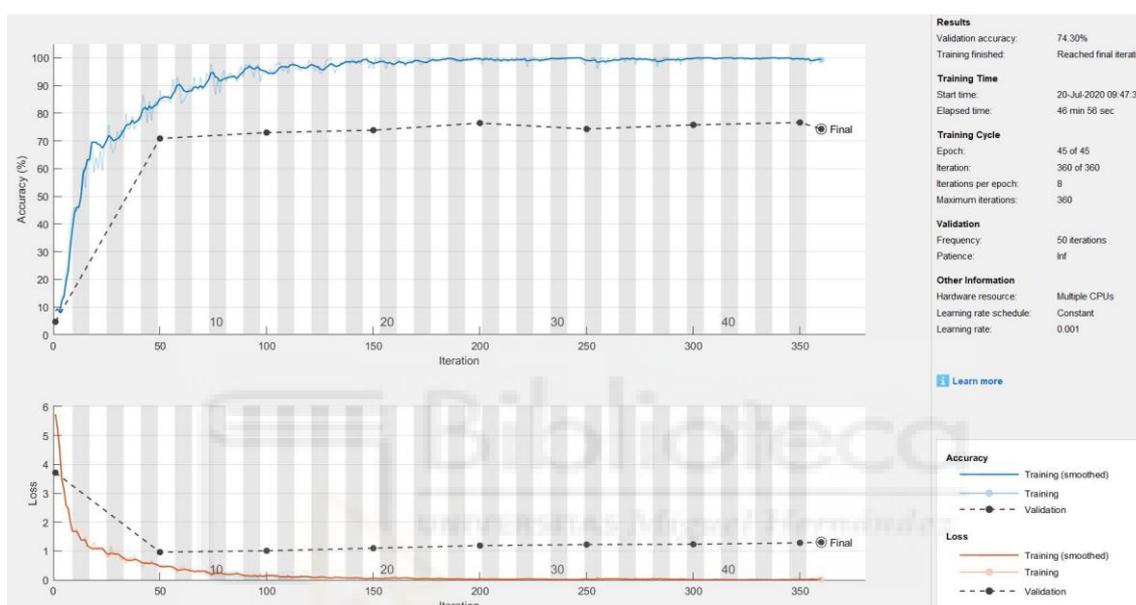


Ilustración 24. Quinta configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:45	8.59%	4.71%	5.7333	3.7106	0.0010
7	50	00:09:00	88.28%	70.88%	0.4362	0.9637	0.0010
13	100	00:15:15	94.53%	73.02%	0.1644	1.0103	0.0010
19	150	00:21:22	96.09%	73.88%	0.1102	1.0996	0.0010
25	200	00:27:26	99.22%	76.45%	0.0315	1.1893	0.0010
32	250	00:33:28	99.22%	74.30%	0.0167	1.2262	0.0010
38	300	00:39:28	100.00%	75.80%	0.0132	1.2339	0.0010
44	350	00:45:31	99.22%	76.66%	0.0445	1.2846	0.0010
45	360	00:46:56	99.22%	74.30%	0.0149	1.3064	0.0010

Tabla 5. Tabla del entrenamiento de la CNN quinta configuración

En esta configuración tenemos una precisión de 74.30% y el tiempo de entrenamiento ha sido de 46 minutos 56 segundos. El tiempo es elevado en comparación con otras configuraciones y el resultado no hace que merezca la pena. Respecto a la tabla 5 podemos ver que tarda unos 6 minutos entre validación y validación.

Solver = SGDM

Momentum = 0.9

Mini batch size = 128

Max epoch = 30

Shuffle = once

Initial learnt rate = 0.0001

Validation frequency = 25

Train data = 70%

Hardware resource = Multiple CPU

Validation data = 30%

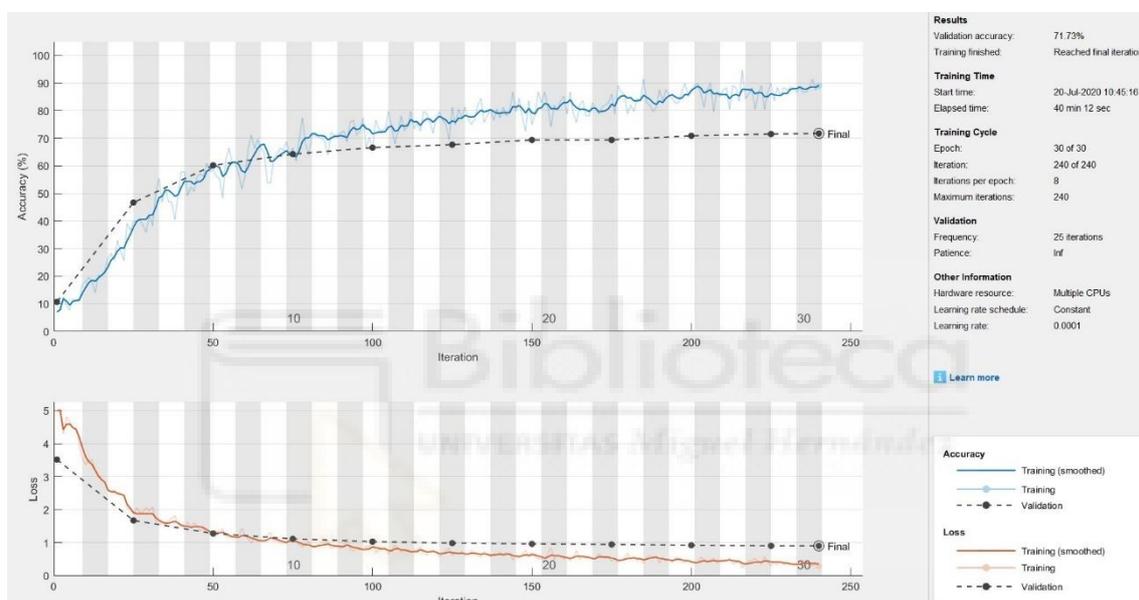


Ilustración 25. Sexta configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:46	7.03%	10.71%	4.9910	3.5143	1.0000e-04
4	25	00:12:43	39.84%	46.68%	1.8731	1.6701	1.0000e-04
7	50	00:15:55	58.59%	60.17%	1.3488	1.2735	1.0000e-04
10	75	00:19:04	66.41%	64.24%	1.0236	1.1117	1.0000e-04
13	100	00:22:16	66.41%	66.60%	1.0629	1.0283	1.0000e-04
16	125	00:25:26	81.25%	67.67%	0.6153	0.9813	1.0000e-04
19	150	00:28:40	75.00%	69.38%	0.6926	0.9582	1.0000e-04
22	175	00:31:49	85.94%	69.38%	0.4405	0.9412	1.0000e-04
25	200	00:34:59	87.50%	70.88%	0.4065	0.9168	1.0000e-04
29	225	00:38:14	89.84%	71.52%	0.2898	0.9009	1.0000e-04
30	240	00:40:12	89.06%	71.73%	0.2830	0.8987	1.0000e-04

Tabla 6. Tabla del entrenamiento de la CNN sexta configuración

En esta configuración vemos como la precisión ha disminuido más todavía, y el tiempo que ha tardado en el entrenamiento, 40 min 12 segundos, tampoco hace que se considere una buena opción. Al aumentar el ritmo de aprendizaje

inicial debería haber mejorado algo la precisión, que es solo de 71.73%, y si que era lógico pensar que el tiempo de entrenamiento aumentaría.

