



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería de Caminos,
Canales y Puertos

Introducción a la automatización de inspecciones de
seguridad vial relativas a sistemas de contención y
señalización. Aplicación práctica a la CV-31, PK 0,0 a 4,3
(T.M. Paterna y Godella, provincia de Valencia)

Trabajo Fin de Máster

Máster Universitario en Ingeniería de Caminos, Canales y Puertos

AUTOR/A: Abou Zahr, Aymane Ismail

Tutor/a: García García, Alfredo

CURSO ACADÉMICO: 2022/2023

Resumen

En el marco de esta investigación, se persigue la exposición detallada de una metodología sistemática destinada a la aplicación de la inteligencia artificial y el procesamiento digital de imágenes en el ámbito de la seguridad vial. De manera específica, se presenta una metodología concebida para la detección automatizada de tres problemáticas concretas que conllevan riesgos latentes en las vías de circulación, las cuales tienden a pasar inadvertidas con relativa facilidad durante las inspecciones tradicionales de seguridad vial que se llevan a cabo en la actualidad. El enfoque metodológico propuesto se fundamenta en la captura de imágenes de las carreteras a través de la herramienta *Streetview* de Google o mediante equipos vehiculares, seguido del procesamiento digital mediante las funcionalidades ofrecidas por la librería *OpenCV* en el entorno de programación *Python*. Adicionalmente, se busca adiestrar un modelo de inteligencia artificial con aptitudes de aprendizaje automático (*Machine Learning*) con la finalidad de identificar estas problemáticas.

Posteriormente, se aspira a la ejecución efectiva de esta metodología, en la medida de lo factible, con el propósito de emprender un análisis de seguridad vial que se centre en la identificación de las problemáticas previamente mencionadas en el contexto de la vía CV-31. Las áreas de interés que abarca este estudio engloban tres problemáticas de riesgo específicas: la incorrecta orientación de ciertas barreras metálicas de seguridad, la insuficiente altura de determinadas barreras metálicas, y la carencia de señalización de entrada prohibida con el fin de prevenir la salida de las glorietas mediante un acceso no apropiado.

El planteamiento integral delineado en esta investigación pretende conjugar la potencialidad de la inteligencia artificial, el procesamiento digital de imágenes y el aprendizaje automático para mejorar la efectividad en la identificación y prevención de problemáticas que afectan la seguridad vial, ofreciendo así una metodología novedosa y prometedora en la gestión y análisis de la infraestructura de tráfico.

Índice

1. Introducción.....	10
2. Objetivos y alcance.....	12
3. Fundamentos teóricos	21
3.1. Python y OpenCV.....	21
3.2. Proceso de tratamiento de las imágenes	22
3.3. Machine learning.....	32
3.3.1. Redes neuronales convolucionales (CNN).....	32
3.3.2. Patrones binarios locales (LBP)	34
3.3.3. Clasificación en cascadas de HAAR	35
4. Metodología	38
4.1. Detección de barreras metálicas mal orientadas	38
4.1.1. Recopilación de imágenes	39
4.1.2. Tratamiento de las imágenes recopiladas.....	39
4.1.3. Detección de barreras metálicas orientando hacia la carretera su cara posterior	40
4.2. Detección de barreras metálicas de altura insuficiente.....	45
4.2.1. Recopilación de imágenes	47
4.2.2. Tratamiento de las imágenes recopiladas.....	48
4.2.3. Detección del elemento de referencia.....	49
4.2.4. Establecimiento del factor de conversión	57
4.2.5. Detección de los postes de las barreras metálicas.....	58
4.2.6. Estimación de la altura de las barreras metálicas.....	62
4.3. Detección de ausencia de señal de prohibición de entrada en carriles de acceso a glorietas	63
4.3.1. Recopilación de imágenes	63
4.3.2. Tratamiento de las imágenes recopiladas.....	63
4.3.3. Detección de los carriles de entrada en las glorietas	64
4.3.4. Detección de señales de entrada prohibida	78
5. Aplicación práctica. Estudio de seguridad vial.....	85
5.1. Ámbito de estudio.....	85
5.2. Problemáticas detectadas y medidas propuestas.....	97
5.2.1. Orientación incorrecta de las barreras metálicas.....	97
5.2.2. Altura insuficiente de las barreras metálicas.....	106

5.2.3.	Ausencia de señal de entrada prohibida.....	129
5.3.	Medición de las medidas propuestas	145
5.4.	Estimación del presupuesto	147
6.	Conclusiones	151
6.1.	Limitaciones encontradas	151
6.2.	Ventajas económicas, sociales y ambientales. Objetivos de Desarrollo Sostenible 153	
7.	Referencias bibliográficas.....	155
	Anexo I. Bibliotecas de imágenes para entrenamiento de los modelos de detección.....	157
	Anexo II. Imágenes de la medición de altura de las barreras metálicas	157

Índice de figuras.

Figura 1. Sección transversal de un guardarrail.....	12
Figura 2. Barrera metálica cuya cara dorsal da a la carretera, en una divergencia de vías.	13
Figura 3. Barrera metálica cuya cara dorsal da a la carretera, en una convergencia de vías.	14
Figura 4. Vuelco de un vehículo pesado tras impactar con un guardarrail. Fuente: Periódico Hoy, 5 de octubre 2019.....	15
Figura 5. Desnivel entre la rasante de la carretera y la berma	16
Figura 6. Barrera metálica de altura insuficiente y SPM	16
Figura 7. Rotonda de 4 patas. Fuente: Wikipedia	17
Figura 8. Elementos de una glorieta.	17
Figura 9. Carril de entrada a una glorieta	18
Figura 10. Carril de salida de una rotonda	18
Figura 11. señal R-101 en el carril de entrada a la rotonda.....	19
Figura 12. ausencia de señal R-101 en carril de entrada a la rotonda.....	20
Figura 13. Vehículos de inspección de seguridad vial, equipados de cámaras. Fuente: Australian Road Research Board	20
Figura 14. Sistema de referencia que determina la posición de los píxeles.	23
Figura 15. Imagen recortada de la cara posterior de una barrera de seguridad.	24
Figura 16. Imagen recortada de la cara frontal de una barrera de seguridad.	24
Figura 17. Núcleo Gaussiano 3x3 con desviación estándar igual a uno.	25
Figura 18. Imagen desenfocada de la cara posterior de la barrera de seguridad.	26
Figura 19. Imagen desenfocada de la cara frontal de la barrera de seguridad.....	27
Figura 20. El gradiente define la dirección del cambio de intensidad.....	28
Figura 21. Límites Max y Min para determinar un borde. Fuente: Tutorial OpenCV.....	28
Figura 22. Imagen de la cara dorsal de la barrera de seguridad, tras aplicar la función Canny.	29
Figura 23. Imagen de la cara frontal de la barrera de seguridad, tras aplicar la función Canny.	30
Figura 24. Imagen de la cara dorsal de la barrera de seguridad tras la aplicación de la	31
Figura 25. Imagen de la cara frontal de la barrera de seguridad tras la aplicación de la máscara.	31
Figura 26. Esquema del algoritmo CNN. Fuente: ResearchGate.net	33
Figura 27. Esquema del proceso LBP.....	35
Figura 28. Esquema: función Haar para la detección de semejanzas en imágenes. Fuente: Viola Jones [16].....	36
Figura 29. Esquema del proceso de clasificación en cascada. Fuente: Viola Jones [16].....	37
Figura 30. Comparación de los diferentes algoritmos de detección de objetos. Fuente: Ozhiganov [18]	37
Figura 31. Imagen inicial de la cara dorsal de la barrera metálica.	40
Figura 32. Imagen tratada de la cara dorsal de la barrera metálica	40
Figura 33. Biblioteca de imágenes positivas, donde aparecen elementos característicos de las caras dorsales de las barreras metálicas.	41
Figura 34. Biblioteca de imágenes negativas, donde no aparecen elementos característicos de las caras dorsales de las barreras metálicas.	43
Figura 35. Parámetros del programa Cascade Trainer GUI.....	44
Figura 36. Hito de arista adosado a barrera metálica	46
Figura 37. Hito de arista anclado al terreno	47
Figura 38. Imagen de la barrera metálica tras haber sido recortada.....	48
Figura 39. Sección de hito de arista de tipo I. Fuente: Orden Circular 309/90. HITOS DE ARISTA,	50
Figura 40. Sección de hito de arista de tipo II. Fuente: Orden Circular 309/90. HITOS DE ARISTA,	50
Figura 41. Dimensiones de los elementos de un hito de arista	52
Figura 42. Hito de arista anclable a la barrera metálica.	53
Figura 43. Biblioteca de imágenes positivas, donde aparecen las franjas negras de los hitos de arista...	54
Figura 44. Biblioteca de imágenes negativas, donde no aparecen las franjas negras de los hitos de arista	55

<i>Figura 45. Biblioteca de imágenes positivas, donde aparecen los postes de las barreras metálicas.</i>	59
<i>Figura 46. Biblioteca de imágenes negativas, donde no aparecen los postes de las barreras metálicas.</i>	60
<i>Figura 47. Marca vial M-4.2 en el carril de incorporación a la glorieta.</i>	64
<i>Figura 48. Carril de salida de la glorieta.</i>	64
<i>Figura 49. Marca vial M-6.5 en el carril de incorporación a la glorieta</i>	65
<i>Figura 50. Curvatura característica de la salida de una glorieta.</i>	65
<i>Figura 51. Curvatura característica de la entrada a una glorieta.</i>	66
<i>Figura 52. Flujo de tráfico entrante a una glorieta</i>	66
<i>Figura 53. Flujo de tráfico saliente de una glorieta.</i>	66
<i>Figura 54. Biblioteca de imágenes positivas, donde aparecen marcas viales M-4.2</i>	68
<i>Figura 55. Biblioteca de imágenes negativas, donde no aparecen marcas viales M-4.2</i>	69
<i>Figura 56. Biblioteca de imágenes positivas, donde aparecen marcas viales M-6.5</i>	70
<i>Figura 57. Biblioteca de imágenes negativas, donde no aparecen marcas viales M-6.5</i>	71
<i>Figura 58. Curvatura característica de los bordes en una entrada a la glorieta.</i>	72
<i>Figura 59. Curvatura característica de los bordes en una entrada a la glorieta. Imagen tratada</i>	72
<i>Figura 60. Biblioteca de imágenes positivas, donde se puede percibir la curvatura característica de los bordes de calzada en las entradas a las glorietas.</i>	74
<i>Figura 61. Curvatura característica de los bordes de calzada en la salida de una glorieta.</i>	75
<i>Figura 62. Curvatura característica de los bordes de calzada en la salida de una glorieta. Imagen tratada.</i>	75
<i>Figura 63. Biblioteca de imágenes negativas, donde se puede percibir la curvatura característica de los bordes de calzada en las entradas a las glorietas.</i>	76
<i>Figura 64. Biblioteca de imágenes positivas, donde se pueden percibir vehículos en las entradas a las glorietas.</i>	77
<i>Figura 65. Biblioteca de imágenes negativas, donde no se pueden percibir vehículos de cara en las entradas a las glorietas.</i>	78
<i>Figura 66. Señal R-101 de entrada prohibida, correctamente colocada en el carril de acceso a la glorieta</i>	80
<i>Figura 67. Señal R-101 de dirección no visible desde el interior de la glorieta, al estar mal orientada</i>	81
<i>Figura 68. Señal R-101 de entrada prohibida ausente en el carril de acceso a la glorieta</i>	81
<i>Figura 69. Biblioteca de imágenes positivas, donde aparece la señal R-101</i>	82
<i>Figura 70. Biblioteca de imágenes negativas, donde no aparece la señal R-101</i>	83
<i>Figura 71. Vista en planta de la carretera estudiada</i>	86
<i>Figura 72. Limitación de velocidad de 80 km/h en el PK 0+510 en sentido ascendente.</i>	87
<i>Figura 73. Limitación de velocidad de 60 km/h en el PK 3+580 en sentido ascendente.</i>	87
<i>Figura 74. Limitación de velocidad de 60 km/h en el PK 4+120 en sentido descendente.</i>	87
<i>Figura 75. Limitación de velocidad de 80 km/h en el PK 3+520 en sentido descendente.</i>	88
<i>Figura 76. Limitaciones de velocidad en la CV-31 entre los PPKK 0+000 y 1+000</i>	88
<i>Figura 77. Limitaciones de velocidad en la CV-31 entre los PPKK 1+000 y 2+000</i>	89
<i>Figura 78. Limitaciones de velocidad en la CV-31 entre los PPKK 2+000 y 3+000</i>	90
<i>Figura 79. Limitaciones de velocidad en la CV-31 entre los PPKK 3+000 y 4+300</i>	91
<i>Figura 80. Fotografía de la sección transversal de la carretera en el PK 0+200</i>	92
<i>Figura 81. Fotografía de la sección transversal de la carretera en el PK 0+500</i>	92
<i>Figura 82. Fotografía de la sección transversal de la carretera en el PK 0+780</i>	92
<i>Figura 83. Fotografía de la sección transversal de la carretera en el PK 1+020</i>	93
<i>Figura 84. Fotografía de la sección transversal de la carretera en el PK 1+280</i>	93
<i>Figura 85. Fotografía de la sección transversal de la carretera en el PK 1+740</i>	93
<i>Figura 86. Fotografía de la sección transversal de la carretera en el PK 2+080, sentido ascendente</i>	94
<i>Figura 87. Fotografía de la sección transversal de la carretera en el PK 2+120, sentido descendente</i>	94
<i>Figura 88. Fotografía de la sección transversal de la carretera en el PK 2+450, sentido ascendente</i>	94
<i>Figura 89. Fotografía de la sección transversal de la carretera en el PK 2+450, sentido descendente</i>	95
<i>Figura 90. Fotografía de la sección transversal de la carretera en el PK 2+850, sentido ascendente</i>	95
<i>Figura 91. Fotografía de la sección transversal de la carretera en el PK 2+750, sentido descendente</i>	95

Figura 92. Fotografía de la sección transversal de la carretera en el PK 3+400.	96
Figura 93. Fotografía de la sección transversal de la carretera en el PK 3+550.	96
Figura 94. Fotografía de la sección transversal de la carretera en el PK 4+100.	97
Figura 95. Deficiencia detectada tras la evaluación de la imagen en OpenCV. PK 1+950. Recorte obtenido a partir de la imagen de salida proporcionada por OpenCV.	99
Figura 96. Elemento característico de la cara dorsal de las barreras metálicas , detectado en la imagen tratada. PK 1+950.	99
Figura 97. Ubicación de la deficiencia y solución propuesta. Vista en planta	99
Figura 98. Deficiencia detectada tras la evaluación de la imagen en OpenCV. PK 1+780. Recorte obtenido a partir de la imagen de salida proporcionada por OpenCV.	100
Figura 99. Elemento característico de la cara dorsal de las barreras metálicas , detectado en la imagen tratada. PK 1+780.	100
Figura 100. Deficiencia detectada tras la evaluación de la imagen en OpenCV. PK 1+190. Recorte obtenido a partir de la imagen de salida proporcionada por OpenCV.	102
Figura 101. Elemento característico de la cara dorsal de las barreras metálicas , detectado en la imagen tratada. PK 1+190.	103
Figura 102. Deficiencia detectada tras la evaluación de la imagen en OpenCV. PK 1+295. Recorte obtenido a partir de la imagen de salida proporcionada por OpenCV.	103
Figura 103. Elemento característico de la cara dorsal de las barreras metálicas , detectado en la imagen tratada. PK 1+295.	103
Figura 104. Ubicación de la deficiencia y solución propuesta. Vista en planta. PK 1+190 a 1+295	104
Figura 105. Deficiencia detectada tras la evaluación de la imagen en OpenCV. PK 1+345. Recorte obtenido a partir de la imagen de salida proporcionada por OpenCV.	105
Figura 106. Elemento característico de la cara dorsal de las barreras metálicas , detectado en la imagen tratada. PK 1+345.	105
Figura 107. Ubicación de la deficiencia y solución propuesta. Vista en planta. PK 1+345.	106
Figura 108. Altura de la barrera de metálica suficiente en el PK 0+550 en sentido ascendente. (80cm)	108
Figura 109. Altura de la barrera metálica insuficiente. PK 0+600 en sentido ascendente.	109
Figura 110. Altura de la barrera metálica insuficiente. PK 0+650 en sentido ascendente.	109
Figura 111. Altura de la barrera metálica insuficiente. PK 0+700 en sentido ascendente.	109
Figura 112. Altura de la barrera metálica suficiente. PK 0+750 en sentido ascendente.	110
Figura 113. Ubicación de la deficiencia y solución propuesta entre los PPKK 0+550 y 0+750. Vista en planta.	110
Figura 114. Altura de la barrera metálica suficiente. PK 0+750 en sentido ascendente.	111
Figura 115. Altura de la barrera metálica insuficiente. PK 0+775 en sentido ascendente.	111
Figura 116. Altura de la barrera metálica insuficiente. PK 0+800 en sentido ascendente.	112
Figura 117. Altura de la barrera metálica insuficiente. PK 0+850. en sentido ascendente.	112
Figura 118. Altura de la barrera metálica insuficiente. PK 0+875 en sentido ascendente.	112
Figura 119. Altura suficiente de la barrera metálica en el PK 0+900 en sentido ascendente (79cm)	113
Figura 120. Ubicación de la deficiencia y solución propuesta entre los PPKK 0+750 y 0+900. Vista en planta.	114
Figura 121. Altura suficiente de la barrera metálica en el PK 1+750 en sentido ascendente (75cm)	115
Figura 122. Altura de la barrera metálica insuficiente. PK 1+850 en sentido ascendente.	116
Figura 123. Altura de la barrera metálica insuficiente. PK 1+900 en sentido ascendente.	116
Figura 124. Altura de la barrera metálica insuficiente. PK 2+100 en sentido ascendente.	116
Figura 125. Altura de la barrera metálica insuficiente. PK 2+250 en sentido ascendente.	117
Figura 126. Altura suficiente de la barrera metálica en el PK 2+275 en sentido ascendente (76cm)	117
Figura 127. Ubicación de la deficiencia y solución propuesta entre los PPKK 1+750 2+275. Vista en planta.	118
Figura 128. Altura suficiente de la barrera metálica en el PK 3+000 en sentido ascendente (75cm)	119
Figura 129. Altura de la barrera metálica insuficiente. PK 3+050 en sentido ascendente.	120
Figura 130. Altura de la barrera metálica insuficiente. PK 3+075 en sentido ascendente.	120
Figura 131. Altura de la barrera metálica insuficiente. PK 3+100 en sentido ascendente.	120