Solver = SGDM

Momentum = 0.9

Mini batch size = 128

Max epoch = 25

Shuffle = once

Initial learnt rate = 0.01

Validation frequency = 25

Train data = 70%

Hardware resource = Single CPU

Validation data = 30%

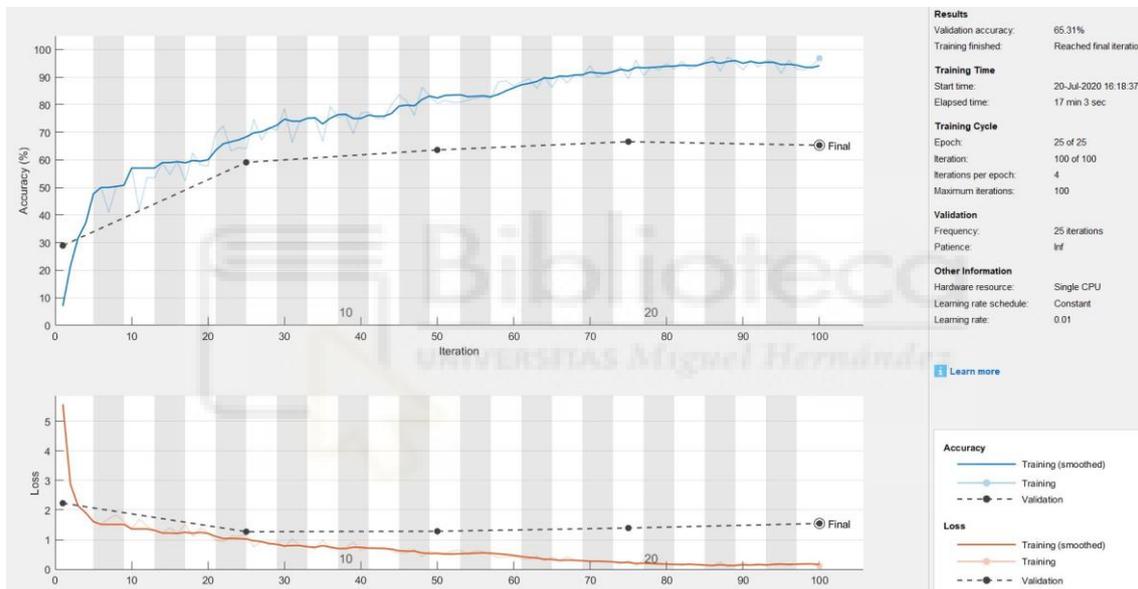


Ilustración 26. Séptima configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:28	7.03%	28.91%	5.5716	2.2296	0.0100
7	25	00:04:31	64.06%	59.10%	1.1581	1.2697	0.0100
13	50	00:08:47	80.47%	63.60%	0.5452	1.2829	0.0100
19	75	00:12:56	89.45%	66.60%	0.2930	1.3930	0.0100
25	100	00:17:03	96.88%	65.31%	0.1096	1.5463	0.0100

Tabla 7. Tabla del entrenamiento de la CNN séptima configuración

Podemos ver que al aumentar el ritmo de aprendizaje inicial el resultado es aún peor que antes, 65.31%, aunque, como era de esperar, el tiempo de entrenamiento si que ha disminuido, es de 17 minuto 3 segundos. También podemos apreciar que la función de coste no ha alcanzado un buen resultado.

Solver = SGDM

Momentum = 0.9

Mini batch size = 256

Max epoch = 30

Shuffle = once

Initial learnt rate = 0.001

Validation frequency = 25

Train data = 70%

Hardware resource = Single CPU

Validation data = 30%

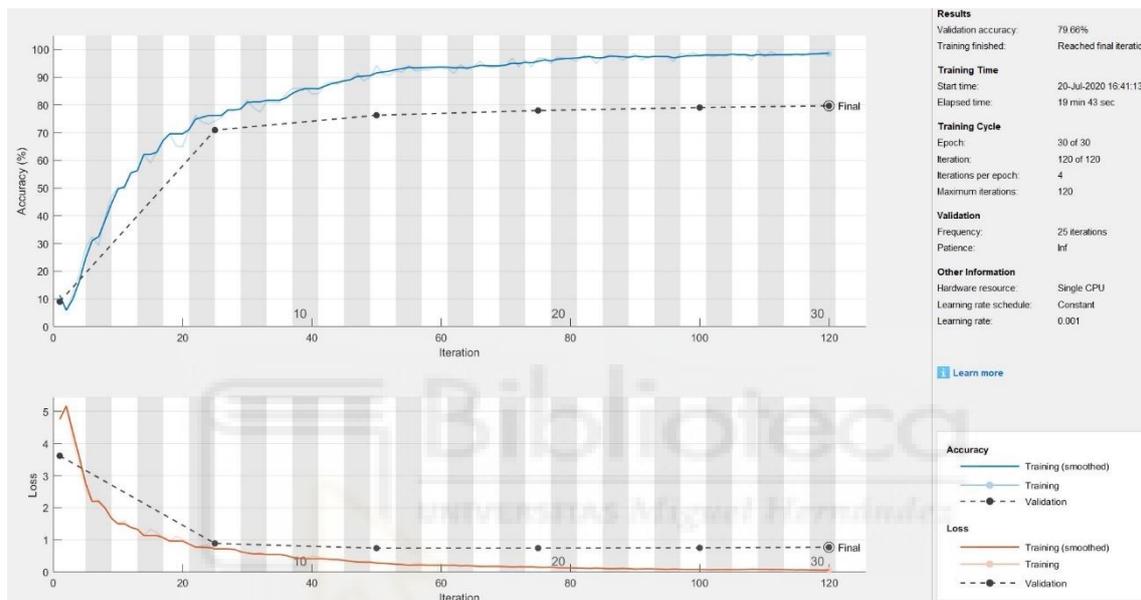


Ilustración 27. Octava configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:19	11.33%	8.99%	4.7530	3.6154	0.0010
7	25	00:04:14	74.22%	70.88%	0.7172	0.8880	0.0010
13	50	00:08:18	94.14%	76.23%	0.2376	0.7405	0.0010
19	75	00:12:17	96.88%	77.94%	0.1168	0.7425	0.0010
25	100	00:16:28	97.66%	79.01%	0.0836	0.7491	0.0010
30	120	00:19:43	98.44%	79.66%	0.0620	0.7682	0.0010

Tabla 8. Tabla del entrenamiento de la CNN octava configuración

Con esta nueva configuración el resultado ha aumentado y ha vuelto al rango de valores que obteníamos al principio. La precisión es de 79.66%. El hecho de aumentar el tamaño del subconjunto de datos de validación ha resultado efectivo y, respecto al tiempo, no ha tardado mucho, 19 minutos 43 segundos.