<i>Figura 132. Altura de la barrera metálica insuficiente. PK 3+125 en sentido ascendente.</i>	<i>121</i>
<i>Figura 133. Altura de la barrera metálica insuficiente. PK 3+150 en sentido ascendente.</i>	<i>121</i>
<i>Figura 134. Altura suficiente de la barrera metálica en el PK 3+200 en sentido ascendente (75cm).....</i>	<i>122</i>
<i>Figura 135. Ubicación de la deficiencia y solución propuesta entre los PPKK 3+000 y 3+200. Vista en planta.....</i>	<i>123</i>
<i>Figura 136. Altura de la barrera metálica insuficiente. PK 3+200 en sentido descendente. (68 cm)</i>	<i>124</i>
<i>Figura 137. Altura de la barrera metálica insuficiente. PK 3+100 en sentido descendente. (67cm)</i>	<i>124</i>
<i>Figura 138. Altura de la barrera metálica insuficiente. PK 3+000 en sentido descendente. (67cm)</i>	<i>125</i>
<i>Figura 139. Ubicación de la deficiencia y solución propuesta entre los PPKK 3+250 y 3+000. Vista en planta.....</i>	<i>125</i>
<i>Figura 140. Altura de la barrera metálica insuficiente. PK 2+750 en sentido descendente. (69 cm)</i>	<i>126</i>
<i>Figura 141. Altura de la barrera metálica insuficiente. PK 2+700 en sentido descendente. (70 cm)</i>	<i>127</i>
<i>Figura 142. Altura de la barrera metálica insuficiente. PK 2+600 en sentido descendente. (68 cm)</i>	<i>127</i>
<i>Figura 143. Altura de la barrera metálica insuficiente. PK 2+500 en sentido descendente. (64 cm)</i>	<i>128</i>
<i>Figura 144. Ubicación de la deficiencia y solución propuesta entre los PPKK 2+750 y 2+500. Vista en planta.....</i>	<i>128</i>
<i>Figura 145. Ubicación de la deficiencia y solución propuesta. Vista en planta de la glorieta Este del enlace con Paterna/Benimamet.....</i>	<i>131</i>
<i>Figura 146. Ausencia de señal R-101 en el carril de entrada NNO.....</i>	<i>131</i>
<i>Figura 147. Ausencia de señal R-101 en el carril de entrada O.....</i>	<i>132</i>
<i>Figura 148. Ausencia de señal R-101 en el carril de entrada S.....</i>	<i>132</i>
<i>Figura 149. Ausencia de señal R-101 en el carril de entrada SE</i>	<i>133</i>
<i>Figura 150. Ausencia de señal R-101 en el carril de entrada NE.....</i>	<i>133</i>
<i>Figura 151. Ubicación de la deficiencia y solución propuesta. Vista en planta de la glorieta Oeste del enlace con Paterna/Benimamet.....</i>	<i>134</i>
<i>Figura 152. Ausencia de señal R-101 en el carril de entrada NNO.....</i>	<i>135</i>
<i>Figura 153. Ausencia de señal R-101 en el carril de entrada O.....</i>	<i>135</i>
<i>Figura 154. Detección de señal R-101 en el carril de entrada S.....</i>	<i>136</i>
<i>Figura 155. Ausencia de señal R-101 en el carril de entrada E</i>	<i>136</i>
<i>Figura 156. Vista en planta de la glorieta del enlace con la Feria de muestras de Valencia</i>	<i>137</i>
<i>Figura 157. Vista en planta de la rotonda del enlace con la Feria de muestras de Valencia.....</i>	<i>137</i>
<i>Figura 158. Detección de señal R-101 en el carril de entrada NO.....</i>	<i>138</i>
<i>Figura 159. Detección de señal R-101 en el carril de entrada S.....</i>	<i>138</i>
<i>Figura 160. Detección de señal R-101 en el carril de entrada NE</i>	<i>138</i>
<i>Figura 161. Ubicación de la deficiencia y solución propuesta. Vista en planta de la glorieta del enlace con la CV-3103.....</i>	<i>139</i>
<i>Figura 162. Ausencia de señal R-101 en el carril de entrada SO.....</i>	<i>140</i>
<i>Figura 163. Ausencia de señal R-101 en el carril de entrada SE</i>	<i>140</i>
<i>Figura 164. Ausencia de señal R-101 en el carril de entrada NE.....</i>	<i>141</i>
<i>Figura 165. Ausencia de señal R-101 en el carril de entrada NO</i>	<i>141</i>
<i>Figura 166. Ubicación de la deficiencia y solución propuesta. Vista en planta de la glorieta del final del tramo.</i>	<i>142</i>
<i>Figura 167. Ausencia de señal R-101 en el carril de entrada O.....</i>	<i>143</i>
<i>Figura 168. Ausencia de señal R-101 en el carril de entrada S.....</i>	<i>143</i>
<i>Figura 169. Ausencia de señal R-101 en el carril de entrada E</i>	<i>144</i>
<i>Figura 170. Ausencia de señal R-101 en el carril de entrada N.....</i>	<i>144</i>
<i>Figura 171. Ausencia de señal R-101 en el carril de entrada NO</i>	<i>144</i>
<i>Figura 172. Ejemplo de imagen con discontinuidad.....</i>	<i>152</i>
<i>Figura 173. Falsos positivos en la detección de elementos característicos de las caras dorsales de las barreras metálicas.</i>	<i>152</i>
<i>Figura 174. Objetivos de Desarrollo Sostenible. Agenda 2030.....</i>	<i>154</i>

Índice de tablas

<i>Tabla 1. Ficha: Barrera metálica mal orientada entre los PPKK 1+975 y PK 1+950.....</i>	<i>98</i>
<i>Tabla 2. Ficha: Barrera metálica mal orientada entre los PPKK 1+755 y PK 1+780.....</i>	<i>100</i>
<i>Tabla 3. Ficha: Barrera metálica mal orientada entre los PPKK 1+190 y 1+295.....</i>	<i>102</i>
<i>Tabla 4. Ficha: Barrera metálica mal orientada entre los PPKK 1+370 y 1+345.....</i>	<i>105</i>
<i>Tabla 5. Ficha: Barrera metálica de altura insuficiente, del PK 0+550 al PK 0+750.....</i>	<i>108</i>
<i>Tabla 6. Ficha: Barrera metálica de altura insuficiente, del PK 0+750 al PK 0+900.....</i>	<i>111</i>
<i>Tabla 7. Ficha: Barrera metálica de altura insuficiente, del PK 1+750 al PK 2+250.....</i>	<i>115</i>
<i>Tabla 8. Ficha: Barrera metálica de altura insuficiente, del PK 3+000 al PK 3+200.....</i>	<i>119</i>
<i>Tabla 9. Ficha: Barrera metálica de altura insuficiente, del PK 3+250 al PK 3+000.....</i>	<i>124</i>
<i>Tabla 10. Ficha: Barrera metálica de altura insuficiente, del PK 2+750 al PK 2+500.....</i>	<i>126</i>
<i>Tabla 11. Alturas de barreras metálicas. Comparativa de valores estimados y valores medidos.</i>	<i>129</i>
<i>Tabla 12. Ficha: Comprobación de presencia de señal R-101 en la glorieta Este del enlace con Paterna/Benimamet.....</i>	<i>130</i>
<i>Tabla 13. Ficha: Comprobación de presencia de señal R-101 en la glorieta Oeste del enlace con Paterna/Benimamet.....</i>	<i>134</i>
<i>Tabla 14. Ficha: Comprobación de presencia de señal R-101 en la glorieta del enlace con Feria de Muestras/Burjassot/Terramelar.....</i>	<i>137</i>
<i>Tabla 15. Ficha: Comprobación de presencia de señal R-101 en la glorieta del enlace la CV-3103.....</i>	<i>139</i>
<i>Tabla 16. Ficha: Comprobación de presencia de señal R-101 en la glorieta del final del tramo.....</i>	<i>142</i>
<i>Tabla 17. Mediciones.....</i>	<i>146</i>

1. Introducción

La seguridad vial se erige como una problemática social de considerable envergadura, al interconectar de manera intrincada factores multidisciplinarios que influyen en la prevención de accidentes de tráfico y la salvaguardia de vidas humanas. Este fenómeno, enmarcado en el ámbito de la seguridad pública, engloba un conjunto de fenómenos interrelacionados que se manifiestan en la infraestructura vial, el comportamiento de los usuarios de la vía, la legislación pertinente y la percepción de riesgo, generando así una red de implicaciones que afectan a nivel micro y macroeconómico.

Desde una perspectiva sociológica, la seguridad vial se erige como un reflejo de la dinámica social contemporánea, donde el aumento de la urbanización y la motorización desempeñan un papel central en la configuración de patrones de movilidad y convivencia ciudadana. Estos fenómenos interactúan con factores psicológicos y cognitivos, influyendo en la toma de decisiones al volante y en la adopción de comportamientos seguros. La falta de una conciencia colectiva en torno a la seguridad vial, junto con la persistencia de actitudes imprudentes, conforman elementos centrales que exacerban la problemática. Por tanto, abordar la seguridad vial desde una perspectiva integral demanda la confluencia de la sociología, la psicología, la ingeniería vial, la economía y el derecho, a fin de establecer estrategias y políticas que promuevan una cultura vial responsable y una coexistencia segura en las vías de tránsito.

En este contexto, el análisis de la seguridad vial como problema social requiere una consideración profunda de las implicaciones económicas y de salud pública asociadas. Los accidentes de tráfico imponen una carga significativa en los sistemas de atención médica, agotando recursos y afectando la calidad de vida de las víctimas y sus familias. Además, la movilidad urbana insegura impacta en la productividad económica al generar costos tangibles e intangibles, como los relacionados con la pérdida de días laborales, la depreciación de bienes materiales y la disminución de la confianza en las vías de tránsito.

En consonancia con esta complejidad, el abordaje de la seguridad vial debe ser enriquecida por un enfoque holístico y colaborativo entre gobiernos, organizaciones no gubernamentales, instituciones académicas y el sector privado. La planificación urbanística, la implementación de tecnologías vehiculares avanzadas, la educación vial, el refuerzo legislativo y la promoción de la responsabilidad individual convergen en la creación de un ecosistema vial seguro y sostenible. De esta manera, la seguridad vial trasciende su naturaleza técnica para amalgamar una serie de esferas interrelacionadas que requieren la convergencia de conocimientos especializados en pos de fomentar una movilidad segura, eficiente y respetuosa con el entorno y la vida humana.

En la búsqueda de soluciones integrales para abordar la complejidad de la seguridad vial como problema social, las inspecciones de seguridad vial emergen como una herramienta esencial. Estas evaluaciones técnicas sistemáticas permiten identificar y mitigar de manera proactiva los riesgos inherentes a la infraestructura vial y a los vehículos en circulación. Desde una perspectiva ingenieril, las inspecciones brindan la oportunidad de detectar deficiencias en la construcción y mantenimiento de las carreteras, puentes y señalización, factores que contribuyen a la ocurrencia de accidentes. Asimismo, las

evaluaciones vehiculares proporcionan una visión crítica sobre la integridad y funcionalidad de los sistemas de seguridad, alentando la adopción de medidas correctivas.

Las inspecciones de seguridad vial son procedimientos técnicos y sistemáticos que se realizan en carreteras, infraestructuras viales y vehículos con el objetivo de evaluar y mejorar su nivel de seguridad. Estas inspecciones buscan identificar posibles deficiencias, riesgos y condiciones inseguras que puedan contribuir a la ocurrencia de accidentes de tráfico. Las inspecciones se llevan a cabo mediante análisis visuales y técnicos, donde expertos en ingeniería vial y seguridad vial evalúan diversos aspectos de la infraestructura y los vehículos.

En el caso de las carreteras e infraestructuras, las inspecciones de seguridad vial abarcan aspectos como la geometría de la vía, la señalización, la iluminación, el estado del pavimento, la visibilidad en intersecciones y cruces, la presencia de barreras de seguridad y otros elementos de mitigación de riesgos. En cuanto a los vehículos, las inspecciones se centran en la verificación del funcionamiento de los sistemas de frenado, neumáticos, luces, dirección, suspensión y otros componentes esenciales para la seguridad operativa del vehículo.

El propósito fundamental de estas inspecciones es identificar y corregir posibles deficiencias antes de que se conviertan en riesgos inminentes para la seguridad vial. Esto contribuye a prevenir accidentes, reducir lesiones y salvar vidas. Las inspecciones de seguridad vial también tienen un impacto en la mejora de la infraestructura y los vehículos a lo largo del tiempo, alientan la adopción de medidas de diseño más seguras y promueven una cultura de seguridad vial en la sociedad en general.

La implementación efectiva de las inspecciones de seguridad vial también conlleva un enfoque educativo y normativo. Al promover una mayor comprensión de los riesgos asociados con la infraestructura y el equipamiento vial, se fomenta la conciencia entre los usuarios y se estimula la adopción de comportamientos responsables. Además, las regulaciones y directrices derivadas de estas inspecciones contribuyen a elevar los estándares de seguridad y a fortalecer la cooperación entre entidades gubernamentales y organismos técnicos, en la búsqueda de una gestión más efectiva de la seguridad vial.

En conclusión, las inspecciones de seguridad vial representan un componente crucial en el arsenal de medidas dirigidas a paliar la problemática de la seguridad vial. Al amalgamar los aspectos técnicos, normativos y educativos, estas evaluaciones ofrecen una estrategia integral para reducir accidentes y salvar vidas, sentando las bases para una movilidad más segura y resiliente en la sociedad contemporánea.

En el ámbito de la monitorización automatizada de carreteras, un gran objetivo a perseguir sería lograr automatizar el proceso de las inspecciones de seguridad vial. Hoy en día, la manera de proceder es que una persona, el inspector o inspectora de seguridad vial, recorra la carretera que se quiera inspeccionar fijándose en los diferentes elementos que se pretenda analizar. Siendo este el *modus operandi*, se pueden citar varias lagunas:

- 1) Realizar dos tareas al mismo tiempo (conducir y fijarse en los diferentes elementos susceptibles de revisión) no es tan evidente. La probabilidad de pasar por alto alguna anomalía es importante, y se incrementa a medida que la

- velocidad de circulación aumenta, ya que se reduce el campo de visión.
- 2) Sería necesario centrarse en inspeccionar sólo ciertos elementos por trayecto, siendo necesario realizar más de un viaje para completar la inspección y haber revisado todos los elementos de la carretera y de sus márgenes.
 - 3) Usualmente, los inspectores o inspectoras suelen moverse por los mismos trayectos, lo cual hace que se acostumbren a ellos, resultándoles más complicado fijarse en los cambios que se hayan podido producir en la carretera o sus márgenes.

Un primer paso se ha dado, equipando un vehículo de suficientes cámaras, obteniéndose así imágenes que se pueden analizar posteriormente en mejores condiciones, conduciendo a mejores resultados.

Yendo un poco más lejos, se podría incluso crear programas informáticos, o funciones dentro de algún programa ya existente, capaces de analizar las imágenes obtenidas y detectar anomalías dentro de alguno de los elementos de la carretera o de sus márgenes.

2. Objetivos y alcance

Este trabajo estará dividido en tres secciones. Las dos primeras estarán centradas en las barreras de seguridad o barreras metálicas, que son elementos de seguridad pasiva colocados a los lados de la vía para impedir que los vehículos se salgan de ella, o que choquen con otros elementos considerados más peligrosos que la propia barrera.

Dentro de los numerosos problemas que pueden existir en cuanto a la ejecución o colocación de las barreras de seguridad (deformabilidad insuficiente, altura inadecuada, falta de conservación etc.), la primera sección de este trabajo se centrará en describir la metodología a seguir para la detección de barreras de seguridad cuya cara dorsal es la orientada a la vía.




Figura 1. Sección transversal de un guardarrail.

Tal y como se observa en la figura 1, la estructura de una barrera metálica consiste en postes metálicos hincados en el terreno unidos a amortiguadores que a su vez sujetan una barrera de acero galvanizado en caliente. Estas barreras presentan una forma de dobleonda y libre de aristas angulosas, que se supone que debe estar orientada hacia la vía que se pretende proteger. Esta barrera horizontal, debido a su forma, se conoce como bionda.

Por lo tanto, el elemento más adelantado y cercano al conductor, de la cara frontal sería la bionda. La cara frontal se considerará bien adaptada para absorber y mitigar impactos de vehículos (existe controversia respecto a este tema, pues hay gente que considera que la colocación de barreras metálicas puede resultar peligroso, pero esto no se tendrá en cuenta al no ser objeto de este trabajo).

Sin embargo, la cara dorsal no es apta para recibir impactos de vehículos. Los elementos más salientes, si se mira desde la cara dorsal, son los postes, que por su configuración vertical y por su rigidez, no están adaptados para recibir impactos, pues las consecuencias serían nefastas. En las zonas entre postes, el elemento más saliente sería la cara dorsal de las biondas, cuyas afiladas aristas pueden resultar extremadamente cortantes a altas velocidades. De hecho, son numerosos los casos de lesiones, amputaciones e incluso de fallecimientos debidos al impacto contra la cara dorsal de las biondas, sobre todo entre motoristas.

Explicado de esta manera, puede resultar ilógico e inverosímil que se den casos de barreras de seguridad que orientan su cara dorsal hacia la vía, sin embargo, es más común de lo que se cree, pues pasa bastante desapercibido, incluso para un inspector de seguridad vial.

Este problema se da sobre todo en tramos donde convergen dos vías, existiendo barrera de seguridad en una de ellas (vía principal) y en la otra no (vía secundaria), de manera que los vehículos circulantes por la vía secundaria, al aproximarse a la vía principal, se encuentran con la cara dorsal de las barreras metálicas. Esta situación también se puede dar en tramos donde divergen dos vías, cuando estas permanecen próximas y sensiblemente paralelas y próximas en un tramo lo suficientemente largo. Estas situaciones se pueden observar en las figuras 2 y 3.



Figura 2. Barrera metálica cuya cara dorsal da a la carretera, en una divergencia de vías.



Figura 3. Barrera metálica cuya cara dorsal da a la carretera, en una convergencia de vías.

Como se ha indicado ya, el objetivo de esta primera sección del trabajo será la descripción de la forma de detectar estas anomalías mediante las técnicas que se describirán en los próximos apartados.

En cuanto a la segunda sección de este trabajo consistirá en identificar aquellas barreras de seguridad que presentan una altura insuficiente. Para que las barreras de seguridad proporcionen una protección adecuada, la altura de estas debe ser suficiente. Específicamente, la altura de la arista superior de la bionda debe estar a 0,75m del nivel del suelo. Con alturas inferiores a la indicada, la posibilidad de vuelco en caso de impacto se vería incrementada considerablemente. De hecho, no son raros los casos de vuelcos debidos al impacto contra barreras de seguridad de insuficiente altura, sobre todo al tratarse de vehículos altos (autobuses, furgones o remolques), cuyo centro de gravedad se ubica a una altura superior a la barrera de seguridad.



Figura 4. Vuelco de un vehículo pesado tras impactar con un guardarraíl. Fuente: Periódico Hoy, 5 de octubre 2019.

Explicado de esta manera, puede resultar ilógico que se den estos casos, ya que resulta una tarea simple colocar las biondas a una altura correcta, sin embargo, el problema no se origina en el momento de implantar las barreras, sino años más tarde, cuando se van realizando trabajos de mantenimiento en la carretera que hacen aflorar este problema de manera indirecta. Un claro ejemplo de esto podría ser el extendido de nuevas capas de firme, lo cual hace que la altura relativa a la superficie de rodadura se vea decrementada. Otro aspecto problemático de esta casuística es que no es fácil de percibir en las inspecciones visuales de seguridad vial.

Este problema se da sobre todo en algunos tramos de carreteras convencionales, donde los trabajos de mantenimiento del firme suelen ser más frecuentes (pues son carreteras más antiguas) y donde el cuidado de los márgenes es menos exhaustivo. Además, este problema es más frecuente en zonas donde los postes de las barreras metálicas están empotrados en zonas sin pavimentar, cometiéndose el error de tomar como nivel de referencia para medir la altura de la bionda el nivel del suelo en lugar de la cota del pavimento como debería ser correcto.



Figura 5. Desnivel entre la rasante de la carretera y la berma



Figura 6. Barrera metálica de altura insuficiente y SPM

Como se ha indicado ya, el objetivo del trabajo será la descripción de la forma de detectar estas anomalías mediante las técnicas que se describirán en los próximos apartados.