Solver = SGDM

Momentum = 0.9

Mini batch size = 128

Max epoch = 35

Shuffle = once

Initial learnt rate = 0.001

Validation frequency = 25

Train data = 80%

Hardware resource = Single CPU

Validation data = 20%

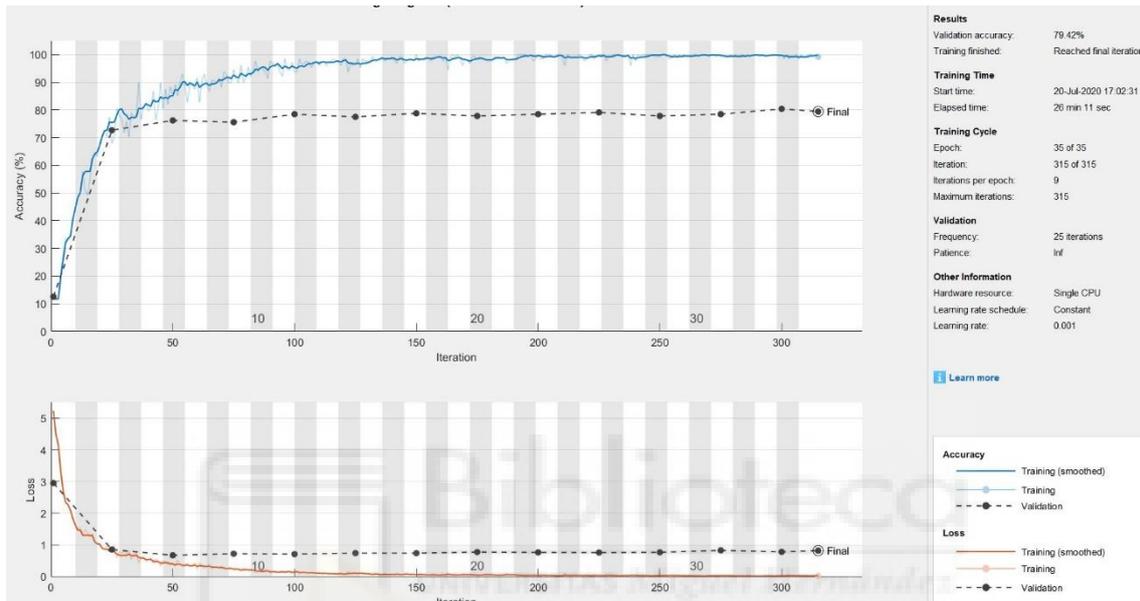


Ilustración 28. Novena configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:09	11.72%	12.54%	5.2372	2.9498	0.0010
3	25	00:02:07	67.97%	72.67%	0.9205	0.8505	0.0010
6	50	00:04:11	85.16%	76.21%	0.3807	0.6673	0.0010
9	75	00:06:15	94.53%	75.56%	0.2032	0.7166	0.0010
12	100	00:08:20	93.75%	78.46%	0.1680	0.7052	0.0010
14	125	00:10:24	96.88%	77.49%	0.1001	0.7357	0.0010
17	150	00:12:27	100.00%	78.78%	0.0266	0.7334	0.0010
20	175	00:14:31	98.44%	77.81%	0.0344	0.7694	0.0010
23	200	00:16:34	100.00%	78.46%	0.0259	0.7589	0.0010
25	225	00:18:37	100.00%	79.10%	0.0162	0.7533	0.0010
28	250	00:20:41	99.22%	77.81%	0.0425	0.7616	0.0010
31	275	00:22:46	99.22%	78.46%	0.0315	0.8239	0.0010
34	300	00:24:54	100.00%	80.39%	0.0113	0.7758	0.0010
35	315	00:26:11	99.22%	79.42%	0.0164	0.8154	0.0010

Tabla 9. Tabla del entrenamiento de la CNN novena configuración

En esta nueva configuración, hemos aumentado el tamaño de los datos de entrenamiento, ahora usamos el 80% de los datos para entrenar a la red neuronal y el otro 20% para la validación. El resultado ha sido que tenemos

una precisión relativamente buena, 79.42%. Y hablando en términos de tiempo, ha tardado 26 minutos 11 segundos, que se excede de lo normal.

Solver = SGDM

Momentum = 1

Mini batch size = 128

Max epoch = 35

Shuffle = once

Initial learnt rate = 0.001

Validation frequency = 25

Train data = 80%

Hardware resource = Single CPU

Validation data = 20%

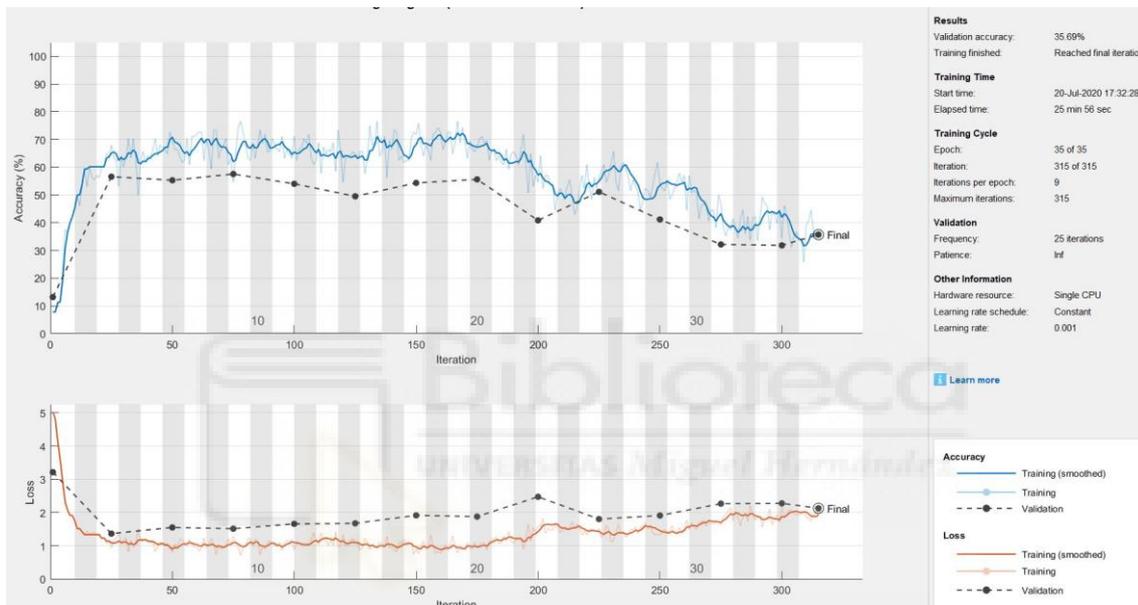


Ilustración 29. Decima configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:08	7.81%	13.18%	5.0272	3.2140	0.0010
3	25	00:02:04	67.97%	56.59%	0.9365	1.3662	0.0010
6	50	00:04:07	69.53%	55.31%	0.8083	1.5527	0.0010
9	75	00:06:12	54.69%	57.56%	1.2835	1.5150	0.0010
12	100	00:08:16	71.09%	54.02%	0.8846	1.6590	0.0010
14	125	00:10:20	64.84%	49.52%	1.1112	1.6759	0.0010
17	150	00:12:23	71.88%	54.34%	0.8876	1.9155	0.0010
20	175	00:14:27	67.19%	55.63%	0.9378	1.8785	0.0010
23	200	00:16:30	54.69%	40.84%	1.5750	2.4743	0.0010
25	225	00:18:34	56.25%	51.13%	1.5065	1.8042	0.0010
28	250	00:20:37	53.91%	41.16%	1.3186	1.9114	0.0010
31	275	00:22:39	46.88%	32.15%	1.6443	2.2682	0.0010
34	300	00:24:41	34.38%	31.83%	2.2306	2.2784	0.0010
35	315	00:25:56	35.94%	35.69%	2.0449	2.1297	0.0010

Tabla 10. Tabla del entrenamiento de la CNN decima configuración

Respecto a esta configuración, hemos mantenido la división de los datos en 80% para entrenamiento y 20% para validación. Lo que hemos modificado ha

vido el 'momentum' y eso ha desencadenado un resultado muy malo, 35.69%, tardando en el entrenamiento 25 minutos 56 segundos. Lo establecimos a 1, que es el máximo.

Solver = SGDM

Momentum = 0.7

Mini batch size = 128

Max epoch = 35

Shuffle = once

Initial learnt rate = 0.001

Validation frequency = 25

Train data = 80%

Hardware resource = Single CPU

Validation data = 20%

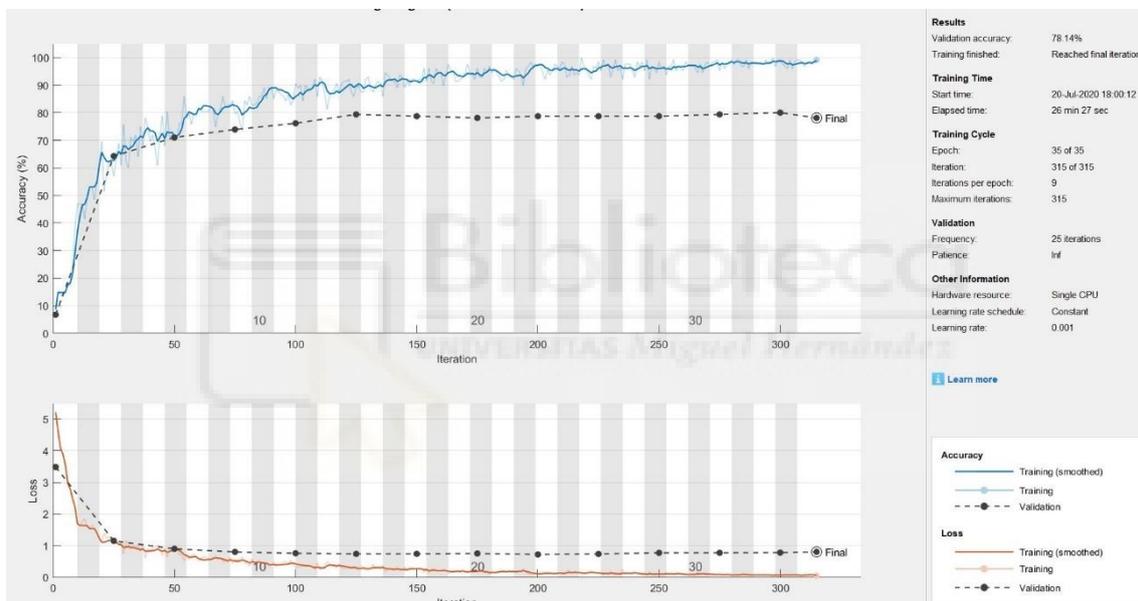


Ilustración 30. Undécima configuración CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:09	8.59%	6.75%	5.2160	3.4841	0.0010
3	25	00:02:08	57.03%	64.31%	1.2359	1.1462	0.0010
6	50	00:04:13	70.31%	71.06%	0.8773	0.8959	0.0010
9	75	00:06:19	79.69%	73.95%	0.5588	0.7971	0.0010
12	100	00:08:25	90.63%	76.21%	0.3080	0.7546	0.0010
14	125	00:10:29	89.06%	79.42%	0.3181	0.7361	0.0010
17	150	00:12:34	91.41%	78.78%	0.2702	0.7370	0.0010
20	175	00:14:38	96.09%	78.14%	0.1833	0.7471	0.0010
23	200	00:16:43	96.88%	78.78%	0.0967	0.7190	0.0010
25	225	00:18:50	98.44%	78.78%	0.1229	0.7333	0.0010
28	250	00:20:57	98.44%	78.78%	0.0782	0.7695	0.0010
31	275	00:23:03	95.31%	79.42%	0.1125	0.7708	0.0010
34	300	00:25:09	99.22%	80.06%	0.0574	0.7766	0.0010
35	315	00:26:27	99.22%	78.14%	0.0413	0.7995	0.0010

Tabla 11. Tabla del entrenamiento de la CNN undécima configuración

Al igual que en la configuración anterior, la partición de la información sigue siendo de 80/20 y hemos vuelto a modificar el 'momentum', esta vez le hemos puesto un valor de 0.7. Todos esto ha ocasionado que la precisión haya aumentado hasta volver a valores más lógicos.