La tercera sección estará centrada en la señalización de las rotondas. Una rotonda, también conocida como glorieta es una construcción vial diseñada para facilitar el flujo de tráfico en las intersecciones entre carreteras y reducir el peligro de accidentes.



Figura 7. Rotonda de 4 patas. Fuente: Wikipedia

Se entiende por rotonda un tipo de intersección caracterizado por que los tramos que en él confluyen se comunican a través de un anillo en el que se establece una circulación rotatoria alrededor de una isleta central. En ellas ya no se cede la preferencia a la derecha, como se hacía previamente en las intersecciones. Ahora la preferencia recae en los vehículos que circulan por los carriles que conforman el anillo, frente a los que pretenden acceder a él por las vías de acceso.




Figura 8. Elementos de una glorieta..

El problema que se quiere abordar, concretamente, es evitar la salida de la rotonda por un carril de acceso, por motivos de señalización confusa, o por falta de señalización.

En muchos casos, los carriles de entrada y salida pueden parecer muy similares. Esto puede llevar a que los conductores se confundan y entren en el carril equivocado. Esta situación puede ser especialmente peligrosa si el conductor se encuentra en un carril de salida y, en lugar de salir de la rotonda, continúa recto.

La confusión entre los carriles de entrada y salida puede generar accidentes graves, en los que no solo se pueden ver afectados los conductores involucrados sino también los peatones y ciclistas que se encuentren en los alrededores.



Figura 9. Carril de entrada a una glorieta



Figura 10. Carril de salida de una rotonda

Por esta razón, es fundamental que existan medidas que permitan a los conductores diferenciar claramente los carriles de entrada y salida en las rotondas. Algunas de estas medidas incluyen la señalización adecuada, la colocación de dispositivos físicos que

separen los carriles y la disposición de elementos físicos que ayuden a identificar claramente los carriles.

En conclusión, la confusión entre los carriles de entrada y salida en las rotondas es una problemática que puede generar accidentes graves. Para evitar esto, es necesario que se establezcan medidas efectivas que permitan a los conductores diferenciar claramente los carriles de entrada y salida. De esta forma, se garantizará una mayor seguridad vial para todos los usuarios de las vías públicas.

Por lo tanto, el objetivo en esta sección es describir un método para la detección de manera automatizada de esta problemática. Todo ello se hará a través de imágenes grabadas desde un vehículo que recorre la rotonda, empleando algoritmos de clasificación en cascada (*Machine learning*) para generar un modelo importable a un entorno de trabajo de Python, de manera que puedan tratarse las diferentes imágenes de entrada para la determinación de la existencia o no de la problemática. Concretamente el elemento clave para diferenciar las entradas de las salidas, es la señal R-101 de entrada prohibida, la cual no siempre está presente en los carriles de entrada. En esta sección, entonces, se procurará detectar las entradas de las rotondas en un primer tiempo, y determinar la presencia o no de las señales de prohibición de paso.



Figura 11. señal R-101 en el carril de entrada a la rotonda




Figura 12. ausencia de señal R-101 en carril de entrada a la rotonda

Para la recopilación de imágenes, la idea es que, en la práctica se empleen vehículos equipados con cámaras, similares a los que se emplean para la monitorización de carreteras en países como Estados Unidos o en Australia. De esta manera se obtendrían vídeos del trayecto realizado, que se podrán tratar posteriormente. Lo ideal sería que estas imágenes fueran capturadas por cámaras laterales en el caso de las dos primeras secciones, con el objetivo de obtener fotografías frontales de las barreras de seguridad, eludiendo así el problema de perspectiva en tramos curvos. En cambio, en el caso de la tercera sección, es preferible que estas imágenes sean frontales, ya que se obtendrían imágenes semejantes a la perspectiva del conductor, al que están destinadas las señales de tráfico.



Figura 13. Vehículos de inspección de seguridad vial, equipados de cámaras. Fuente: Australian Road Research Board

En este trabajo, las imágenes empleadas para ilustrar la metodología han sido obtenidas a través de *Google Earth Pro*, pues resulta imposible tener acceso a vídeos obtenidos de la manera con la que se realizaría esto en la práctica.

Por último, una vez que se haya descrito la metodología, se aplicará esta de manera que se detecten de manera automatizada las problemáticas descritas en la carretera autonómica CV-31. Sin embargo, cabe destacar que la altura de las barreras metálicas no siempre podrá ser detectada de manera automatizada, por lo que será necesario desplazarse a la carretera para medir su altura y poder inventariar todos los tramos sobre los cuales se tendrá que actuar, para poder completar el estudio de seguridad vial. En la aplicación práctica se delimitará el ámbito de estudio, se detectarán los problemas y se propondrá una solución, junto con la estimación del presupuesto.

3. Fundamentos teóricos

Una vez obtenidas los vídeos de los trayectos realizados, es necesario separarlos en fotogramas para poder analizarlos como imágenes. Cada uno de estos fotogramas será sometido a modificaciones con el fin de obtener imágenes simplificadas. Estas técnicas son conocidas como procesamiento de imágenes y son propias del campo de la visión artificial.

La visión artificial es una disciplina científica que incluye métodos para adquirir, procesar y analizar imágenes del mundo real con el fin de producir información que pueda ser tratada por una máquina.

Mediante la visión artificial, las computadoras pueden comprender y diferenciar su entorno. Son numerosas las aplicaciones que se le pueden dar, en diferentes campos. Por ejemplo, los vehículos inteligentes son capaces de detectar los carriles de circulación adaptándose a ellos, mientras que las cámaras de nuestros móviles pueden detectar caras humanas y aplicarles diferentes filtros.

Existen numerosos programas informáticos que permiten esto, como *MVTec Halcon* o *Wenglor*. Sin embargo, se optará por usar las funciones que ofrece *OpenCV*. [1]

3.1. Python y OpenCV

OpenCV es una biblioteca libre de visión artificial originalmente desarrollada por *Intel*. *OpenCV* significa *Open Computer Vision* (Visión Artificial Abierta). Desde que apareció su primera versión alfa en el mes de enero de 1999, se ha utilizado en una gran cantidad de aplicaciones, y hasta hoy en día se sigue considerando como la biblioteca más popular de visión artificial. Su éxito se debe a varios motivos:

- 1) Se trata de un software libre lo cual permite que sea empleado tanto para fines comerciales como para propósitos de investigación.
- 2) Es un software multiplataforma, ejecutable en varios sistemas operativos y apto para diversas arquitecturas de hardware.
- 3) Al tratarse de un programa de código abierto es posible explorar las diferentes funciones existentes, e incluso implementar nuevas aplicaciones y subrutinas.

- 4) Pese a haber sido totalmente desarrollado en C++, incluye conectores para otros lenguajes, como Java, Matlab, o Python.

En cuanto al lenguaje de programación, se escogerá Python, por su simplicidad y por su extendido uso en el ámbito laboral.

OpenCV dispone de diferentes módulos dedicados a distintas áreas de la visión artificial. Cuenta con más de 2500 algoritmos relacionados con el tratamiento digital de imágenes y *machine learning* (aprendizaje de máquina) [2].

En el siguiente apartado se verán las diferentes operaciones que se aplicarán sobre las imágenes sin tratar que se han obtenido.

3.2. Proceso de tratamiento de las imágenes

En este apartado se irá describiendo el tratamiento al que se someterán cada uno de los fotogramas que se han captado en la fase de recopilación de datos. Para ilustrar el proceso se partirá de dos imágenes sin tratar, obtenidas gracias a la herramienta Streetview de Google Earth Pro. En las dos imágenes que se tratará, como ejemplo, se observará que, en una de ellas, la cara visible de la barrera de seguridad es la frontal, mientras que en la otra será lo contrario.

Antes de continuar, es necesario saber que las imágenes serán tratadas como matrices tridimensionales cuya dimensión es $(H, B, 3)$, donde H y B representan la altura y la anchura de la imagen en píxeles. La tercera dimensión representa el número de canales de color que se van a superponer, y que son 3. Estos tres canales son el rojo, el verde y el azul, y sus valores estarán comprendidos entre 0 y 255. Un valor de 0 significará que la intensidad de ese color es nula, y por lo tanto el color será negro. Un valor de 255 significará que la intensidad del color será máxima. Combinando las intensidades de cada uno de los canales de se podrá representar cualquier color. [3]

Respecto del sistema de referencia que determina la posición de los píxeles, es el que se observa en la figura 14.

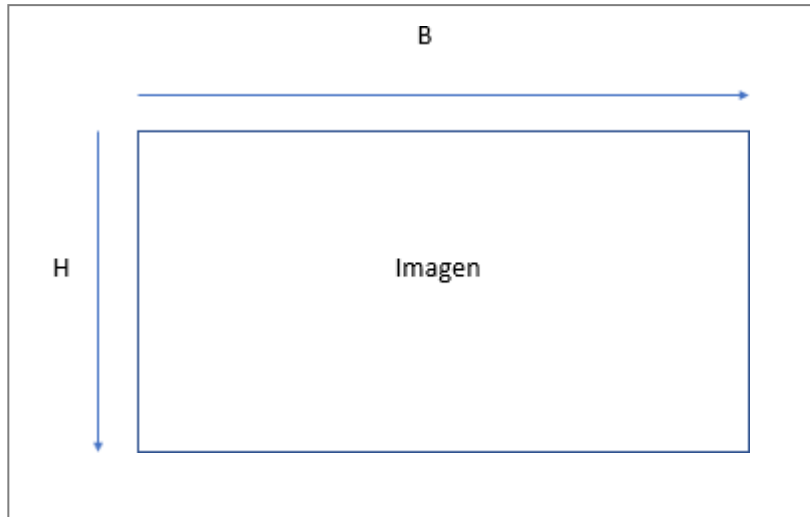


Figura 14. Sistema de referencia que determina la posición de los píxeles.

Recorte

Para garantizar que todas las imágenes tengan las mismas dimensiones, se han realizado capturas de pantalla completas y se han recortado de manera que solo quedaran visibles los píxeles comprendidos entre H=100 y el H=600 y B=250 y B=1300. A continuación, se han redimensionado las imágenes de manera que su altura sea de 480px y su anchura sea de 720px.

El código para realizar estas primeras operaciones es el que se cita a continuación:

- import cv2 #importación de la biblioteca cv2, en la que están disponibles las diversas funciones que permiten el tratamiento de las imágenes
- import numpy as np #importación de la biblioteca numpy, que permite realizar operaciones numéricas y matriciales
- imag = cv2.imread("imagenes/01.JPG") #lectura de la imagen
- img = imag[100:700, 250:1300] #recorte de la imagen
- img1 = cv2.resize(img, (720,480)) #redimensionamiento de la imagen
- cv2.imshow("image cropped", img1) #impresión de la imagen



Figura 15. Imagen recortada de la cara posterior de una barrera de seguridad.



Figura 16. Imagen recortada de la cara frontal de una barrera de seguridad.

Desenfoque

Con el objetivo de reducir el ruido en la imagen, será necesario aplicar un filtro de desenfoque sobre las imágenes. De esta manera, la información innecesaria, en cierta medida, desaparecerá de la imagen. Así pues, quedará resaltada la forma de las barreras metálicas frente a otros elementos más pequeños como la vegetación, las sombras, o la textura del asfalto. Para ello, se aplicará un filtro conocido como filtro gaussiano [4].

Un filtro gaussiano, es un filtro no uniforme de paso bajo que se utiliza para reducir el ruido (componentes de alta frecuencia) y las regiones borrosas de una imagen. El filtro se implementa como un núcleo simétrico de tamaño impar que es pasado a través de cada píxel de la imagen a tratar para obtener el efecto deseado. En el *kernel* o núcleo, es difícil que cambie drásticamente de color en los bordes, puesto que los píxeles

centrales del kernel tienen más peso que los píxeles periféricos. Un filtro gaussiano podría considerarse como una aproximación de la función gaussiana.

El proceso de usar el filtro gaussiano en una imagen consistirá en:

- 1) Definir el tamaño de la matriz Kernel que se usaría para reducir el ruido de la imagen. Las dimensiones de esta matriz suelen ser impares, de manera que los resultados generales se puedan calcular en el píxel central. Además, los núcleos son simétricos y, por lo tanto, tienen el mismo número de filas y columnas.
- 2) Calcular los valores (pesos) de los diferentes píxeles del kernel. Estos valores son calculados por la función gaussiana, que es la siguiente:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

Donde:

- X = valor de la coordenada x
- Y = valor de la coordenada y
- σ = Desviación estándar

Usando la función anterior, se puede calcular un kernel gaussiano de cualquier tamaño. Una aproximación del núcleo gaussiano de dimensiones 3×3 con desviación estándar = 1, resultaría en:

$\frac{1}{16}$	1	2	1
$\frac{1}{16}$	2	4	2
$\frac{1}{16}$	1	2	1

Figura 17. Núcleo Gaussiano 3x3 con desviación estándar igual a uno.

Afortunadamente, en la librería cv2 de OpenCV, existe una función que permite esta operación.

El código que se emplea para su llamada es el siguiente:

- `import cv2` #importación de la biblioteca cv2, en la que están disponibles las diversas funciones que permiten el tratamiento de las imágenes
- `import numpy as np` #importación de la biblioteca numpy, que permite realizar operaciones numéricas y matriciales
- `imgBlur = cv2.GaussianBlur(img1, (11,11),2)` # esta función aplica sobre la imagen recortada y redimensionada un filtro gaussiano cuyo núcleo es de dimensiones 11x11 y cuya desviación estándar es 2.

- `cv2.imshow("blur image", imgBlur) #salida por pantalla de la imagen tratada`

Los resultados obtenidos para las dos imágenes que se van a tratar a modo de ejemplo serían los observados en las figuras 18 y 19.



Figura 18. Imagen desenfocada de la cara posterior de la barrera de seguridad.



Figura 19. Imagen desenfocada de la cara frontal de la barrera de seguridad.

Detección de bordes

Para simplificar la imagen es posible transformarla de manera que sólo se perciban los contornos de los diferentes objetos presentes en ella. Habiéndose eliminado el ruido se pueden obtener imágenes limpias donde se pueden distinguir fácilmente los elementos que nos interesan (las barreras de seguridad o barreras metálicas). Las imágenes así procesadas presentarán un único canal de color, y que además será de carácter binario (o blanco o negro). El fondo de la imagen será negro, mientras que los contornos serán blancos. De esta manera, en procesos posteriores, el costo computacional resultaría mucho más reducido.

En OpenCV existe una función que permite esta operación, que lleva el nombre de su desarrollador John F. Canny [5].

Internamente, la función realiza las siguientes etapas:

- 1) Determinación del gradiente de intensidad de la imagen: Encuentra el gradiente. El gradiente define dos valores: la dirección en donde el cambio de intensidad es máximo y la magnitud de esa dirección.




Figura 20. El gradiente define la dirección del cambio de intensidad.

- 2) Supresión de los valores no extremos: Después de obtener la magnitud y la dirección del degradado, se realiza un escaneo completo de la imagen para eliminar los píxeles no deseados que pueden no constituir el borde. Esto elimina los píxeles que no se consideran parte de un borde. Por lo tanto, solo quedarán líneas finas (bordes candidatos).
- 3) Umbral de histéresis: En esta etapa se decide cuáles son los contornos que se considerarán realmente bordes y cuáles no. Para esto, necesitamos dos valores de umbral, minVal y maxVal .




Figura 21. Límites Max y Min para determinar un borde. Fuente: Tutorial OpenCV

Los contornos con un gradiente de intensidad superior a maxVal serán considerados bordes, mientras que aquellos cuyo valor esté por debajo de minVal no lo serán con seguridad, por lo que se descartarán. Aquellos que se encuentran entre estos dos umbrales se clasificarán (como bordes o no bordes) en función de su conectividad. Si están conectados a píxeles de “borde seguro”, se les otorgará la condición de bordes y pasarán a ser representados. De lo contrario, también se descartarían [6].

El código que se empleará para su llamada es el que se describe a continuación:

- `import cv2` #importación de la biblioteca `cv2`, en la que están disponibles las diversas funciones que permiten el tratamiento de las imágenes
- `import numpy as np` #importación de la biblioteca `numpy`, que permite realizar operaciones numéricas y matriciales
- `imgCanny = cv2.Canny(imgBlur,90,100)` esta función aplica sobre la imagen recortada y redimensionada tras la aplicación del filtro gaussiano. Los valores del umbral mínimo y máximo serán de 90 y 100 respectivamente.
- `cv2.imshow("canny",imgCanny)` #salida por pantalla de la imagen tratada

Los resultados obtenidos para las dos imágenes que se van a tratar a modo de ejemplo serían los observados en las figuras 22 y 23.




Figura 22. Imagen de la cara dorsal de la barrera de seguridad, tras aplicar la función Canny.



Figura 23. Imagen de la cara frontal de la barrera de seguridad, tras aplicar la función Canny.

Región de interés.

A pesar de los cambios introducidos, las imágenes siguen presentando contornos de objetos que no van a ser relevantes en nuestro análisis, por lo que se aplicará una máscara negra que solo deje visible la región de la imagen en la que están las barreras metálicas. Esta región es conocida como región de interés, en inglés *region of interest* (ROI) [7].

A continuación, se muestra el código empleado para lograr esta operación:

- def función_canny (imagen_redimensionada): # se define una función en la que se agrupan todas las funciones anteriormente citadas. En esta función, la variable de entrada es la imagen redimensionada
- imgBlur = cv2.GaussianBlur(imagen_redimensionada, (11, 11), 2)
- imgCanny = cv2.Canny(imgBlur, 90, 100)
- return imgCanny # la variable de salida de esta función será la imagen Canny
-
- def region_of_interest(imagen_redimensionada): # se define una función cuya finalidad es la obtención de una imagen sobre la cual se ha aplicado una máscara
- polygons= np.array ([[0,170),(720,170),(720,310),(0,310]]) # se define el contorno de la máscara. Se trata de un rectángulo.
- mask = np.zeros_like(imagen_redimensionada) # la región exterior del rectángulo será rellenada de píxeles negros.
- cv2.fillPoly(mask, polygons, 255) # la región interior del rectángulo será rellenada de píxeles blancos.
-
- masked_image = cv2.bitwise_and(imagen_redimensionada, mask) # se superponen dos imágenes de las mismas dimensiones. Dentro de la región de

interés, se comparan los píxeles homólogos. Si ambos son blancos, el color de salida será blanco. En cambio, si el píxel de la primera imagen es negro, el color de salida será negro.

- `return masked_image`
- `Imagen_redimensionada = cv2.resize(img, (720,480))` # imagen inicial, recortada y redimensionada
- `Copia_imagen_redimensionada = np.copy(imagen_redimensionada)` # se crea una copia de la imagen inicial recortada y redimensionada, pues es necesaria para ser el argumento de dos funciones diferentes
- `imagentratada = función_canny(copia_imagen_redimensionada)` # se ejecuta la función canny. La imagen resultante se llamará "imagentratada"
- `resultado_final = region_of_interest(imagentratada)` # se ejecuta la función. El argumento de la función será la imagen de salida de la función anterior. El resultado será la imagen sobre la cual se ha aplicado el filtro Canny, pero sólo será visible la región de interés.
- `cv2.imshow("Imagen tratada final",resultado_final)` # salida por pantalla de la imagen resultante

En las figuras 24 y 25 se pueden observar los resultados obtenidos para las dos imágenes que se van a tratar a modo de ejemplo.




Figura 25. Imagen de la cara frontal de la barrera de seguridad tras la aplicación de la máscara.