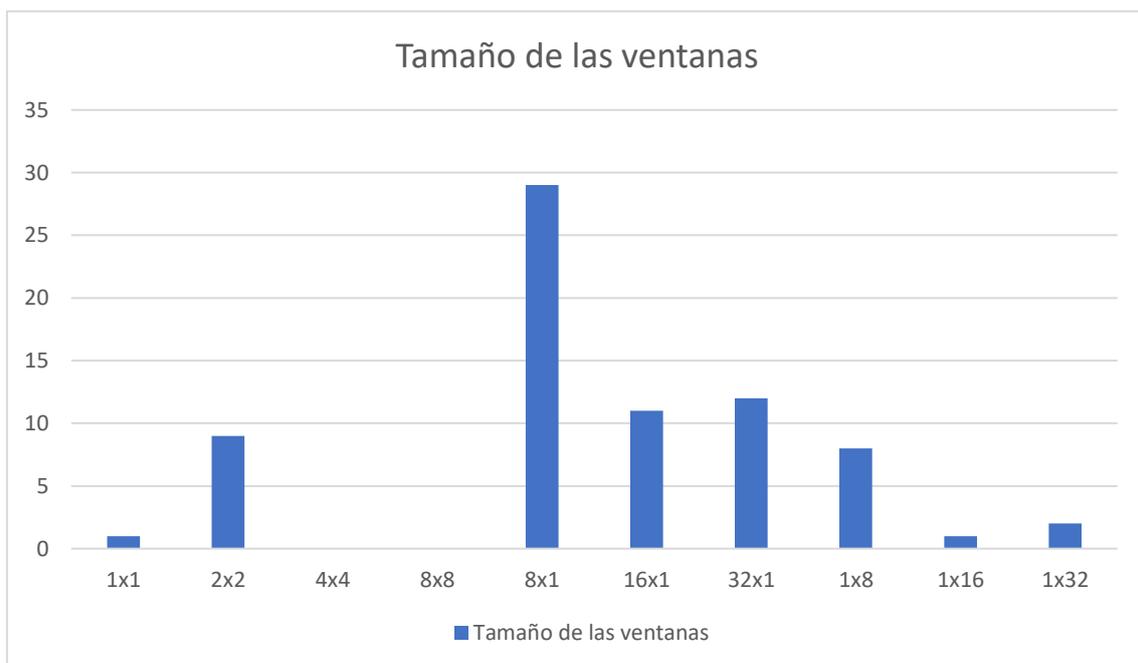


## 5. Conclusiones

En este capítulo se expondrán las conclusiones obtenidas en base a los resultados del capítulo anterior. Hemos realizado las distintas pruebas en busca de la mejor manera para establecer un sistema de clasificación mediante visión por computador. Hemos utilizado tres distintos tipos de descriptores: los momentos de histograma, la matriz de coocurrencia y los patrones locales binarios. Y, respecto a la clasificación, hemos utilizados K-NN ponderado, K-NN fino, K-NN medio, K-NN grueso, K-NN cúbico, K-NN coseno, SVM lineal, SVM cuadrático, SVM cúbico, SVM gaussiano fino, SVM gaussiano medio, SVM gaussiano grueso, árbol de decisión fino, árbol de decisión medio, árbol de decisión grueso y una red neuronal. También se ha utilizado un clasificador basado 'transfer learning', la red neuronal convolucional Alexnet.

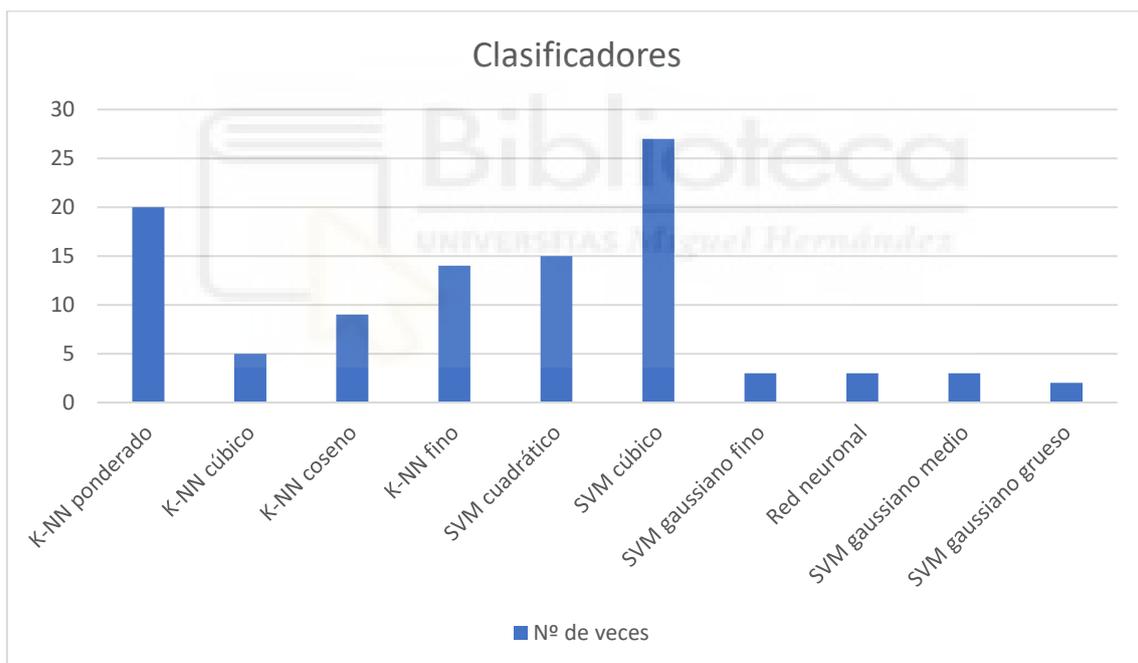
### 5.1 Análisis de los resultados de los espacios de color y clasificadores de imagen

Como ya se ha explicado anteriormente, el análisis se ha realizado con distintos tamaños de ventana y proporciones para varios espacios de color usando diferentes descriptores.



Se ha contabilizado las veces que una ventana daba la precisión máxima en los distintos espacios de color para cada descriptor. Como bien refleja el gráfico anterior, la ventana de 8x1 es la que más veces ha conseguido obtener el valor más alto. Además, también se puede comprobar que las ventanas de 16x1 y 32x2 son las siguientes que más veces han conseguido la precisión más alta. Por todo esto, se puede concluir que, si las imágenes son analizadas con ventanas en fila, los resultados serán mejores.

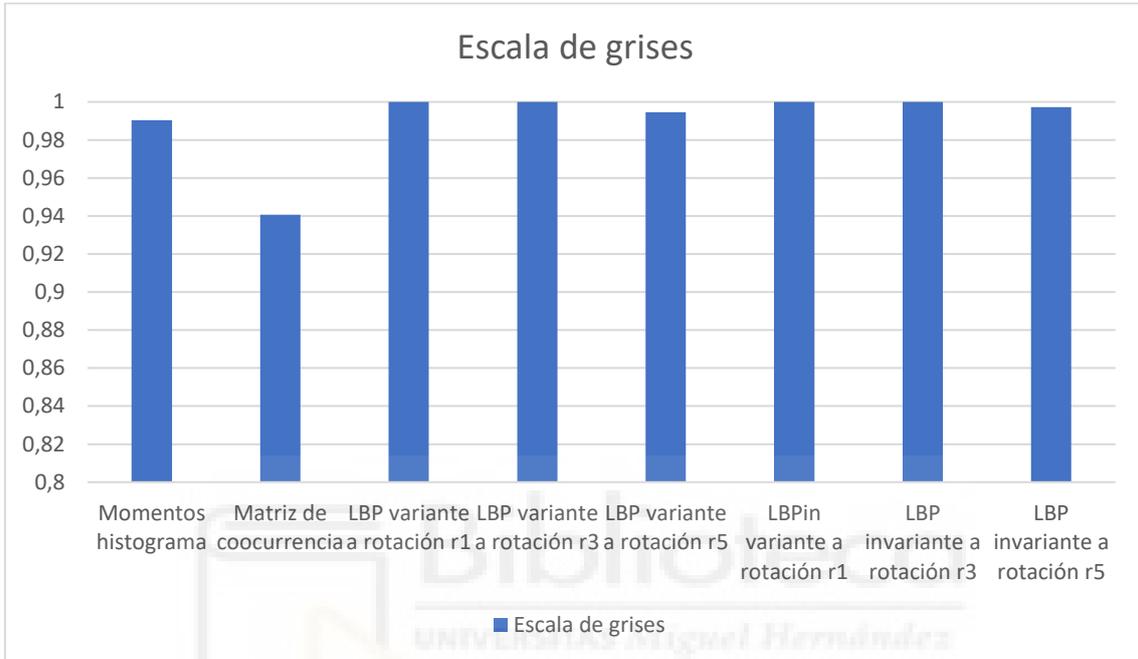
Ahora que ya sabemos las ventanas que suelen propiciar los mejores resultados, tenemos que comprobar que clasificador es el más usado y cual el que mejor resultado proporciona. Hay que tener en cuenta que, a veces, dos clasificadores obtenían el mismo o prácticamente el mismo resultado.