Tal y como se puede ver, las imágenes resultantes quedan muy simplificadas y limpias, quedando claramente visible la barrera de seguridad. A simple vista es posible distinguir entre la cara frontal y la cara dorsal de las barreras metálicas. La cara frontal (figura 25)

queda representada por dos líneas horizontales continuas, mientras que la cara dorsal (figura 24) queda representada por cuatro líneas horizontales, debido a la forma angulosa de la cara posterior de las biondas.

En resumen, estas técnicas de tratamiento digital de imágenes son las que se van a emplear en el trabajo. Esta sucesión de tratamientos no siempre va a ser la del ejemplo, y dependerá de la sección en la que se esté trabajando. Así pues, en la segunda sección no será necesario emplear el filtro Canny, o en la tercera sección la región de interés no será la misma que la del ejemplo.

3.3. Machine learning

El Aprendizaje de máquina o *machine learning* es una rama dentro del campo de la inteligencia artificial que proporciona a los sistemas la capacidad de aprender y mejorar de manera automática, a partir de la experiencia. Estos sistemas transforman los datos en información y con esta pueden tomar decisiones. Para que un modelo realice predicciones de manera robusta necesita alimentarse de datos, y cuantos más, mejores resultados [8]. Afortunadamente, hoy en día la red está repleta de fuentes de datos. En muchas ocasiones, los datos son recolectados por empresas privadas para su propio beneficio, pero también existen otras iniciativas, como, por ejemplo, portales de datos abiertos. Sin embargo, dado al carácter innovador de este trabajo, no existen bases de datos aplicables a este ámbito.

Dentro de las diferentes variantes, nos centraremos en la descripción del aprendizaje de máquina supervisado. El aprendizaje supervisado necesita conjuntos de datos etiquetados, es decir, le decimos al modelo qué es lo que queremos que aprenda. En nuestro caso, las etiquetas indicarán si las barreras metálicas están colocadas correctamente o no.

Dependiendo del tipo de etiqueta, dentro del aprendizaje supervisado existen dos tipos de modelos:

- 1) Los modelos de clasificación, que producen como salida una etiqueta discreta, es decir, una etiqueta dentro de un conjunto finito de etiquetas posibles. A su vez, los modelos de clasificación pueden ser binarios si tenemos que predecir entre dos clases, o multiclase cuando se tiene que clasificar más de dos clases.
- 2) Los modelos de regresión producen como salida un valor real.

En nuestro caso, se necesitaría implementar un modelo de clasificación, que catalogue las diferentes imágenes en dos clases. A continuación, se presentan tres posibles alternativas para la clasificación de imágenes.

3.3.1. Redes neuronales convolucionales (CNN)

El *Deep Learning* es un método de *Machine Learning* y viene de la idea de imitar el funcionamiento de las neuronas en los humanos. Éstas trabajan conjuntamente, pero sin una tarea concreta, y la experiencia va reforzando ciertas conexiones y hace posible el

aprendizaje [9].

Lo revolucionario del sistema es que permite identificar patrones de manera rápida y eficaz a partir de un gran conjunto de datos e imágenes. Se enseña un resultado a la máquina y ella aprende los pasos que hacen posible la consecución del objetivo.

Los algoritmos de aprendizaje profundo o de *deep learning* son aquellos que ejecutan datos a través de múltiples capas de redes neuronales. Estas pasan a la capa siguiente una representación simplificada de los datos analizados. Estos algoritmos aprenden progresivamente sobre el objeto o imagen que estudian.

Las redes neuronales convolucionales es un algoritmo de *Deep Learning* que está diseñado para trabajar con imágenes, tomando estas como input, asignándole importancias (pesos) a ciertos elementos en la imagen para así poder diferenciar unos de otros. Este es uno de los principales algoritmos que ha contribuido en el desarrollo y perfeccionamiento del campo de Visión por computadora [10].

Las redes convolucionales contienen varias capas ocultas (*hidden layers*), donde las primeras puedan detectar líneas, curvas y así se van especializando hasta poder reconocer formas complejas.

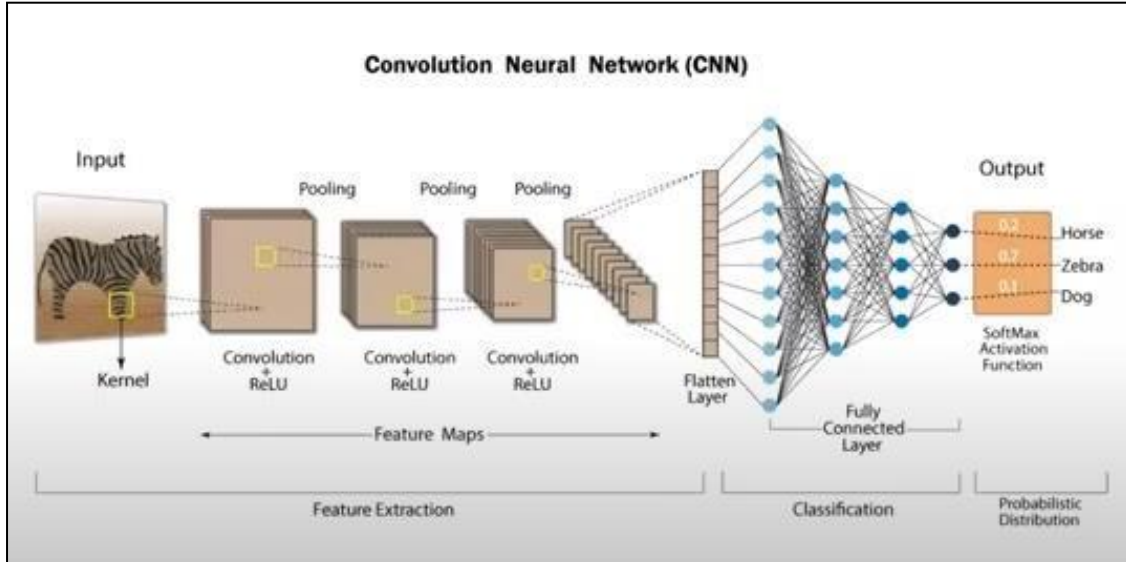


Figura 26. Esquema del algoritmo CNN. Fuente: ResearchGate.net

Para la detección de objetos, es necesario hacer pasar nuestras imágenes de entrada por diferentes filtros o convoluciones, cada vez más restrictivos, con fin de que la computadora vaya reconociendo patrones, comparándolos con los de las imágenes etiquetadas que formarían parte de nuestra biblioteca de comparación. Este proceso o algoritmo es conocido como red neuronal convolucional, en inglés *Convolution Neural Network* (CNN). [11]

3.3.2. Patrones binarios locales (LBP)

Los patrones binarios locales (LBP) son un tipo de descriptor visual utilizado para la clasificación en la visión por computadora. LBP es el caso particular del modelo de Espectro de Textura propuesto en los años 90 del pasado siglo. Los LBP fueron descritos por primera vez en 1994. [12]

Desde entonces, se ha demostrado que es una característica potente para la clasificación de texturas; además, se ha determinado que cuando LBP se combina con el descriptor de Histograma de gradientes orientados (HOG), mejora considerablemente el rendimiento de detección en algunos conjuntos de datos. En 2015, Silva et al. realizaron una comparación de varias mejoras del LBP original en el campo de la sustracción de fondos. [13]

Se puede encontrar un estudio completo de las diferentes versiones de LBP en Bouwmans et al. [14]

El vector de características LBP, en su forma más simple, se crea de la siguiente manera:

- Divide la ventana examinada en celdas (por ejemplo, 16x16 píxeles para cada celda).
- Para cada píxel en una celda, compara el píxel con cada uno de sus 8 vecinos (en la parte superior izquierda, en el medio izquierdo, en la parte inferior izquierda, en la parte superior derecha, etc.). Sigue los píxeles a lo largo de un círculo, ya sea en sentido horario o en sentido contrario a las agujas del reloj.
- Donde el valor del píxel central sea mayor que el valor del vecino, escribe "0". De lo contrario, escribe "1". Esto da como resultado un número binario de 8 dígitos (que generalmente se convierte a decimal para mayor conveniencia).
- Calcula el histograma, sobre la celda, de la frecuencia de cada "número" que ocurre (es decir, cada combinación de qué píxeles son más pequeños y cuáles son mayores que el centro). Este histograma se puede ver como un vector de características de 256 dimensiones.
- Opcionalmente, normaliza el histograma.
- Concatena los histogramas (normalizados) de todas las celdas. Esto da como resultado un vector de características para toda la ventana.

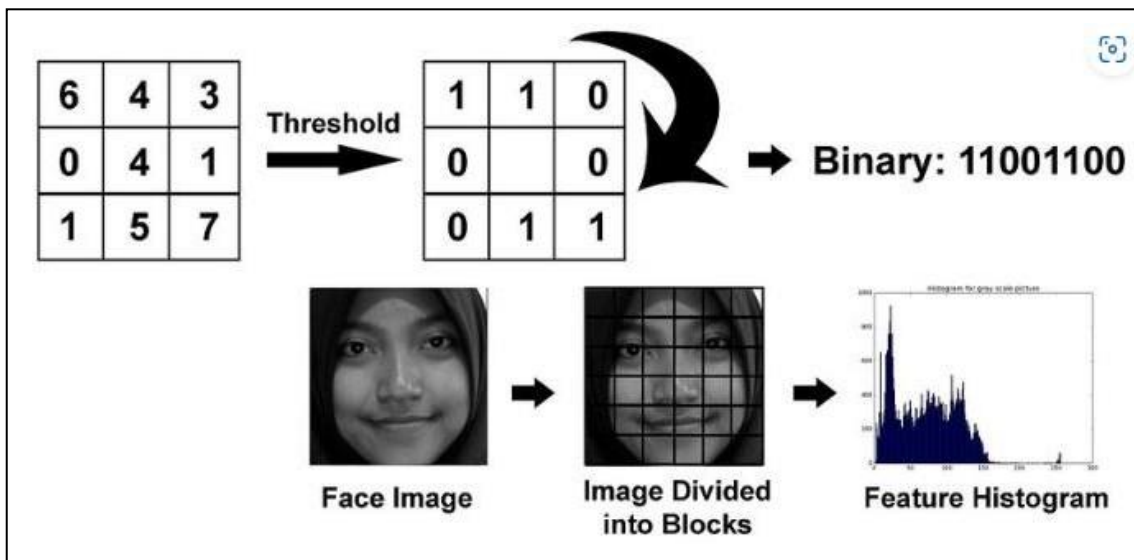


Figura 27. Esquema del proceso LBP

El vector de características ahora se puede procesar utilizando una máquina de vectores de soporte, máquinas de aprendizaje extremo u otro algoritmo de aprendizaje automático para clasificar imágenes. Tales clasificadores se pueden utilizar para reconocimiento facial o análisis de texturas.

3.3.3. Clasificación en cascadas de HAAR

Existen diferentes estrategias de aprendizaje automático para identificar objetos en una imagen o en un marco de video. Entre ellas, se ha destacado la aplicación de técnicas inductivas para la construcción de árboles de clasificación. [15]

En este trabajo, se ha optado por implementar el método de clasificación Haar Cascades, también conocido como técnica de clasificación de cascada, diseñado por Viola y Jones. [16]

Dicha técnica consiste en la concatenación de varios clasificadores débiles, los cuales analizan porciones específicas de la imagen o del marco de video. A pesar de ser considerados débiles debido a su alta tasa de falsos positivos, el resultado global de la combinación de los clasificadores se convierte en una herramienta muy poderosa.

La metodología utiliza un objeto de clasificación, el cual organiza la imagen en función del valor de sus características (features). Estas características se corresponden con bloques o rectángulos de píxeles encontrados dentro de una ventana de detección cerrada. En este sentido, se ha manifestado a favor de utilizar características en lugar de píxeles directamente relacionados con la intensidad de la imagen. Como resultado, el algoritmo utiliza una variedad de ventanas de igual tamaño, las cuales contienen 2, 3 y 4 rectángulos también de igual dimensión. En cada una de estas ventanas, se aplica la función Haar, la cual se calcula como la suma de los píxeles blancos dentro de los rectángulos y se resta con la suma de los píxeles grises del área sombreada. (Ver Figura 28).




Figura 28. Esquema: función Haar para la detección de semejanzas en imágenes. Fuente: Viola Jones [16]

Esto permite encontrar las características del objeto de análisis comparando el resultado en cada una de las imágenes positivas con las imágenes negativas y encontrar similitudes en todas las imágenes positivas.

Durante la fase de entrenamiento, es crucial disponer de un conjunto de datos que contenga imágenes positivas que incluyan el objeto de interés, así como un conjunto de datos que contenga imágenes negativas de aquello que no se busca. A continuación, se debe seguir de manera rigurosa los procedimientos descritos en la referencia, haciendo hincapié en la selección de características pertinentes.

La propuesta contempla la utilización de Adaboost como solución óptima dada la alta capacidad de cómputo requerida. Este algoritmo de clasificación estadística, ideado por Yoav Freund y Robert Schapire en 1995, tiene como objetivo principal señalar aquellas áreas de la imagen que poseen relevancia para el objeto en cuestión. [17]

La simultánea utilización de todas las funcionalidades principales durante el reconocimiento de un sujeto dentro de una imagen o fotograma resultaría poco eficiente en cuanto a la gestión temporal y financiera. Por lo tanto, se introduce el concepto de clasificación de cascada, en el cual las funcionalidades se separan en etapas, al igual que una cascada de agua en la cual la caída es gradual. Cada una de ellas contiene un grupo de funcionalidades adecuado para tomar una decisión relevante. En consecuencia, se recibe como entrada una región parcial de la imagen con una alta probabilidad de contener el objetivo, esto se debe a la característica recursiva de la imagen integral que permite una rápida evaluación de las funcionalidades para localizar el objeto.

En el supuesto evento de un fallo en una etapa de subregión de la imagen, se adopta la decisión de rechazar la ventana. Sin embargo, si la etapa es aprobada, se procede a la siguiente en cola de prioridad. Es importante destacar que las etapas de mayor jerarquía contienen las características más relevantes del objeto en cuestión.

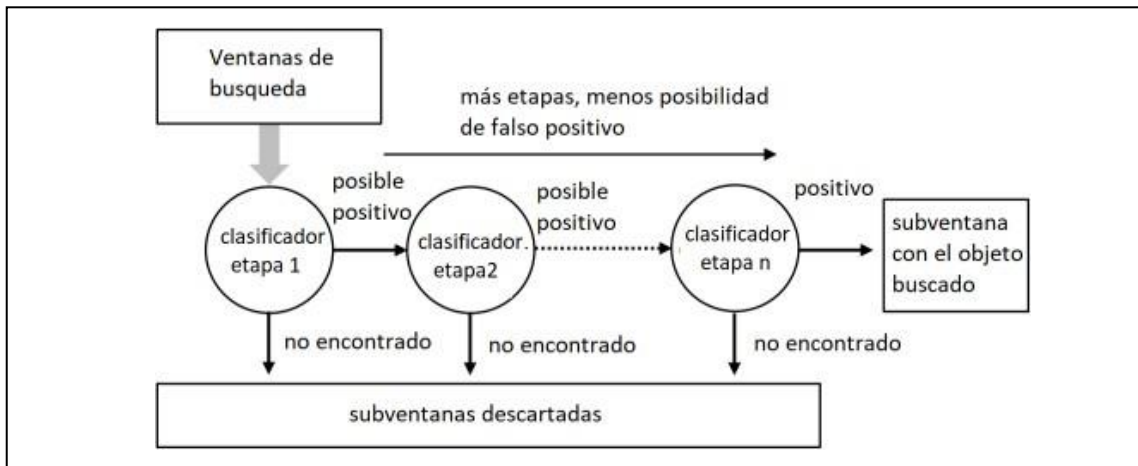


Figura 29. Esquema del proceso de clasificación en cascada. Fuente: Viola Jones [16]

Teniendo en cuenta la existencia de estas tres técnicas de clasificación, se puede proceder a su comparación.

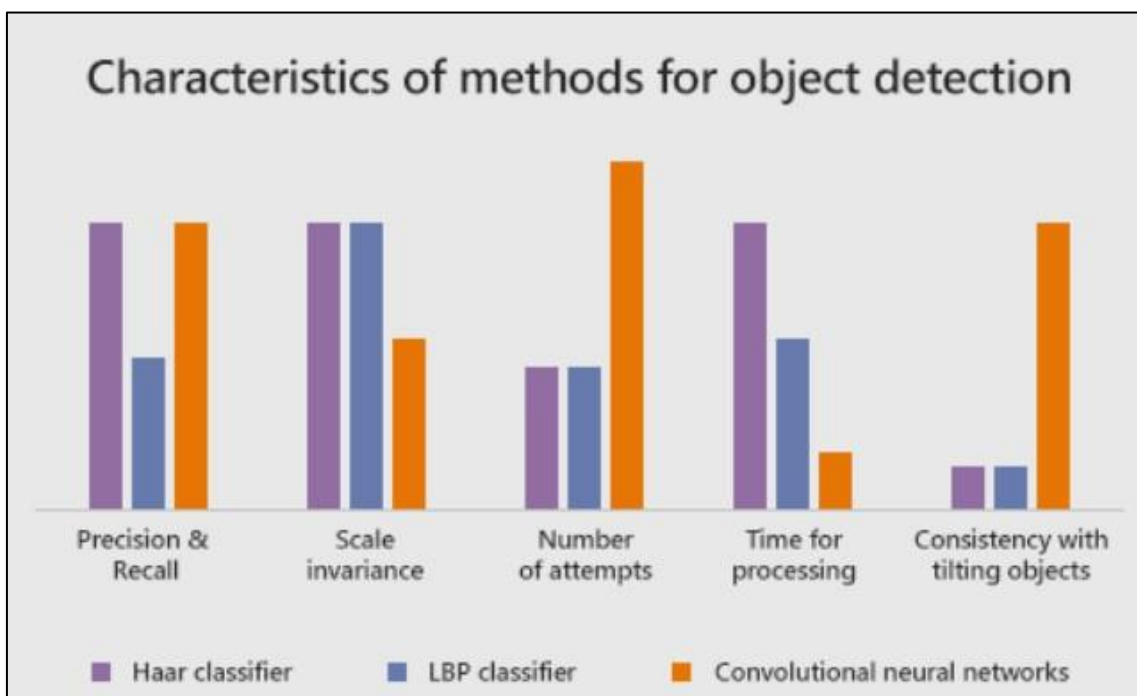


Figura 30. Comparación de los diferentes algoritmos de detección de objetos. Fuente: Ozhiganov [18]

Según Ozhiganov, estas son las diferencias entre diferentes métodos en cuanto a los siguientes parámetros: [18]

- Precisión y recuperación: Tanto el CNN como el clasificador Haar tienen un nivel relativamente alto de precisión y recuperación al detectar objetos en imágenes. Al mismo tiempo, el clasificador LBP tiene una alta tasa de falsos positivos y baja precisión.

- Invariancia de escala: Los clasificadores en cascada Haar y LBP gestionan fácilmente la escala de los objetos debido a su fuerte invariancia. Sin embargo, el CNN no puede manejar bien los objetos a escala debido a su baja invariancia de escala.
- Número de intentos requeridos para obtener un modelo funcional: Los clasificadores en cascada solo requieren unos pocos intentos para obtener un modelo funcional para la detección de objetos. El CNN no es tan rápido y requiere docenas de experimentos.
- Tiempo de procesamiento: Una red neuronal convolucional no requiere mucho tiempo de procesamiento. Lo mismo ocurre con el clasificador LBP. En cambio, el clasificador Haar requiere mucho más tiempo para ser procesado.

Por lo tanto, y en base a esto, los dos métodos más adecuados para el tipo de tareas que se pretenden llevar a cabo son el modelo en cascada de Haar y las redes convolucionales neuronales. Sin embargo, se seleccionará el modelo de Haar, por ser más sencillo, y por la existencia de programas informáticos basados en él como *CascadeTrainer GUI*, que es un programa que ofrece una interfaz gráfica, la cual facilita el uso de herramientas de OpenCV para el entrenamiento y prueba de clasificadores. Este programa ofrece entrenar, probar y mejorar modelos de clasificadores en cascada.

4. Metodología

A continuación, se describe la metodología que se deberá seguir para la detección de las problemáticas abordadas en cada una de las secciones.

4.1. Detección de barreras metálicas mal orientadas

La metodología propuesta consistiría en recopilar imágenes, tratarlas mediante visión artificial con el objetivo de obtener imágenes más simplificadas de manera que puedan aplicarse las técnicas de *machine learning*. Estas técnicas permitirían detectar semejanzas entre las imágenes recopiladas y las imágenes de comparación. Estas últimas imágenes serán imágenes tratadas de la misma manera que las recopiladas, en las que se sabe de antemano que se da el problema que se pretende identificar. De esta manera se podrían detectar aquellas imágenes en las que se puede percibir la cara dorsal de las barreras de seguridad.

De manera resumida, el procedimiento consistirá en:

- 1) Recopilación de imágenes.
- 2) Tratamiento previo de las imágenes recopiladas
- 3) Detección de barreras metálicas que orientan hacia la carretera su cara posterior

A continuación, se describirá con más detenimiento cada una de las fases, explicando las técnicas, algoritmos y lenguajes de programación que se podrían usar para solucionar este problema.

4.1.1. Recopilación de imágenes

Para la recopilación de imágenes, la idea es que, en la práctica se empleen vehículos equipados con cámaras. De esta manera se obtendrían vídeos del trayecto realizado, que se podrán tratar posteriormente. Lo ideal sería que estas imágenes fueran capturadas por cámaras laterales, con el objetivo de obtener fotografías frontales de las barreras de seguridad, eludiendo así el problema de perspectiva en tramos curvos.

Para obtener imágenes homogéneas, se recomendaría viajar siempre en el mismo carril, y que se adaptara la captación de fotogramas a la velocidad, con el objetivo de obtener una distribución espacial homogénea de imágenes (una imagen cada X metros recorridos)

En este trabajo, las imágenes empleadas para ilustrar la metodología han sido obtenidas a través de *Google Earth Pro*, pues resulta imposible tener acceso a vídeos obtenidos de la manera con la que se realizaría esto en la práctica, al no ser accesibles los vehículos descritos en el párrafo anterior.

4.1.2. Tratamiento de las imágenes recopiladas

Una vez obtenidas los vídeos de los trayectos realizados, es necesario separarlos en fotogramas para poder analizarlos como imágenes.

Al tratarse de elementos lineales, es preferible realizar todas las transformaciones descritas en el apartado 3.2, con el objetivo de obtener imágenes simples y limpias.



Figura 31. Imagen inicial de la cara dorsal de la barrera metálica.




Figura 32. Imagen tratada de la cara dorsal de la barrera metálica

4.1.3. Detección de barreras metálicas orientando hacia la carretera su cara posterior

Para poder detectar objetos, el primer paso consiste en entrenar un modelo para que sea capaz de dar resultados correctos, clasificando de manera correcta las imágenes entrantes.

Para ello se empleará el programa *Cascade Trainer GUI*.

El primer paso consistirá en almacenar un número suficiente de imágenes positivas en una carpeta. Por imágenes positivas se entenderá, en este apartado, imágenes donde sea posible visualizar barreras de seguridad cuya cara dorsal sea la más próxima a la vía, sometidas a los mismos tratamientos que las imágenes dato.

Según las indicaciones del programa, para un correcto entrenamiento son necesarias miles de imágenes positivas, aunque es posible conseguir los mismos objetivos con un tamaño de muestra mucho menor si se tratan de figuras simples.

Un factor habilitante del uso de un conjunto de datos o *data set* de pequeño tamaño en el contexto de imágenes se atribuye a la variabilidad de las condiciones de captura. Específicamente, cuando las imágenes se adquieren bajo diversas condiciones de iluminación o desde diferentes ángulos, se requiere una cantidad menor de imágenes en el conjunto para lograr resultados precisos, disminuyendo así la probabilidad de falsos positivos o errores en la detección.

Además, con el propósito de mitigar la carga computacional, se sugiere emplear imágenes de dimensiones reducidas. Para tal fin, resulta necesario redimensionar las imágenes antes de su almacenamiento en el directorio de positivos. Con el objetivo de preservar las proporciones, únicamente se modificará la altura de dichas imágenes, manteniendo constante la relación de aspecto entre la altura y el ancho.

La figura 33, representa esquemáticamente lo recién descrito, pues son pequeñas imágenes donde se puede apreciar claramente el objeto que se desea detectar. Las bibliotecas de imágenes para el entrenamiento se pueden consultar en el Anexo I.




Figura 33. Biblioteca de imágenes positivas, donde aparecen elementos característicos de las caras dorsales de las barreras metálicas.

Por otra parte, será necesario almacenar un número suficiente de imágenes negativas en una carpeta. Por imágenes negativas se entenderá, en este apartado, imágenes donde no sea posible sea posible visualizar barreras de seguridad colocadas incorrectamente, sometidas al mismo tratamiento que las imágenes de entrada. Según las indicaciones del programa, para un correcto entrenamiento son necesarias miles de imágenes negativas, aunque es posible conseguir los mismos objetivos con un tamaño de muestra mucho menor si el objeto a detectar se tratara de una figura simple.

Para entrenar correctamente el modelo son imprescindibles dos aspectos:

- 1) Que bajo ningún concepto aparezcan imágenes positivas en la carpeta de imágenes negativas, ni que aparezca el objeto que se pretende detectar en ninguna de ellas, aunque sea sólo parcialmente. Esto afectaría de manera sumamente importante la eficacia del modelo.
- 2) Aunque en teoría, las imágenes negativas puedan ser cualquier imagen donde no aparezca el objeto que se pretende detectar, se recomienda que estén relacionadas. Si lo que se pretende detectar barreras de seguridad cuya cara dorsal sea la más próxima a la vía, será mucho mejor emplear imágenes donde sea posible visualizar barreras de seguridad colocadas correctamente antes que de imágenes sin relación con lo que se pretende detectar, como imágenes de perros o aviones. El objetivo es que el modelo aprenda a no darle relevancia a las formas o elementos presentes en las dos categorías de imágenes de manera que se pueda diferenciar las dos categorías de imágenes con una mayor eficacia.

Al igual que para el caso de las imágenes positivas, resulta más práctico emplear un mayor número de imágenes pequeñas que un número más reducido de imágenes. Paralelo, se reducirá el tamaño de estas imágenes modificándolas, de manera que se iguale su altura, pero sin que se produzcan distorsiones.

La figura 34, representa esquemáticamente lo recién descrito, pues son pequeñas imágenes donde se puede apreciar el entorno en el cual podrían aparecer las caras dorsales de las barreras, pero sin que aparezcan éstas. Las bibliotecas de imágenes para el entrenamiento se pueden consultar en el Anexo I.




Figura 34. Biblioteca de imágenes negativas, donde no aparecen elementos característicos de las caras dorsales de las barreras metálicas.

Según Viola & Jones, se recomienda que el número de imágenes positivas represente alrededor de un 25% del total de imágenes que se vayan a emplear para el entrenamiento, es decir que son necesarias el triple de imágenes negativas que de positivas.

Al trabajar con esta herramienta debemos ajustar algunos parámetros y valores. Esto permite generar distintos modelos y comparar posteriormente sus resultados. A continuación, se detallan los parámetros más relevantes en la configuración de un entrenamiento del modelo de clasificación:

- El número de repeticiones o ciclos: cantidad de veces que se repite el proceso de aprendizaje del modelo. Es indispensable hallar el número ideal de repeticiones para prevenir el sobreajuste (recordar la información). En términos generales, el número de repeticiones recomendado para entrenar el modelo sobre objetos básicos es de 15 a 20 para una salida confiable
- Tamaño de buffer para valores e índices de memoria: Este parámetro permite indicar la cantidad de Megabytes que se utilizarán como buffer durante el entrenamiento. Esto dependerá principalmente del hardware disponible. para todos los entrenamientos efectuados se configuró con el valor de 4096 Mb.
- Ancho y alto de las imágenes: La herramienta sólo soporta que los datos del set de entrenamiento contengan la misma dimensión, y en caso de no ser así solo interpreta la porción de la imagen que se corresponde con los parámetros configurados (en pixeles).

Para las ejecuciones de entrenamientos, en base a los sets de datos disponibles, se configuraron estos parámetros con los valores: 24px de ancho y 24px de alto.

- Tipo de algoritmo utilizado: en este caso la opción elegida es Haar, el algoritmo de clasificación de modelos de cascada detallado anteriormente, aunque este programa permita el uso de otros algoritmos, como podrían ser el algoritmo LBP, más rápido, pero menos eficiente.

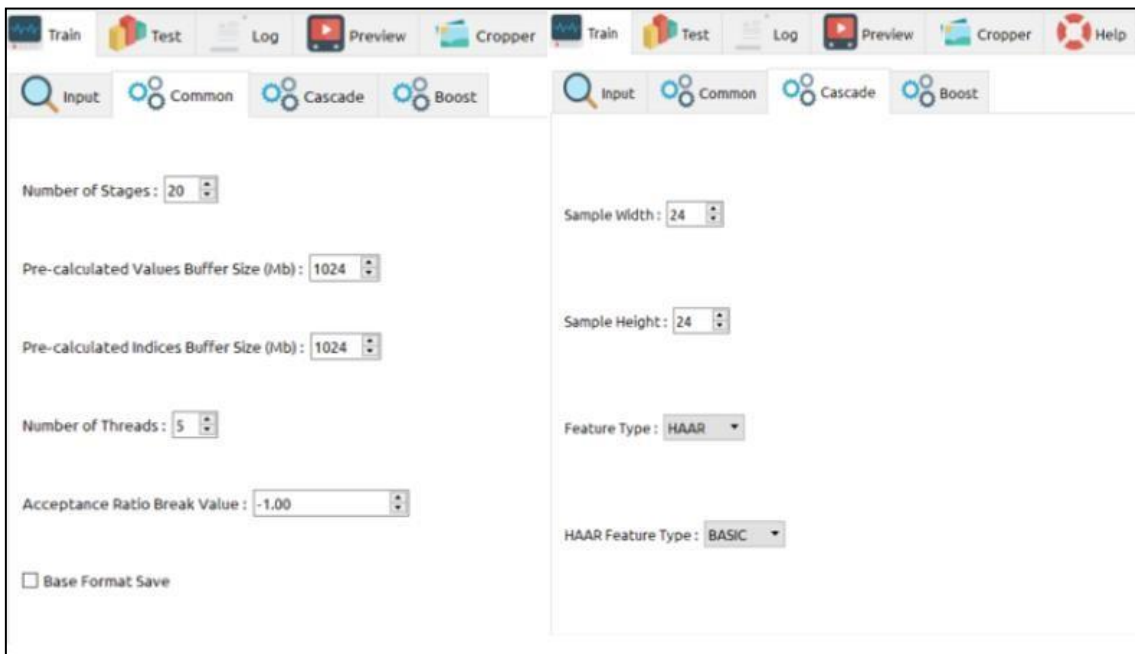


Figura 35. Parámetros del programa Cascade Trainer GUI

A partir de estas fuentes de datos se obtiene como salida (resultado) un modelo de cascada en formato XML.

Para importar un modelo entrenado de clasificación en cascada que barreras mal orientadas en OpenCV, se pueden seguir los siguientes pasos:

- 1) Descargar el archivo XML del modelo entrenado de clasificación en cascada para la detección de barreras mal orientadas.
- 2) Importar las bibliotecas necesarias:

```
Importcv2
import os
```

- 3) Cargar el modelo entrenado en cascada:

```
modelo = 'ruta/al/modelo.xml' # Ruta al archivo XML del modelo
entrenado

cascade = cv2.CascadeClassifier(modelo)
```

Asegurarse de reemplazar 'ruta/al/modelo.xml' con la ruta y el nombre de archivo

correctos en el sistema desde el cual se vaya a ejecutar el código.

- 4) Leer la imagen que se desea analizar:

```
imagen = 'ruta/a/la/imagen.jpg' # Ruta a la imagen que deseas analizar
img = cv2.imread(imagen)
```

Asegurarse de reemplazar 'ruta/a/la/imagen.jpg' con la ruta y el nombre de archivo correctos en el sistema desde el cual se vaya a ejecutar el código.

- 5) Detección de barreras mal orientadas:

```
Barrera_mal_{ } = cascade.detectMultiScale(gray, scaleFactor=1.1,
minNeighbors=5, minSize=(30, 30))
```

Se pueden ajustar los parámetros `scaleFactor`, `minNeighbors` y `minSize` según las necesidades.

- 6) Verificación de si se ha detectado alguna señal barrera mal orientada y almacenamiento de la imagen en una carpeta correspondiente:

```
# Crear la carpeta de destino si no existe
if not os.path.exists(carpeta_destino):
    os.makedirs(carpeta_destino)

# Almacenar las imágenes detectadas en la carpeta correspondiente
for (x, y, w, h) in objetos:
    nombre_archivo = os.path.join(carpeta_destino,
Barrera_mal_{ }.jpg'.format(len(os.listdir(carpeta_destino))))
    cv2.imwrite(nombre_archivo, img[y:y+h, x:x+w])
```

Es primordial asegurarse de reemplazar 'ruta/a/la/carpeta/destino' con la ruta y el nombre de carpeta en el sistema

Este código cargará cada modelo entrenado en cascada, detectará objetos en la imagen y almacenará la imagen original (previa al tratamiento) en la carpeta de destino correspondiente. Cada imagen almacenada se nombrará como "Barrera_mal_x.jpg", donde "x" es un número único que incrementa cada vez que se almacena una imagen.

4.2. Detección de barreras metálicas de altura insuficiente

Existen numerosas maneras de medir distancias sin necesidad de medirlas físicamente. Una de ellas consistiría en emplear cámaras dotadas de sensores de movimiento. Tras calibrar la cámara, sería posible obtener una estimación bastante precisa del objeto que se deseara medir. Otra opción consistiría en emplear sensores ultrasónicos, cuyo funcionamiento se basa en enviar una onda ultrasónica a través del disparador o *trigger*, que rebote contra el objeto y que el receptor o *echo* detecte la onda. Sabiendo cuánto ha tardado en viajar dicha onda, se podría estimar la distancia. Sin embargo, ninguna de estas formas resultaría eficaz, pues no se podrían realizar en movimiento.

Por lo que la metodología propuesta, al igual que en la sección anterior, consistiría en recopilar imágenes, tratarlas mediante visión artificial con el objetivo de obtener imágenes más simplificadas de manera que puedan detectarse los postes de las barreras metálicas mediante técnicas de *machine learning* y *deep learning* y ser estimada su altura. No obstante, cabe recalcar que, para proceder de esta manera, será necesario conocer previamente la dimensión de algún objeto situado en el mismo plano vertical (y además paralelo al eje de la carretera), con el fin de evitar problemas en la estimación debidos a la perspectiva. Por lo tanto, el problema principal consistiría en encontrar algún elemento fiable, que cumpla las condiciones recién mencionadas que se pudiera tomar como elemento de referencia. Uno de estos elementos podría ser un hito de arista, cuyas medidas y dimensiones de sus partes están homologadas.



Figura 36. Hito de arista adosado a barrera metálica

Sin embargo, no todos los hitos de arista servirían. Únicamente los hitos de arista adosados a las barreras de seguridad nos servirían como elemento de referencia, ya que estarían casi en el mismo plano vertical que los postes. Dicho de esta manera, puede parecer que el ámbito de aplicación de esta metodología se reduzca bastante, pero por fortuna, en casi todos los casos se emplean hitos acoplados a las barreras metálicas, pues resultan más baratos que los hitos de arista empotrados. En las figuras 36 y 37 se pueden observar las dos casuísticas existentes de hitos de arista.



Figura 37. Hito de arista anclado al terreno

De manera resumida, el procedimiento consistirá en:

- 1) Recopilación de imágenes.
- 2) Tratamiento previo de las imágenes recopiladas
- 3) Detección del elemento de referencia
- 4) Establecimiento del factor de conversión (equivalencia píxeles-centímetros)
- 5) Detección de las zonas de las barreras metálicas con postes
- 6) Estimación de la altura de las barreras metálicas

A continuación, se describirá con más detenimiento cada una de las fases, explicando las técnicas, algoritmos y lenguajes de programación que se podrían usar para solucionar este problema.

4.2.1. Recopilación de imágenes

En cuanto a la recopilación de imágenes, se propone el empleo práctico de vehículos equipados con sistemas de cámaras. La finalidad de este enfoque es adquirir secuencias de video que documenten el recorrido vehicular, lo cual permitirá un análisis posterior. La recomendación principal es que estas cámaras estén ubicadas en los costados de los vehículos, lo que posibilitará la captura de imágenes frontales de las infraestructuras de seguridad, evitando así los desafíos de perspectiva asociados a tramos de carretera curvos.

Con el objetivo de obtener imágenes uniformes y coherentes, se sugiere mantener la continuidad de la trayectoria en un carril constante. Para lograr esto, se propone ajustar la frecuencia de captura de cuadros de acuerdo con la velocidad del vehículo, garantizando una distribución espacial equitativa de las imágenes a intervalos regulares (cada X metros recorridos).

En el contexto de este estudio, las imágenes utilizadas para ejemplificar la metodología se han obtenido a través de Google Earth Pro. Esto se debe a que es impracticable acceder a

vídeos capturados en la forma descrita anteriormente, ya que los vehículos necesarios para este propósito no están disponibles para el investigador.

4.2.2. Tratamiento de las imágenes recopiladas

Una vez obtenidas los vídeos de los trayectos realizados, es necesario separarlos en fotogramas para poder analizarlos como imágenes. A diferencia de lo descrito en la sección anterior, centrada en detectar barreras de seguridad mal orientadas, en esta sección no será necesario un tratamiento previo tan exhaustivo. La razón es que en este caso no se tratarán elementos lineales como podían ser las biondas, sino elementos discretos: los hitos de arista y los postes de las barreras metálicas.

En cuanto al tratamiento previo, simplemente se realizarán las tareas de recorte y de redimensionamiento.

Para garantizar que todas las imágenes tengan las mismas dimensiones, se han realizado capturas de pantalla completas desde el visor a pie de calle de Google Earth y se han recortado de manera que solo quedaran visibles los píxeles comprendidos entre $H=100$ y $H=600$ y $B=250$ y $B=1300$. A continuación, se han redimensionado las imágenes de manera que su altura sea de 480px y su anchura sea de 720px.




Figura 38. Imagen de la barrera metálica tras haber sido recortada

Al tratarse el problema actual de determinar la altura de las biondas, es decir, de medir distancias, es imprescindible tener claras las dimensiones de las fotografías con el fin de poder convertir con más facilidad las unidades de longitud (píxeles a centímetros).

4.2.3. Detección del elemento de referencia

La detección de objetos es una tecnología informática relacionada con la visión por computadora, el procesamiento de imágenes y el deep learning que se ocupa de detectar instancias de objetos en imágenes y videos. En esta sección, se realizará la detección de objetos usando las cascadas de Haar.

Para facilitar la tarea, se propone el uso de *Cascade Trainer GUI* que es un programa que ofrece una interfaz gráfica, la cual facilita el uso de herramientas de OpenCV para el entrenamiento y prueba de clasificadores. Este programa ofrece entrenar, probar y mejorar modelos de clasificadores en cascada.