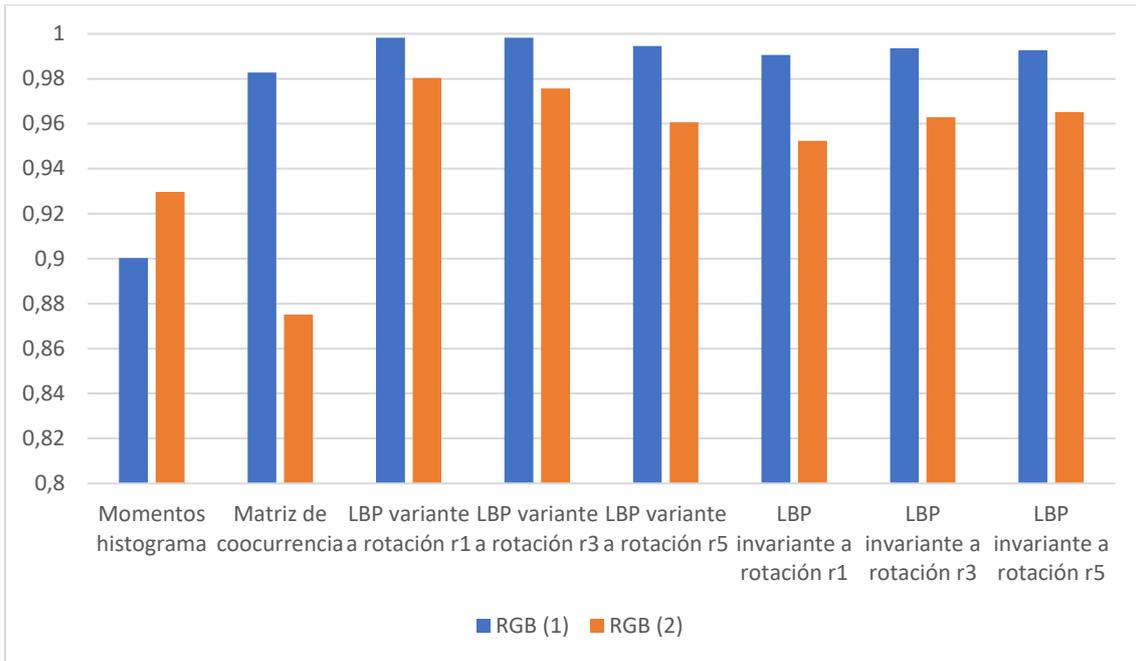
Se han contabilizado los clasificadores que, en las distintas combinaciones de descriptores, espacios de color y ventana, han proporcionado el valor de precisión más alto. Como se puede observar el clasificador SVM cúbico es el que, por lo general, ha proporcionado más veces los mejores resultados. Hay que recalcar que aquí solo se pone de manifiesto que clasificadores son los más propensos a dar el mejor resultado, no que lo den siempre. También, podemos

darnos cuenta de que en ningún momento un árbol de decisión ha conseguido un valor determinante, de ahí que no aparezca ninguno en la gráfica.

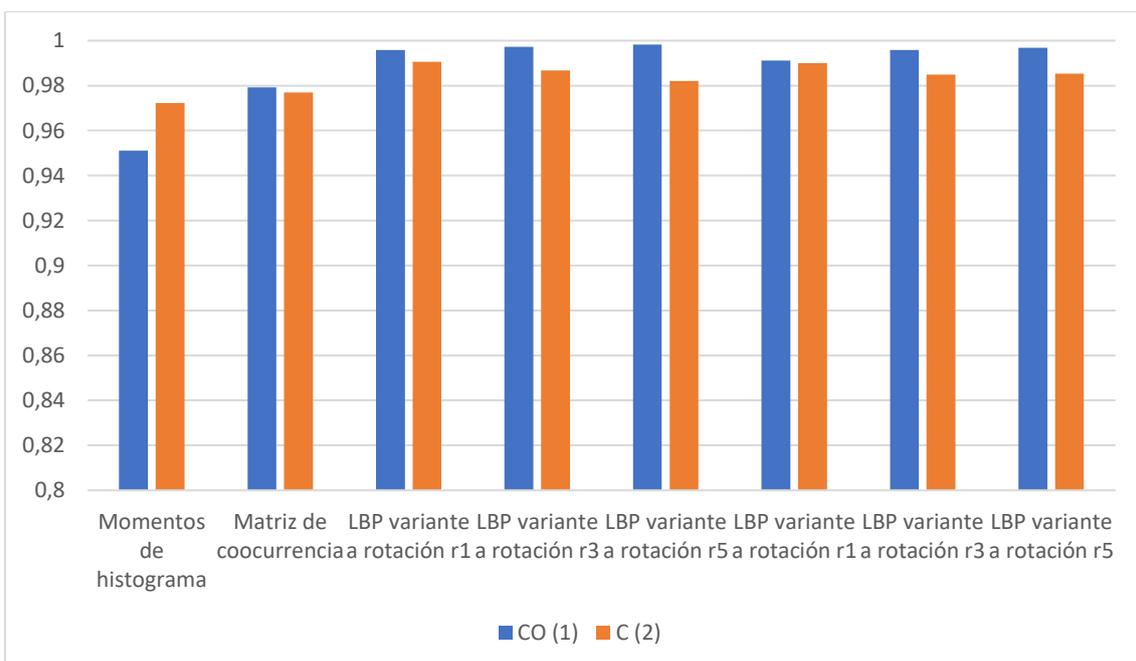
Ahora, empezaremos a comparar las respectivas precisiones de las distintas configuraciones posibles.



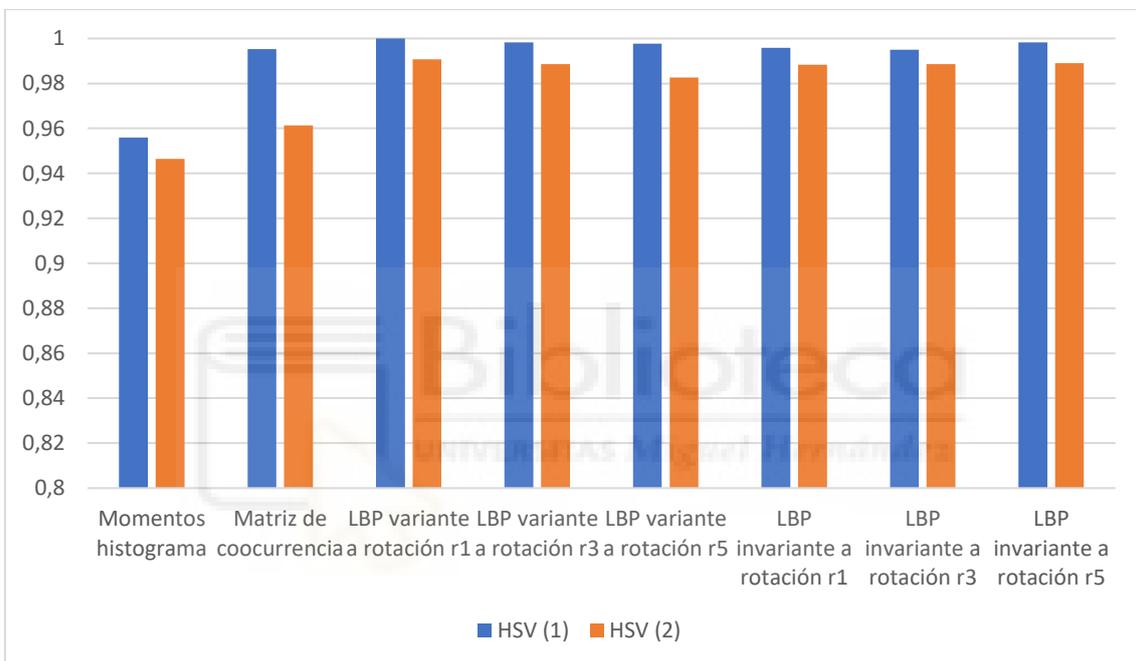
Para escala de grises solo se ha usado el primer data set. En este caso ha sido la matriz de coocurrencia la que peor resultado ha arrojado si la comparamos con el resto de descriptores. En la gráfica, siguiendo con esta comparación, LBP en general ha sido el que mejor resultado ha ofrecido independientemente del radio.



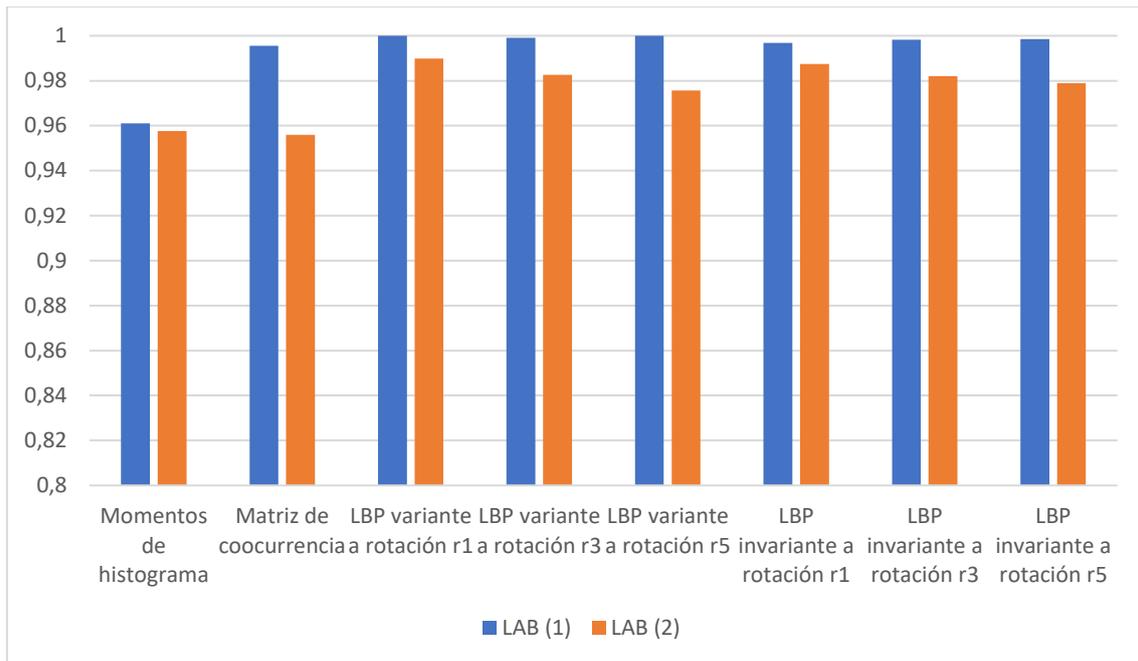
Esta última gráfica muestra la mejor precisión obtenida por cada descriptor en el espacio RGB. Vemos que, en ambos casos, los momentos de histograma adquieren valores menores que el resto. También queda claro que cuando usamos LBP variante a rotación con radio 1, conseguimos el valor de precisión más alto en ambos casos. Por último, cabe mencionar que los resultados son un poco mejores cuando usamos LBP variante a rotación que cuando usamos LBP invariante a rotación.



Podemos ver en la gráfica anterior las mejores precisiones obtenidas por los distintos descriptores utilizados en colores opuestos. Vemos que con momentos de histograma los resultados son peores en comparación con el resto de resultados. Generalmente, los resultados son elevados y muy parecidos entre sí, comprobamos que para el segundo data set es con LBP variante a rotación con radio 5 con el que obtenemos la mayor precisión, pero para el tercer data set es con LBP variante a rotación con radio 1. Esto último refleja que los valores de LBP variante a rotación son mejores que los de LBP invariante a rotación.



Esta gráfica nos muestra los resultados obtenidos en el espacio de color HSV para los diferentes descriptores utilizados. Con los momentos de histograma logramos los peores resultados de toda la gráfica. Y queda claro que el mejor descriptor es el LBP variante a rotación con radio 1, ya que obtiene el valor más alto para ambos data sets. También podemos ver que los resultados de cualquier configuración de LBP son mejores que los de los momentos de histograma y matriz de coocurrencia.



Esta última gráfica refleja los resultados obtenidos por los diferentes descriptores en el espacio de color LAB. Se puede observar que los momentos de histograma son los que no proporcionan los peores valores en comparación con los del resto de la gráfica. También queda en manifiesto que al usar LBP variante a rotación con radio 1 obtenemos el mejor valor de toda la gráfica tanto para un data set como para el otro.

## 5.2 Análisis de los resultados de la CNN

Respecto a la red neuronal convolucional, hemos visto ya las distintas configuraciones probadas para obtener la mayor precisión posible, así que se ha hecho un último entrenamiento mezclando las características que hacían mejorar el modelo.

Solver = SGDM

Momentum = 0.7

Mini batch size = 256

Max epoch = 30

Shuffle = once

Initial learnt rate = 0.001

Validation frequency = 25

Train data = 80%

Hardware resource = Single CPU

Validation data = 20%

Hemos establecido los valores de las características como se muestra en la tabla anterior. Con esta configuración este ha sido el resultado obtenido:

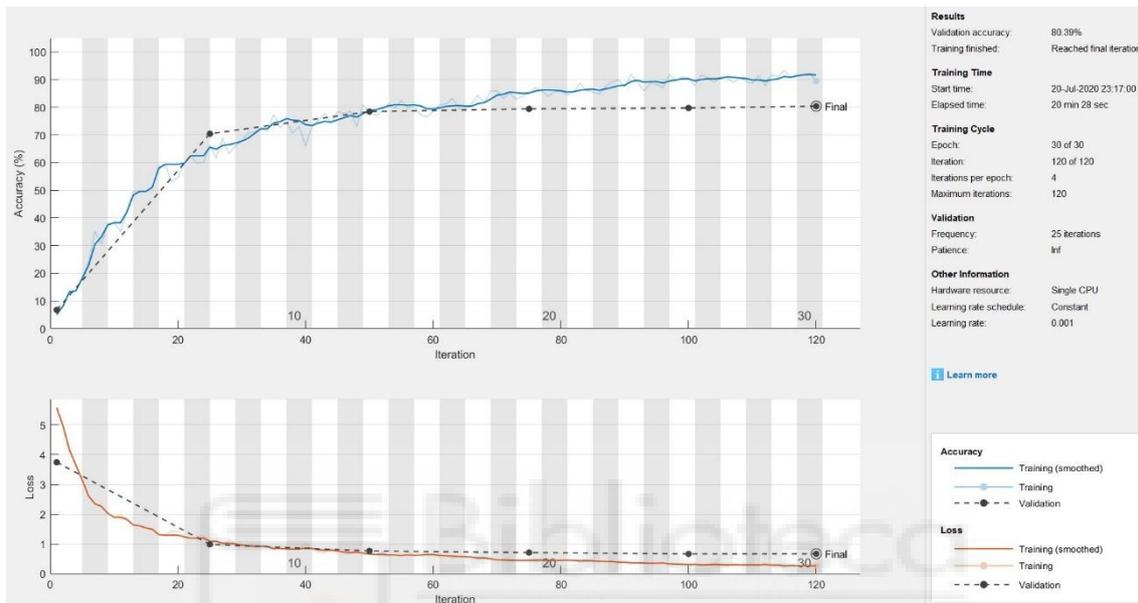


Ilustración 31. Progreso del entrenamiento de la CNN

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:45	5.08%	6.75%	5.5848	3.7473	0.0010
7	25	00:05:11	66.02%	70.42%	1.0883	0.9826	0.0010
13	50	00:09:13	78.52%	78.46%	0.6530	0.7599	0.0010
19	75	00:13:14	85.16%	79.42%	0.4812	0.7058	0.0010
25	100	00:17:14	90.23%	79.74%	0.2918	0.6619	0.0010
30	120	00:20:28	89.45%	80.39%	0.2816	0.6644	0.0010

Tabla 12. Tabla del entrenamiento de la CNN última configuración

Como podemos observar la ilustración 29 hemos alcanzado una precisión de 80.39% en un tiempo de 20 minutos 28 segundos. Es la mayor precisión que hemos obtenido y el tiempo es relativamente bajo.

### 5.3 Trabajos futuros

Ya hemos estudiados muchas configuraciones posibles entre espacios de color, descriptores y tamaño de ventanas. Ahora que ya se ha reducido el número de posibilidad, ya que sabemos tanto que descriptor es más eficiente, que espacio de color es más útil y que clasificador responde mejor, se podría intentar llevar un paso más allá e intentarlo con distintas texturas en la misma imagen. Esto sería un primer paso para poder analizar las distintas texturas, no objetos ya que un objeto puede tener distintas texturas, en tiempo real. Me parece de gran utilidad esta vía, porque hay procesos que no solo se necesita saber, lo típico, que objeto es, sino que la textura puede lograr una mayor diferenciación.



## Bibliografía

- [1] Menche N (Ed). Biologie Anatomie Physiologie. München: Urban und Fischer; 2016.
- [2] Y. Aloimonos (ed.), Special Issue on Purposive and Qualitive Active Vision, CVGIP B: Image Understanding, Vol. 56 (1992).
- [3] D. Marr, ``Vision: A Computational Investigation into the Human Representation and Processing of Visual Information'', Freeman, San Francisco (1982)
- [4 ] 'Predicting Cardiovascular Risk Factors from Retinal Fundus Photographs using Deep Learning'. Google Research, Google Inc, Mountain View, CA, USA. Verily Life Sciences, South San Francisco, CA, USA; Division of Cardiovascular Medicine, Stanford School of Medicine, Stanford, CA USA
- [5] Herrera, P.J.; Dorado, J.; Ribeiro, Á. A Novel Approach for Weed Type Classification Based on Shape Descriptors and a Fuzzy Decision-Making Method. Sensors 2014, 14, 15304-15324.
- [6] Computer Vision System for Quality Control in Production. Agosto de 2010. Universidad Tecnológica de Pereira. ISSN 0122-1701. Jimmy Alexander Cortés Osorio. Francisco Alejandro Medina Aguirre. M. Sc Jairo Alberto Mendoza Vargas.
- [7] Computer Vision System for Real-time Registry of Pedestrian Density. 7. Universidad Tecnológica de Pereira. ISSN 0122-1701. MAURICIO ABRIL CAÑAS. MAURICIO VALENCIAL. BONIE JOHANA RESTREPO. GERMÁN ANDRÉS HOLGUÍN

- [8] A. Broggi, P. Cerri and P.C. Antonello, "Multi-Resolution Vehicle Detection using Artificial Vision", "IEEE Intelligent vehicles 2004 Symposium, pp. 310-314, June 2004
- [9] Aguilar, W. G., & Angulo, C. (2012, March). Compensación y Aprendizaje de Efectos Generados en la Imagen durante el Desplazamiento de un Robot. In *X Simposio CEA de Ingeniería de Control* (pp. 165-170).
- [10] Ojala, T., Pietikainen, M., & Harwood, D. (1994, October). Performance evaluation of texture measures with classification based on Kullback discrimination of distributions. In *Proceedings of 12th International Conference on Pattern Recognition* (Vol. 1, pp. 582-585). IEEE.
- [11] Liu, L., Fieguth, P., Guo, Y., Wang, X., & Pietikäinen, M. (2017). Local binary features for texture classification: Taxonomy and experimental study. *Pattern Recognition*, 62, 135-160.
- [12] C. Zhu, C.E. Bichot and L. Chen, "Image region description using orthogonal combination of local binary patterns enhanced with color information," *Pattern Recognition*, vol. 46, no. 7, pp. 1949-1963, 2013
- [13] Kleinbaum, D. y Klein, M. 2002. *Logistic Regression: A Self Learning Text*. Segunda edición, Ed. Springer, New York.
- [14] Reed, L.G y Berkson, J., <<The application of the logistic function to experimental data>>, en *Journal of Physical Chemistry*, 33 (1920) 760-779
- [15] Simon Tong and Edward Chang. 2001. Support vector machine active learning for image retrieval. In *Proceedings of the ninth ACM international conference on Multimedia (MULTIMEDIA '01)*. Association for Computing Machinery, New York, NY, USA, 107–118.

- [16] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- [17] Gevers, T., van de Weijer, J., Stokman, H.: Color feature detection: An overview. In: Lukac, R., Plataniotis, K.N. (eds.) *Color Image Processing: Methods and Applications*. CRC Press, University of Toronto, Ontario, Canada (2006)
- [18] Bratkova, M., Boulos, S., Shirley, P.: oRGB: A practical opponent color space for computer graphics. *IEEE Computer Graphics and Applications* 29(1), 42–55 (2009)
- [19] P. Brodatz, "Textures: A Photographic Album for Artists and Designers", Dover Publications, New York, 1966
- [20] Burghouts, G. J., & Geusebroek, J. M. (2009). Material-specific adaptation of color invariant features. *Pattern Recognition Letters*, 30(3), 306-313.
- [21] M. Cimpoi and S. Maji and I. Kokkinos and S. Mohamed and and A. Vedaldi. Describing Textures in the Wild. *Proceedings of the {IEEE} Conf. on Computer Vision and Pattern Recognition ({CVPR})* (2014)
- [22] Murphy, K. P. *Machine Learning: A Probabilistic Perspective*. The MIT Press, Cambridge, Massachusetts, 2012.