Para realizar el entrenamiento será necesario contar con gran cantidad (cientos o miles) de imágenes en donde esté presente el objeto que deseemos detectar (conjunto de muestras positivas) y otro conjunto de imágenes donde NO esté presente dicho objeto (conjunto de muestras negativas). Estas imágenes no deben ser muy grandes, ya que esto podría provocar lentitud en la detección.

El objeto por detectar, como se ha comentado anteriormente, se tratará de la parte reflexiva de los hitos de arista adosados a las barreras metálicas .

Según la *Orden Circular 309/90. HITOS DE ARISTA*, se define como hito de arista un poste dotado de uno o varios elementos reflexivos que se coloca verticalmente en la margen de la plataforma de una carretera.

Los hitos de arista tienen por objetivo primordial balizar los bordes de las carreteras durante las horas nocturnas o de escasa visibilidad.

También balizan el borde de las vías en las horas diurnas, y por ello son de color blanco y llevan una franja negra inclinada hacia el eje de la carretera.

Además, sirven también para materializar los hectómetros de la vía, circunstancia muy interesante para los estudios de accidentes y otros temas.

Existen dos tipos de hitos fundamentalmente diferentes:

- Tipo I - Hitos para carreteras convencionales de calzada única.
- Tipo II - Hitos para carreteras de calzadas separadas.

El Tipo I tiene una sección en forma de "A". con lados iguales, de doce (12) centímetros de longitud. El ángulo formado por los lados de la "A" es de 30 grados sexagesimales. Los espesores de la sección se definen en la figura 10.




Figura 39. Sección de hito de arista de tipo I. Fuente: Orden Circular 309/90. HITOS DE ARISTA,

El hito Tipo II tiene una sección formada por dos líneas paralelas unidas en sus extremos por dos semicircunferencias. Las dimensiones exteriores son de 12 centímetros de longitud y 3.2 de anchura. Los espesores de cada sección se definen en la figura 11.




Figura 40. Sección de hito de arista de tipo II. Fuente: Orden Circular 309/90. HITOS DE ARISTA,

De cada uno de estos dos tipos de hitos existen diversas variantes en función del anclaje.

- Si el anclaje se efectúa en tierra deberá empotrarse no menos de 50 centímetros.
- Si el anclaje se efectúa sobre roca, hormigón u otro material de características semejantes, el hito se asegurará por medio de una pieza metálica galvanizada que garantice su inmovilidad.
- Si el anclaje se efectúa sobre barrera metálica, el hito se asegurará por medio de una pieza metálica en su extremo inferior.
- Si el hito se ancla a cualquier otro elemento (muros, barreras rígidas, etc.) dispondrá de una pieza de fijación apropiada.

El hito se compone de tres Partes.

- Poste
- Material reflexivo y franja negra.
- Elementos de anclaje.

La franja negra del hito se realizará mediante una lámina adherida de vinilo pigmentado, que será flexible y resistente. Esta franja negra tendrá una anchura de 250 milímetros, y se colocará a una distancia fija del extremo superior del hito, inclinada hacia el eje de la carretera.

Es primordial que exista uniformidad en la colocación de los hitos y, por tanto, en la altura a la que quede la banda negra. Todos los hitos instalados en un tramo deben presentar una línea uniforme. En lo que respecta este proyecto, esto supondría una ventaja a la hora de obtener imágenes homogéneas.




Figura 41. Dimensiones de los elementos de un hito de arista

Indiferentemente del tipo de vía (autovía, autopista o carretera convencional), y, por lo tanto, del tipo de hito de arista, las dimensiones de las franjas negras y del elemento reflectante serán las mismas.

En presencia de barreras metálicas de seguridad de tipo bionda, los hitos de arista que se usarán serán más cortos y estarán provistos de una pieza metálica en su parte inferior, que permitirá su anclaje sobre el guardarraíl. Sin embargo, en lo referente a las franjas negras y elementos reflexivos, se deberán cumplir las mismas condiciones que en el resto de los casos.



Figura 42. Hito de arista anclable a la barrera metálica.

Por lo tanto, son cuatro las medidas fijas que se han de cumplir siempre:

- 1) La altura del extremo superior del hito de arista sobre el pavimento, que ha de ser de 105 centímetros.
- 2) Las dimensiones de la franja negra, cuya altura ha de ser de 25 centímetros.
- 3) La altura del recuadro reflexivo amarillo, presente en la cara anterior del hito, y que debe de medir 18 centímetros.
- 4) Las dimensiones y la separación entre los círculos amarillos reflexivos presentes en la cara posterior de los hitos de arista.

Atendiendo a todo lo anterior, se puede concluir que adoptar como elemento de referencia los hitos de arista puede ser una solución válida. Sin embargo, no se tomará en cuenta la altura de estos respecto al pavimento, pues esto solo se podría realizar si el hito de arista estuviera empotrado en el suelo.

Por ser demasiado simple, también se descartaría la adopción del recuadro reflexivo amarillo como elemento de referencia. Se trataría de simples píxeles amarillos, aumentando la posibilidad de detección de falsos positivos. Cualquier elemento amarillo podría ser detectado de manera incorrecta, reduciendo e incluso anulando la eficacia de este procedimiento.

Finalmente, se concluye que el elemento más fiable es la franja negra incluido el recuadro reflexivo amarillo. Se trata de un elemento simple y a la vez lo suficientemente complejo para evitar problemas de falsos positivos. Además, siempre será visible a la derecha del sentido de circulación, lo cual permitiría la captación de imágenes circulando siempre por el carril lento.

Para poder detectar objetos, el primer paso consiste en entrenar un modelo para que sea capaz de dar resultados correctos, clasificando de manera correcta las imágenes entrantes.

Para ello se empleará el programa Cascade Trainer GUI.

El primer paso consistirá en almacenar un número suficiente de imágenes positivas en una carpeta. Por imágenes positivas se entenderá, en este apartado, imágenes donde sea posible visualizar la franja negra de los hitos de arista.

Según las indicaciones del programa, para un correcto entrenamiento son necesarias miles de imágenes positivas, aunque es posible conseguir los mismos objetivos con un tamaño de muestra mucho menor si se tratan de figuras simples.

Un aspecto que permite el uso de una colección o dataset (de imágenes) de tamaño reducido, es la variabilidad de las condiciones de toma. Es decir, si se toman imágenes en diferentes condiciones de iluminación, o desde diferentes ángulos, serán necesarias menos imágenes en la colección para obtener resultados correctos, reduciéndose la posibilidad de falsos positivos o de errores en la detección.

Además, con el objetivo de reducir el esfuerzo computacional, se recomienda el uso de imágenes de tamaño reducido. Para ello será necesario redimensionar las imágenes antes de almacenarlas en la carpeta de los positivos. Con el objetivo de no perder las proporciones, sólo se modificará la altura de estas imágenes, manteniéndose la proporción altura-anchura.

La figura 43, representa esquemáticamente lo recién descrito, pues son pequeñas imágenes donde se puede apreciar claramente el objeto que se desea detectar. Las bibliotecas de imágenes para el entrenamiento se pueden consultar en el Anexo I.

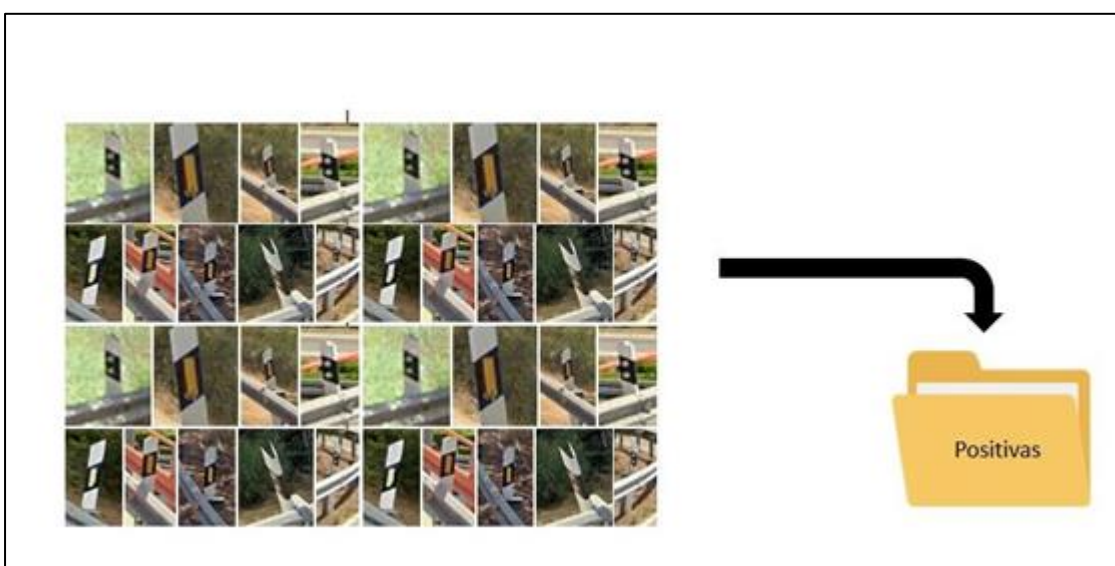


Figura 43. Biblioteca de imágenes positivas, donde aparecen las franjas negras de los hitos de arista

Por otra parte, será necesario almacenar un número suficiente de imágenes negativas en una carpeta. Por imágenes negativas se entenderá, en este apartado, imágenes donde no sea posible visualizar la franja negra de los hitos de arista.

Según las indicaciones del programa, para un correcto entrenamiento son necesarias miles de imágenes negativas, aunque es posible conseguir los mismos objetivos con un tamaño de muestra mucho menor si el objeto a detectar se tratara de una figura simple.

Para entrenar correctamente el modelo son imprescindibles dos aspectos:

- 1) Que bajo ningún concepto aparezcan imágenes positivas en la carpeta de imágenes negativas, ni que aparezca el objeto que se pretende detectar en ninguna de ellas, aunque sea sólo parcialmente. Esto afectaría de manera sumamente importante la eficacia del modelo.
- 2) Aunque en teoría, las imágenes negativas puedan ser cualquier imagen donde no aparezca el objeto que se pretende detectar, se recomienda que estén relacionadas. Si lo que se pretende detectar son las franjas negras de los hitos de arista, será mucho mejor emplear imágenes donde se puedan apreciar barreras metálicas o vegetación propia de los márgenes de las carreteras antes que emplear imágenes del cielo, o de rostros humanos. El objetivo es que el modelo aprenda a no darle relevancia a las formas o elementos presentes en las dos categorías de imágenes.

Al igual que para el caso de las imágenes positivas, resulta más práctico emplear un mayor número de imágenes pequeñas que un número más reducido de imágenes. Para ello, se reducirá el tamaño de estas imágenes modificándolas, de manera que se iguale su altura, pero sin que se produzcan distorsiones.

La figura 44 representa esquemáticamente lo recién descrito, pues son pequeñas imágenes donde se puede apreciar el entorno en el cual podrían aparecer hitos de arista, pero sin que aparezcan éstos. Las bibliotecas de imágenes para el entrenamiento se pueden consultar en el Anexo I.

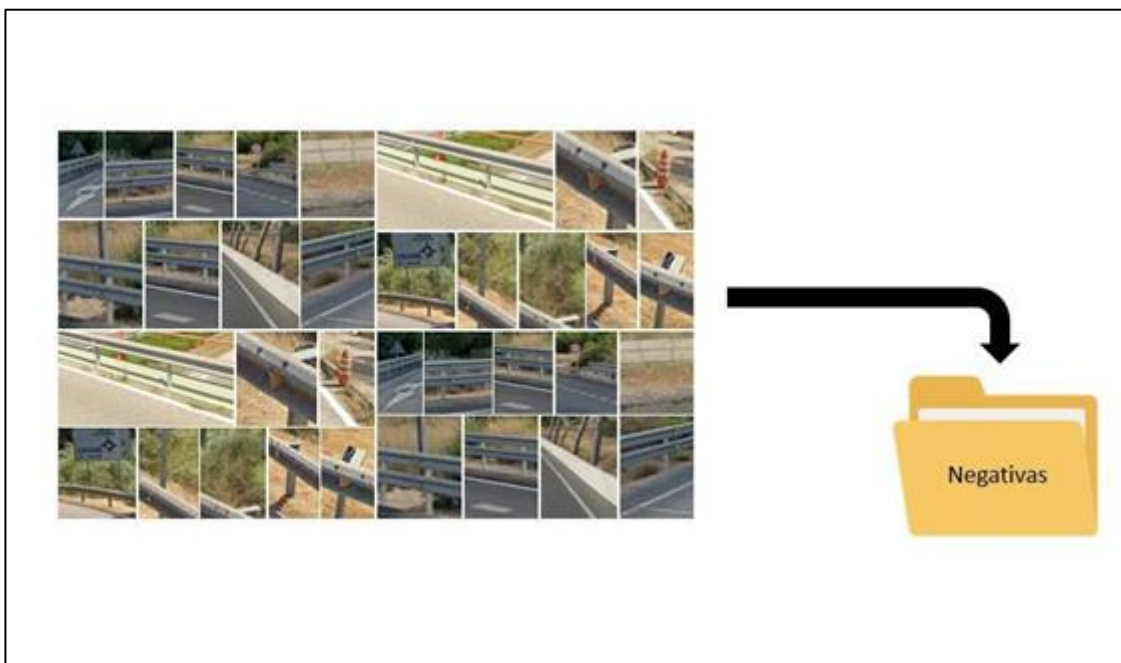


Figura 44. Biblioteca de imágenes negativas, donde no aparecen las franjas negras de los hitos de arista

Se sugiere que la cantidad de imágenes positivas constituya alrededor del 25% del total de imágenes que se utilizarán para el entrenamiento, lo que significa que se requieren tres veces más imágenes negativas que positivas.

A partir de estas fuentes de datos, se obtiene como resultado un modelo en cascada en formato XML.

Una vez obtenido este modelo, será necesario importarlo a OpenCV, de manera que pueda ser utilizado en una función que permita la detección de los objetos en cuestión. Para lograrlo, se deben seguir los siguientes pasos:"

- 1) Descargar la cascada .xml para la detección de objetos que desee utilizar y colocarla en la carpeta de trabajo.
- 2) Cargar la cascada .xml en el programa de OpenCV utilizando la función "CascadeClassifier". Esto se puede hacer de la siguiente manera:

```
Import cv2  
  
cascade_classifier = cv2.CascadeClassifier("nombre_cascada.xml")
```

- 3) Cargar la imagen en la que se desea detectar objetos utilizando la función "cv2.imread". Esto se puede hacer de la siguiente manera:

```
image = cv2.imread("nombre_imagen.jpg")
```

En caso de querer leer un vídeo, se haría de la manera siguiente:

```
cap= cv2.VideoCapture(("nombre.video.mp4"))
```

- 4) Convertir la imagen a escala de grises utilizando la función "cv2.cvtColor". Estose puede hacer de la siguiente manera:

```
gray_image = cv2.cvtColor(image, cv2.COLOR_BGR2GRAY)
```

- 5) Utilizar la función "detectMultiScale" de la cascada para detectar los objetos en la imagen en escala de grises. Esto se puede hacer de la siguiente manera:

```
objects = cascade_classifier.detectMultiScale(gray_image,  
scaleFactor=1.3, minNeighbors=5)
```

La función "detectMultiScale" toma como entrada la imagen en escala de grises y realiza la detección de objetos utilizando la cascada .xml cargada previamente. Los parámetros "scaleFactor" y "minNeighbors" son ajustables para mejorar la precisión de la detección.

- 6) Crear un contador, para que sea posible almacenar los diferentes objetos detectados en los diferentes fotogramas:
- 7) Dibujar los rectángulos alrededor de los objetos detectados en la imagen. Esto se puede hacer de la siguiente manera:

```
for (x, y, w, h) in objects:  
    cv2.rectangle(image, (x, y), (x+w, y+h), (0, 255, 0), 2)
```

La función "cv2.rectangle" dibuja un rectángulo en la imagen. Los parámetros "x" e "y" representan las coordenadas del punto superior izquierdo del rectángulo, "w" y "h" representan el ancho y la altura del rectángulo. Los parámetros (0, 255,0) representan el color del rectángulo en formato RGB y el parámetro 2 representa el grosor del rectángulo.

- 8) Mostrar la imagen con los rectángulos dibujados utilizando la función "cv2.imshow". Esto se puede hacer de la siguiente manera:

```
cv2.imshow("Detección de objetos", image)  
  
cv2.waitKey(0)  
  
cv2.destroyAllWindows()
```

La función "cv2.imshow" muestra la imagen con los rectángulos dibujados en una ventana. La función "cv2.waitKey" espera a que se presione una tecla para cerrar la ventana. La función "cv2.destroyAllWindows" cierra todas las ventanas abiertas.

Con estos pasos, se puede importar una cascada .xml a OpenCV y hacer que detecte objetos en una imagen. Es posible ajustar los parámetros para mejorar la precisión de la detección y adaptarla a diversos escenarios de detección de objetos.

Tal y como se puede observar en el apartado sexto, se crea una variable h, cuyo valor es la altura del objeto detectado en píxeles. Concretamente, se trata de la altura del elemento de referencia.

4.2.4. Establecimiento del factor de conversión

Para establecer un factor de conversión de píxeles a centímetros en OpenCV, primero necesitamos conocer la distancia real o el tamaño del objeto que se detecta. Para ello, podemos utilizar la información proporcionada por la cámara, como la distancia focal y la resolución de la imagen.

Una vez que conocemos la distancia real del objeto, podemos medir su tamaño en píxeles utilizando el rectángulo que lo enmarca. Para convertir los píxeles a centímetros, podemos dividir el tamaño del objeto en píxeles por la altura del rectángulo en centímetros. Esto nos dará un factor de conversión que podemos utilizar para futuras mediciones de objetos en la misma imagen o en imágenes similares.

Por ejemplo, si la distancia real del objeto es de 25 centímetros y su tamaño medido en píxeles es de 250 píxeles, podemos calcular el factor de conversión como:

factor de conversión = tamaño del objeto en píxeles / altura del rectángulo en centímetros
= $250 / 25 = 10$ píxeles / centímetro

Una vez que tenemos el factor de conversión, podemos utilizarlo para medir el tamaño de otros objetos en la imagen, dividiendo su tamaño en píxeles por el factor de conversión para obtener su tamaño en centímetros.

4.2.5. Detección de los postes de las barreras metálicas

De manera análoga al punto 4.2.3, para poder detectar las barreras metálicas, será necesario entrenar un nuevo modelo que sea capaz de distinguir entre imágenes donde aparecen postes e imágenes donde no. Para ello se empleará el programa Cascade Trainer GUI, al igual que en el caso anterior.

El primer paso en el proceso consistirá en almacenar un conjunto suficiente de imágenes positivas que muestren el poste de la barrera metálica. Para garantizar un entrenamiento eficaz, se necesitan miles de imágenes positivas, aunque si se trata de figuras simples, se pueden obtener objetivos similares con una muestra menor.

La variación de las condiciones en que se toman las imágenes permite el uso de un dataset más pequeño, ya que se reduce la necesidad de obtener una cantidad excesiva de imágenes para lograr una detección correcta y reducir la posibilidad de falsos positivos o errores en la detección.

Además, para minimizar el esfuerzo computacional, es recomendable utilizar imágenes de menor tamaño, por lo que se deberán redimensionar las imágenes antes de almacenarlas en la carpeta de imágenes positivas. Es importante mantener las proporciones de la imagen, modificando únicamente la altura, sin afectar la relación entre la altura y la anchura.

La figura 45, representa esquemáticamente lo recién descrito, pues son pequeñas imágenes donde se puede apreciar claramente el objeto que se desea detectar. Las bibliotecas de imágenes para el entrenamiento se pueden consultar en el Anexo I.




Figura 45. Biblioteca de imágenes positivas, donde aparecen los postes de las barreras metálicas.

Por otra parte, será necesario almacenar un número suficiente de imágenes negativas en una carpeta. Por imágenes negativas se entenderá, en este apartado, imágenes donde no sea posible visualizar el poste de la barrera metálica.

El programa de entrenamiento requiere una gran cantidad de imágenes negativas para lograr una capacitación efectiva, aunque se puede obtener una muestra mucho más reducida si se trata de detectar figuras simples.

Es esencial evitar la inclusión de imágenes positivas o imágenes que contengan parcialmente el objeto que se desea detectar en la carpeta de imágenes negativas, ya que esto comprometerá significativamente la eficacia del modelo. Además, se recomienda que las imágenes negativas estén relacionadas con el objeto de detección. Por ejemplo, para detectar los postes de las barreras metálicas, es preferible utilizar imágenes de tramos de barrera metálica sin postes (sólo la bionda) o de los bordes de las carreteras en lugar de imágenes del cielo o de rostros humanos. La meta es que el modelo aprenda a no dar importancia a las formas o elementos presentes en ambas categorías de imágenes.

De manera similar a las imágenes positivas, es más práctico utilizar una gran cantidad de imágenes pequeñas en lugar de un número reducido de imágenes. Por lo tanto, se reducirá el tamaño de estas imágenes modificándolas, asegurándose de que todas tengan la misma altura sin distorsión alguna.

La figura 46, representa esquemáticamente lo recién descrito, pues son pequeñas imágenes donde se puede apreciar el entorno en el cual podrían aparecer los postes, pero sin que aparezcan éstos. Las bibliotecas de imágenes para el entrenamiento se pueden consultar en el Anexo I.




Figura 46. Biblioteca de imágenes negativas, donde no aparecen los postes de las barreras metálicas.

Según Viola & Jones, se recomienda que el número de imágenes positivas represente alrededor de un 25% del total de imágenes que se vayan a emplear para el entrenamiento, es decir que son necesarias el triple de imágenes negativas que de positivas.

A partir de estas fuentes de datos se obtiene como salida (resultado) un modelo de cascada en formato XML.

Una vez obtenido este modelo, será necesario importarlo a OpenCV, de manera que pueda ser usado en una función que permita la detección de los objetos en cuestión. Para ello se deberán seguir los siguientes pasos:

- 1) Descargar la cascada .xml para la detección de objetos que desee utilizar y colocarla en la carpeta de trabajo.
- 2) Cargar la cascada .xml en el programa de OpenCV utilizando la función "CascadeClassifier". Esto se puede hacer de la siguiente manera:

```
import cv2
cascade_classifier = cv2.CascadeClassifier("nombre_cascada.xml")
```

- 3) Cargar la imagen en la que se desea detectar objetos utilizando la función "cv2.imread". Esto se puede hacer de la siguiente manera:

```
image = cv2.imread("nombre_imagen.jpg")
```

En caso de querer leer un vídeo, se haría de la manera siguiente:

```
cap= cv2.VideoCapture(("nombre.video.mp4"))
```

- 4) Convertir la imagen a escala de grises utilizando la función "cv2.cvtColor". Estose puede hacer de la siguiente manera:

```
gray_image = cv2.cvtColor(image, cv2.COLOR_BGR2GRAY)
```

- 5) Utilizar la función "detectMultiScale" de la cascada para detectar los objetos en la imagen en escala de grises. Esto se puede hacer de la siguiente manera:

```
objects = cascade_classifier.detectMultiScale(gray_image,  
scaleFactor=1.3, minNeighbors=5)
```

La función "detectMultiScale" toma como entrada la imagen en escala de grises y realiza la detección de objetos utilizando la cascada .xml cargada previamente. Los parámetros "scaleFactor" y "minNeighbors" son ajustables para mejorar la precisión de la detección.

- 6) Crear un contador, para que sea posible almacenar los diferentes objetos detectados en los diferentes fotogramas:
- 7) Dibujar los rectángulos alrededor de los objetos detectados en la imagen. Esto se puede hacer de la siguiente manera:

```
for (n, m, a, l) in objects:
```

```
cv2.rectangle(image, (n, m), (n+a, m+l), (0, 255, 0), 2)
```

La función "cv2.rectangle" dibuja un rectángulo en la imagen. Los parámetros "n" e "m" representan las coordenadas del punto superior izquierdo del rectángulo, "a" y "l" representan el ancho y la altura del rectángulo. Los parámetros (0, 255,0) representan el color del rectángulo en formato RGB y el parámetro 2 representa el grosor del rectángulo.

- 8) Mostrar la imagen con los rectángulos dibujados utilizando la función "cv2.imshow". Esto se puede hacer de la siguiente manera:

```
cv2.imshow("Detección de objetos", image)
```

```
cv2.waitKey(0)
```

```
cv2.destroyAllWindows()
```

La función "cv2.imshow" muestra la imagen con los rectángulos dibujados en una ventana. La función "cv2.waitKey" espera a que se presione una tecla para cerrar la ventana. La función "cv2.destroyAllWindows" cierra todas las ventanas abiertas.

4.2.6. Estimación de la altura de las barreras metálicas

Una vez ejecutados los anteriores pasos, se obtiene una imagen tal que la siguiente:



En ella se observan los dos elementos detectados (si los hubiera), con los dos rectángulos que los enmarcan. Ambos rectángulos están definidos por sus parámetros (coordenadas del vértice superior izquierdo, anchura y altura). Para realizar la estimación, nos centraremos en la altura.

Serán conocidos los valores en píxeles (px) de los parámetros "h" (altura del elemento de referencia) y "l" (altura de la barrera metálica).

Se sabe que el parámetro "h" se corresponde con 25 centímetros en la realidad. Con estos parámetros resulta posible estimar la altura de las barreras metálicas.

El código para esta tarea sería el descrito a continuación:

- 1) Realización del cálculo para estimar la altura de la barrera metálica y creación de una variable donde se almacena este valor

$$H_g = 25 * (l/h)$$

$$\text{altura_barrera metálica} = H_g$$

- 2) Creación de una etiqueta que se imprime junto a la imagen, donde aparece el valor de la altura en centímetros de la barrera metálica

$$\text{etiqu} = \text{"Altura del guardarrail: \{ \} cm"}.format(\text{altura_g})$$

$$\text{cv2.putText}(\text{img}, \text{etiqu}, (\text{x2}, \text{y2} - 70), \text{cv2.FONT_HERSHEY_SIMPLEX}, 0.5, (0, 255, 255), 1)$$

- 3) Impresión en pantalla de la etiqueta y de la imagen

$$\text{print}(\text{'La altura de la barrera metálica es de ', } H_g, \text{' cm'}$$

cv2.imshow('Detección de hitos', img)

4.3. Detección de ausencia de señal de prohibición de entrada en carriles de acceso a glorietas

Por lo que la metodología propuesta, al igual que en la sección anterior, consistiría en recopilar imágenes, tratarlas mediante visión artificial con el objetivo de obtener imágenes más simplificadas de manera que se facilite la clasificación.

De manera resumida, el procedimiento consistirá en:

- 1) Recopilación de imágenes.
- 2) Tratamiento previo de las imágenes recopiladas
- 3) Detección de los carriles de entrada de las rotondas y selección de imágenes.
- 4) Detección de ausencia de señal de entrada prohibida en las imágenes seleccionadas en el punto 3

A continuación, se describirá con más detenimiento cada una de las fases, explicando las técnicas, algoritmos y lenguajes de programación que se podrían usar para solucionar este problema.

4.3.1. Recopilación de imágenes

Para la recopilación de imágenes, la idea es que, en la práctica se empleen vehículos equipados con cámaras. De esta manera se obtendrían vídeos del trayecto realizado, que se podrán tratar posteriormente. Lo ideal sería que estas imágenes fueran capturadas por cámaras frontales, con el objetivo de captar imágenes desde un punto de vista similar al del conductor, a quien están destinadas las señales.

Para obtener imágenes homogéneas, se recomendaría viajar siempre en el mismo carril, y que se adaptara la captación de fotogramas a la velocidad, con el objetivo de obtener una distribución espacial homogénea de imágenes (una imagen cada X metros recorridos)

En este trabajo, las imágenes empleadas para ilustrar la metodología han sido obtenidas a través de Google Earth Pro, pues resulta imposible tener acceso a vídeos obtenidos de la manera con la que se realizaría esto en la práctica, al no ser accesibles los vehículos descritos en el párrafo anterior.

4.3.2. Tratamiento de las imágenes recopiladas

Una vez obtenidas los vídeos de los trayectos realizados, es necesario separarlos en fotogramas para poder analizarlos como imágenes.

En cuanto al tratamiento previo, simplemente se realizarán las tareas de recorte y de redimensionamiento.

Para garantizar que todas las imágenes tengan las mismas dimensiones, se han realizado capturas de pantalla completas desde el visor a pie de calle de Google Earth y se han recortado

de manera que solo quedaran visibles los píxeles comprendidos entre $H=0$ y el $H=480$ y $B=780$ y $B=1500$. A continuación, se han redimensionado las imágenes de manera que su altura sea de 480px y su anchura sea de 720px.

4.3.3. Detección de los carriles de entrada en las glorietas

Una vez tratadas las imágenes, el siguiente paso consiste en seleccionar aquellas en las que se vea con claridad un carril de entrada a la rotonda, por lo que será necesario diferenciar entre carriles de entrada y de salida.

Los carriles de entrada a una rotonda son aquellos que conducen al centro de la misma, mientras que los carriles de salida son aquellos que se alejan del centro de la rotonda y conducen hacia la salida de la misma. Los elementos que permiten diferenciar los carriles de entrada y salida son los siguientes:

- 1) Marcas viales transversales: Los carriles de entrada suelen contar con una marcavial transversal de cesión de paso (M-4.2), mientras que las salidas no cuentan con ninguna marca vial transversal.



Figura 47. Marca vial M-4.2 en el carril de incorporación a la glorieta.



Figura 48. Carril de salida de la glorieta.

- 2) Marca vial de cesión de paso: Junto a la marca vial transversal M-4.2, se suele pintar una marca vial de cesión de paso (M-6.5) sobre el pavimento en el carril de entrada, indicando de esta manera que es necesario ceder el paso a aquellos vehículos presentes ya en la glorieta. No obstante, son numerosos los casos de glorietas en los cuales aparece sólo la señal M-6.5.




Figura 49. Marca vial M-6.5 en el carril de incorporación a la glorieta

- 3) Disposición de la rotonda y curvatura de las marcas viales continuas y/o bordillos: La planta de la mayoría de las rotondas es circular, por lo que al recorrer la glorieta la curvatura de la isleta central siempre es convexa. Ahora bien, en los carriles de salida, se observa una curvatura pronunciada de las marcas viales de borde de calzada o de los bordillos (en tramos urbanos), mientras que en los carriles de entrada la curvatura es notablemente menor.



Figura 50. Curvatura característica de la salida de una glorieta.




Figura 51. Curvatura característica de la entrada a una glorieta.

4) Flujo del tráfico: Puesto que a veces las marcas viales no van a poder ser visibles, por presencia de vehículos, otro criterio para diferenciar los carriles de entrada de los de salida es fijándose en el flujo del tráfico. Así pues, los carriles de entrada tienen un flujo de tráfico que entra en la rotonda (percibiéndose en las imágenes la parte frontal de los vehículos), mientras que los de salida tienen un flujo que sale de la misma, observándose la parte trasera de los automóviles.




Figura 52. Flujo de tráfico entrante a una glorieta



Figura 53. Flujo de tráfico saliente de una glorieta.

Por lo tanto, teniendo claros estos criterios, se podrán desarrollar 4 modelos clasificatorios independientes, de manera que se recopilen las imágenes en las cuales se puedan percibir carriles de entrada rotonda, almacenándolas en una carpeta en concreto. A continuación, se explicará de manera detallada cada uno de estos cuatro criterios.

a) Proceso de detección marcas M-4.2

Con el propósito de habilitar la detección de objetos, el proceso inicial implica el entrenamiento de un modelo con capacidad de proporcionar resultados precisos, logrando así la correcta clasificación de las imágenes entrantes.

En este contexto, se empleará el programa Cascade Trainer GUI. La fase inicial del procedimiento requiere la acumulación de un conjunto sustancial de imágenes positivas en un directorio específico. En esta instancia, las imágenes positivas se definen como aquellas en las que sea evidente la visualización de la marca vial transversal de ceda el paso (M-4.2) en las entradas de las rotondas.

De acuerdo con las directrices del programa, para lograr un entrenamiento apropiado se precisa un número considerable de imágenes positivas, aunque para figuras simples, se puede obtener resultados equivalentes con un tamaño de muestra más reducido.

Un factor que favorece la utilización de un *dataset* de dimensiones limitadas es la variabilidad inherente a las condiciones de adquisición de imágenes. Esto significa que al capturar imágenes bajo diversas condiciones de iluminación o desde distintos ángulos, se puede reducir la cantidad de imágenes requeridas en el conjunto, disminuyendo así las posibilidades de falsos positivos o errores en la detección.

Adicionalmente, con el objetivo de mitigar la carga computacional, se aconseja el uso de imágenes de dimensiones reducidas. Para este propósito, se debe redimensionar las imágenes antes de almacenarlas en la carpeta de imágenes positivas. Con el fin de conservar las proporciones originales, solo se modificará la dimensión de altura de estas imágenes, manteniendo constante la relación de aspecto.

La Figura 54 es una representación esquemática que ilustra lo previamente mencionado, mostrando imágenes de pequeño tamaño en las cuales el objeto a detectar es claramente visible.




Figura 54. Biblioteca de imágenes positivas, donde aparecen marcas viales M-4.2

Además, se requerirá el almacenamiento de un volumen adecuado de imágenes negativas en un directorio específico. En este contexto, se definen como imágenes negativas aquellas en las cuales no sea factible visualizar la marca vial transversal de ceda el paso (M-4.2) en las entradas de las rotondas.

De acuerdo con las instrucciones del software, para efectuar un entrenamiento preciso se demanda una cantidad sustancial de imágenes negativas. Sin embargo, para objetos de naturaleza sencilla, se puede lograr el mismo propósito con un tamaño de muestra reducido.

Para llevar a cabo una formación efectiva del modelo, se deben considerar dos aspectos críticos:

- a. Es esencial que en ningún caso las imágenes positivas se encuentren en la carpeta de imágenes negativas, ni que el objeto a detectar aparezca en ninguna de ellas, aunque sea parcialmente. Esto podría tener un impacto significativo en la eficacia del modelo.
- b. Aunque en teoría, las imágenes negativas podrían ser cualquier imagen donde el objeto a detectar no esté presente, se recomienda que estén contextualmente relacionadas. Si la detección se centra en las marcas viales transversales de ceda el paso (M-4.2) en las entradas de las rotondas, sería más apropiado utilizar imágenes que muestren salidas de rotondas en lugar de imágenes sin relación con el objetivo, como imágenes de animales o vehículos. El propósito es permitir al modelo diferenciar con mayor eficacia las dos categorías de imágenes al aprender a no destacar las formas o elementos presentes en ambas.

Igual que con las imágenes positivas, resulta más práctico utilizar un mayor número de imágenes de dimensiones reducidas que un conjunto menor. Para este fin, se ajustará el tamaño de estas imágenes modificándolas de manera que sus alturas sean iguales, evitando distorsiones.

La Figura 55 representa de manera esquemática lo previamente explicado, exhibiendo imágenes pequeñas que reflejan el entorno donde podrían aparecer las marcas viales en las salidas de rotondas, aunque dichas marcas no sean visibles en las imágenes.




Figura 55. Biblioteca de imágenes negativas, donde no aparecen marcas viales M-4.2

A partir de estas fuentes de datos se obtiene como salida (resultado) un modelo de cascada en formato XML.

b) Proceso de detección marcas M-6.5

Con el propósito de implementar la detección de objetos, la fase inicial conlleva el adiestramiento de un modelo para lograr resultados precisos, logrando la correcta clasificación de las imágenes entrantes.

Para esta finalidad, se hará uso del programa Cascade Trainer GUI. El proceso inicial involucra la acumulación de un volumen adecuado de imágenes positivas en una ubicación específica. En esta fase, las imágenes positivas se definen como aquellas en las que sea posible identificar la marca vial de ceder el paso (M-6.5) en las entradas de las rotondas.

De acuerdo con las directrices del software, para un entrenamiento eficaz se requiere un número sustancial de imágenes positivas. Sin embargo, en el caso de objetos simples, los mismos resultados pueden ser alcanzados con un tamaño de muestra reducido.

Un aspecto habilitante en el uso de un conjunto de datos de pequeña escala en el ámbito de imágenes radica en la diversidad de condiciones de captura. Concretamente, cuando las imágenes se obtienen bajo diversas condiciones de iluminación o ángulos de captura, se disminuye la cantidad necesaria en el conjunto para obtener resultados precisos, reduciendo la probabilidad de falsos positivos o errores en la detección.

Además, con la finalidad de reducir la carga computacional, se propone el empleo de imágenes de dimensiones reducidas. Para lograrlo, es necesario redimensionar las imágenes antes de su almacenamiento en el directorio de imágenes positivas. Con el objetivo de mantener la relación de aspecto, solo se modificará la dimensión de altura de estas imágenes, manteniendo constante la proporción entre la altura y el ancho.

La Figura 56 ilustra de manera esquemática lo expuesto recientemente, presentando imágenes de pequeñas dimensiones en las cuales el objeto que se desea detectar es claramente perceptible.

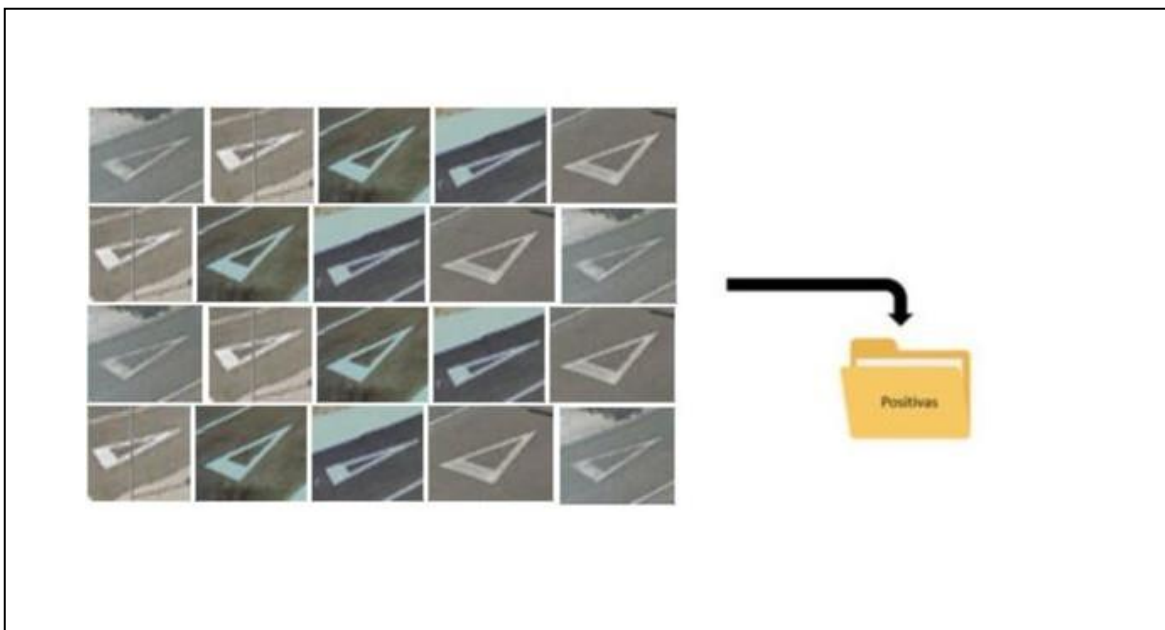


Figura 56. Biblioteca de imágenes positivas, donde aparecen marcas viales M-6.5

En el mismo tenor, se hace necesario almacenar una cantidad adecuada de imágenes negativas en un directorio específico. En esta perspectiva, las imágenes negativas se definen como aquellas en las cuales no se logra visualizar la marca vial de ceder el paso (M-6.5) en las entradas de las rotondas.

De acuerdo con las directrices provistas por el software, un entrenamiento efectivo requiere de miles de imágenes negativas, aunque se puede alcanzar los mismos objetivos con una muestra mucho más reducida si el objeto a detectar tiene una forma simple.

Para una formación precisa del modelo, resultan fundamentales dos aspectos clave:

- a. Es imperativo evitar enérgicamente que las imágenes positivas se encuentren en la carpeta de imágenes negativas, así como impedir que el objeto que se pretende detectar aparezca en ninguna de ellas, incluso de manera parcial. Esto tendría un impacto significativamente negativo en la eficacia del modelo.
- b. Aunque en teoría, las imágenes negativas pueden ser cualquier imagen donde el objeto que se desea detectar no esté presente, se aconseja que estas imágenes tengan una relación contextual. Si el objetivo de detección son las marcas viales de ceder el paso (M-6.5) en las entradas de las rotondas, será más ventajoso utilizar imágenes que

muestren las salidas de rotondas en lugar de imágenes sin relevancia para el objetivo, como imágenes de animales o aviones. El propósito subyace en instruir al modelo para que no otorgue importancia a las formas o elementos presentes en ambas categorías de imágenes, facilitando así una diferenciación más eficaz entre ambas categorías.

Al igual que en el caso de las imágenes positivas, resulta más operativo emplear un conjunto mayor de imágenes de dimensiones reducidas que un conjunto más limitado. Para alcanzar esto, se reducirá el tamaño de las imágenes, modificándolas de tal manera que sus alturas sean uniformes, sin generar deformaciones.

La Figura 57 representa de manera esquemática lo anteriormente explicado, mostrando imágenes pequeñas que reflejan el entorno donde podrían aparecer las marcas viales en las salidas de rotondas, aunque estas marcas no sean visibles en las imágenes.

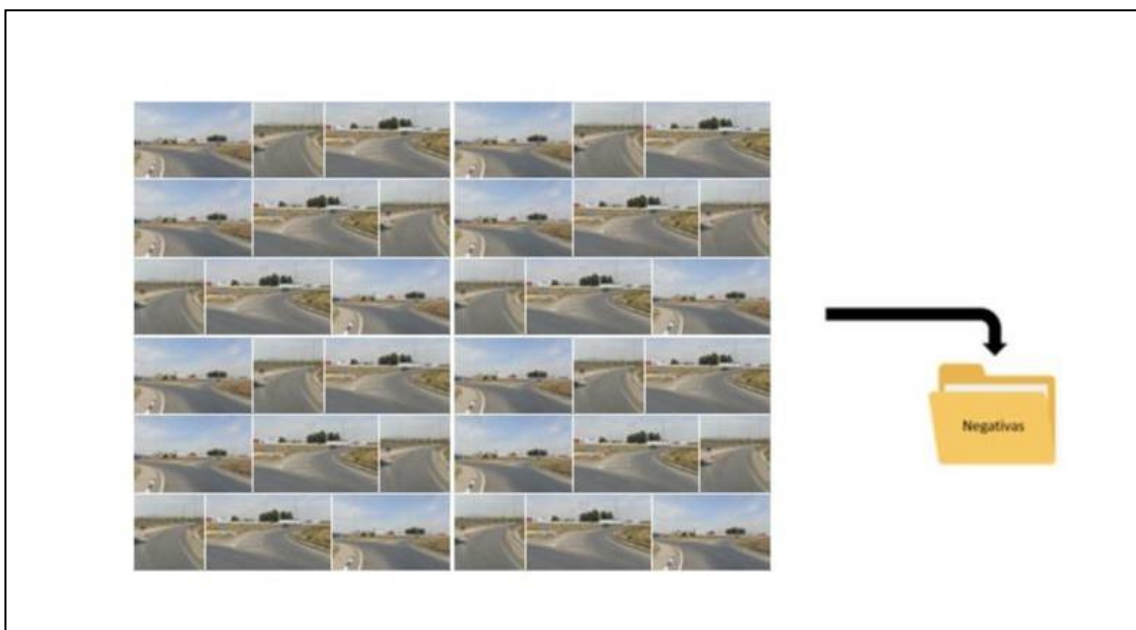


Figura 57. Biblioteca de imágenes negativas, donde no aparecen marcas viales M-6.5

A partir de estas fuentes de datos se obtiene como salida (resultado) un modelo de cascada en formato XML.

c) Proceso de detección curvatura de los bordes

Con el objetivo de efectuar la detección de objetos, la fase inicial conlleva el entrenamiento de un modelo para generar resultados precisos, logrando una correcta clasificación de las imágenes entrantes.

Para esta tarea, se empleará la herramienta Cascade Trainer GUI. La etapa inicial implica la acumulación de un conjunto adecuado de imágenes positivas en una ubicación específica. En este contexto, las imágenes positivas se definen como aquellas que

presentan un conjunto de marcas viales o bordillos con características particulares. Estos elementos, al ser marcas viales o bordillos, se componen de trazos lineales curvos, siendo su distinción principal su disposición relativa y la curvatura inherente. Esta característica se ejemplifica en la figura 58, donde la primera curva identificada corresponde a la marca vial de la isleta central de la glorieta, que se caracteriza por su curvatura pronunciada hacia la izquierda. La segunda línea marcada representa la unión entre la marca vial del anillo exterior de la rotonda y la marca vial del borde derecho del carril de entrada a la glorieta. Esta segunda línea exhibe una curvatura considerablemente menor en comparación con la primera, mostrando semejanza a una línea horizontal recta.



Figura 58. Curvatura característica de los bordes en una entrada a la glorieta

Al tratarse de elementos lineales, se propone la aplicación del filtro Canny a las imágenes de entrada.




Figura 59. Curvatura característica de los bordes en una entrada a la glorieta. Imagen tratada

De hecho, el uso de este filtro OpenCV para tratar imágenes previamente en el entrenamiento de modelos de clasificación en cascada puede proporcionar varias ventajas:

- 1) Detección de bordes mejorada: El filtro Canny es una técnica popular para la detección de bordes en imágenes. Al aplicar este filtro, se resaltan los bordes presentes en la imagen, lo que puede ayudar a resaltar las características clave utilizadas por el modelo de clasificación en cascada para tomar decisiones. Esto puede mejorar la capacidad del modelo para identificar patrones relevantes en los datos de entrada
- 2) Reducción del ruido: El filtro Canny también ayuda a reducir el ruido en una imagen. Al suavizar la imagen y eliminar detalles innecesarios o insignificantes, se obtiene una imagen más limpia y simplificada. Esto puede ayudar al modelo a centrarse en las características importantes y evitar la confusión causada por el ruido.
- 3) Reducción de la dimensionalidad: Al aplicar el filtro Canny, se puede reducir la cantidad de información en la imagen, ya que solo se conservan los bordes detectados. Esto puede ayudar a reducir la dimensionalidad de los datos de entrada, lo que a su vez puede llevar a una mejora en el rendimiento del modelo y a una reducción en el tiempo de entrenamiento.
- 4) Normalización de la apariencia de las imágenes: En ocasiones, las imágenes utilizadas para entrenar modelos de clasificación pueden tener diferentes niveles de iluminación, contraste o condiciones de captura. Al aplicar el filtro Canny, se puede normalizar la apariencia de las imágenes, lo que ayuda a que el modelo se vuelva más robusto frente a estas variaciones y mejora la generalización del modelo a nuevas imágenes.

En resumen, el uso del filtro Canny de OpenCV en el preprocesamiento de imágenes para el entrenamiento de modelos de clasificación en cascada puede mejorar la detección de bordes, reducir el ruido, disminuir la dimensionalidad de los datos y normalizar la apariencia de las imágenes. Estas ventajas pueden conducir a un mejor rendimiento del modelo y una mayor capacidad de generalización.

Según las indicaciones del programa, para un correcto entrenamiento son necesarias miles de imágenes positivas, aunque es posible conseguir los mismos objetivos con un tamaño de muestra mucho menor si se tratan de figuras simples.

Un aspecto que permite el uso de una colección o *dataset* (de imágenes) de tamaño reducido, es la variabilidad de las condiciones de toma. Es decir, si se toman imágenes en diferentes condiciones de iluminación, o desde diferentes ángulos, serán necesarias menos imágenes en la colección para obtener resultados correctos, reduciéndose la posibilidad de falsos positivos o de errores en la detección.

Además, con el objetivo de reducir el esfuerzo computacional, se recomienda el uso de imágenes de tamaño reducido. Para ello será necesario redimensionar las imágenes antes de almacenarlas en la carpeta de los positivos. Con el objetivo de no perder las proporciones, sólo se modificará la altura de estas imágenes, manteniéndose la ratio altura-anchura.

La figura 60, representa esquemáticamente lo recién descrito, pues son pequeñas imágenes donde se puede apreciar claramente el objeto que se desea detectar.




Figura 60. Biblioteca de imágenes positivas, donde se puede percibir la curvatura característica de los bordes de calzada en las entradas a las glorietas.

Además, se requerirá almacenar un número adecuado de imágenes negativas en un directorio designado. En esta perspectiva, las imágenes negativas se definen como aquellas en las cuales no sea viable observar el conjunto de marcas viales previamente delineado.

Según las orientaciones brindadas por el programa, para un entrenamiento efectivo, se necesitan miles de imágenes negativas, aunque se podría alcanzar los mismos objetivos utilizando un tamaño de muestra considerablemente menor si el objeto a detectar tuviera una estructura simple.

Para un entrenamiento preciso del modelo, son fundamentales dos aspectos esenciales:

- 1) Es vital que en ningún caso aparezcan imágenes positivas en la carpeta de imágenes negativas, ni que el objeto que se desea detectar surja en ninguna de ellas, incluso si es parcialmente. Esto impactaría significativamente la eficacia del modelo.
- 2) A pesar de que, en teoría, las imágenes negativas podrían abarcar cualquier imagen donde el objeto a detectar no esté presente, se sugiere que estén vinculadas. En el caso de la detección de las marcas viales de la isleta central de la rotonda y la marca vial de la entrada de la rotonda, será más ventajoso emplear imágenes que compartan elementos comunes, para que la característica distintiva adquiera mayor relevancia. Un ejemplo sería el uso de imágenes que muestren salidas de rotondas, además de otras imágenes de carreteras.



Figura 61. Curvatura característica de los bordes de clazada en la salida de una glorieta.

En el caso de las imágenes de salida de rotonda, la principal diferencia con las imágenes de entrada es que se pueden observar dos líneas curvas, correspondientes a las marcas viales de la isleta central de la rotonda y a la unión de la marca vial del anillo exterior de la rotonda y la marca vial del borde derecho del carril de salida. Esto se traduce en dos líneas curvas con gran curvatura, una hacia la izquierda y otra a la derecha, a diferencia de las imágenes positivas, donde una de las líneas era prácticamente recta y horizontal.



Figura 62. Curvatura característica de los bordes de clazada en la salida de una glorieta. Imagen tratada.

Al igual que antes, se aplicará el filtro Canny para almacenar de esta manera imágenes negativas más simples. Además, al igual que para el caso de las imágenes positivas, resulta más práctico emplear un mayor número de imágenes pequeñas que un número más reducido de imágenes. Para ello, se reducirá el tamaño de estas imágenes modificándolas, de manera que se iguale su altura, pero sin que se produzcan distorsiones.

La figura 63, representa esquemáticamente lo recién descrito, pues son pequeñas imágenes donde se puede apreciar el entorno en el cual podrían aparecer esas marcas viales propias de las entradas de rotonda, pero sin que aparezcan éstas.




Figura 63. Biblioteca de imágenes negativass, donde se puede percibir la curvatura característica de los bordes de calzada en las entradas a las glorietas.

A partir de estas fuentes de datos se obtiene como salida (resultado) un modelo de cascada en formato XML.

d) Proceso de detección vehículos de cara

Con el objetivo de habilitar la detección de objetos, el proceso inicial conlleva el entrenamiento de un modelo con el objetivo de producir resultados precisos, realizando una correcta clasificación de las imágenes que ingresan.

Para este propósito, se empleará el software Cascade Trainer GUI. El primer paso en esta secuencia implicará la acumulación de un volumen adecuado de imágenes positivas en un directorio específico. En este contexto, las imágenes positivas son aquellas en las que es posible identificar vehículos orientados frontalmente en las entradas de las rotondas.

De acuerdo con las directrices proporcionadas por el programa, para un entrenamiento preciso se requieren miles de imágenes positivas. Sin embargo, es viable lograr los mismos resultados con una muestra considerablemente menor si se trata de figuras geométricas simples.

Un aspecto habilitante para el uso de conjuntos de datos o *datasets* de pequeña envergadura en el contexto de imágenes se debe a la variabilidad inherente en las condiciones de captura. Concretamente, cuando las imágenes son capturadas bajo diferentes condiciones de iluminación o desde distintos ángulos, se reduce la cantidad requerida de imágenes en el conjunto para obtener resultados precisos, disminuyendo así la probabilidad de errores en la detección o de falsos positivos.

Adicionalmente, con el propósito de aligerar la carga computacional, se sugiere el uso de imágenes de dimensiones reducidas. Para lograrlo, se vuelve necesario redimensionar las imágenes antes de almacenarlas en el directorio de imágenes positivas. Con el fin de preservar las proporciones originales, solo se modificará la dimensión de altura de estas imágenes, manteniendo constante la relación de aspecto entre la altura y el ancho.

La Figura 64 es una representación esquemática que ilustra lo previamente explicado, mostrando imágenes pequeñas donde el objeto que se busca detectar es claramente visible.



Figura 64. Biblioteca de imágenes positivas, donde se pueden percibir vehículos en las entradas a las glorietas.

Adicionalmente, será esencial almacenar un volumen adecuado de imágenes negativas en un directorio específico. En este contexto, las imágenes negativas se definen como aquellas en las que no se puede observar la presencia de vehículos orientados de frente.

Siguiendo las instrucciones del programa, para lograr un entrenamiento efectivo se requieren miles de imágenes negativas. No obstante, es factible alcanzar los mismos objetivos con un conjunto de muestras considerablemente menor si el objeto a detectar adoptara una forma geométrica simple.

Para un entrenamiento preciso del modelo, dos aspectos resultan fundamentales:

- 1) Es de imperiosa importancia que no se incluyan imágenes positivas en el directorio de imágenes negativas, ni que el objeto que se pretende detectar aparezca en ninguna de ellas, aunque sea en forma parcial. Esto afectaría gravemente la eficacia del modelo.
- 2) A pesar de que, en teoría, las imágenes negativas podrían ser cualquier imagen en la que el objeto que se desea detectar no esté presente, se recomienda que tengan alguna relación contextual. Si la detección se centra en vehículos orientados de frente en las entradas de las rotondas, será más ventajoso emplear imágenes que muestren vehículos que salen de rotondas, o especialmente vehículos observados desde atrás en las salidas de la rotonda, en lugar de imágenes sin ninguna relación con el objetivo, como imágenes de animales o aviones. El propósito es que el modelo aprenda a no

atribuir relevancia a las formas o elementos presentes en ambas categorías de imágenes, lo que permitirá diferenciar las dos categorías con mayor eficacia.

De manera similar al enfoque para las imágenes positivas, resulta más práctico utilizar un conjunto mayor de imágenes de pequeñas dimensiones en lugar de uno más reducido. Para lograr esto, se modificará el tamaño de estas imágenes, igualando sus alturas, pero sin inducir distorsiones.

La Figura 65 es una representación esquemática que ilustra lo recién explicado, mostrando imágenes pequeñas que reflejan el entorno donde podrían aparecer las marcas viales características de las salidas de las rotondas, aunque dichas marcas no estén presentes en las imágenes.

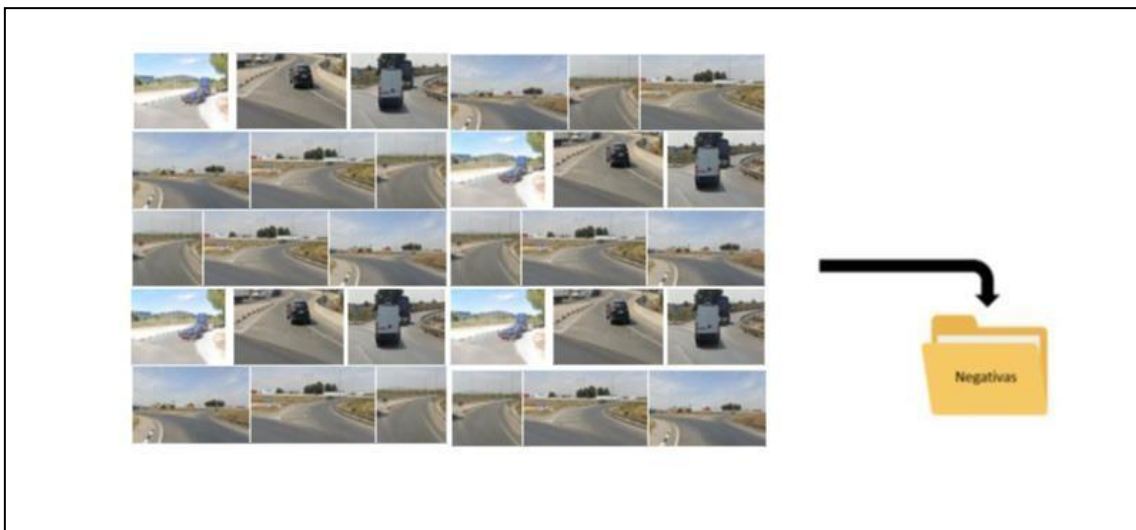


Figura 65. Biblioteca de imágenes negativas, donde no se pueden percibir vehículos de cara en las entradas a las glorietas.

A partir de estas fuentes de datos se obtiene como salida (resultado) un modelo decascada en formato XML.

4.3.4. Detección de señales de entrada prohibida

Una vez creados los modelos entrenados de clasificación en cascada, será necesario seguir el proceso siguiente para clasificar las imágenes y almacenar todas aquellas imágenes en las que se pueda apreciar un carril de entrada a las rotondas.

El proceso se describe a continuación:

1. Importa las bibliotecas necesarias:

```
import cv2
```

```
import os
```


2. Definición la función para detectar y almacenar la imagen en la carpeta correspondiente:

```
def detectar_y_almacenar(imagen, modelos, carpeta_destino):#
    Leer la imagen
    img = cv2.imread(imagen)

    # Convertir a escala de grises
    gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)

    # Aplicar filtro Canny para el modelo descrito en el punto 3.3.3
    canny = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)

    # Iterar sobre los modelos entrenados
    for modelo in modelos:
        # Cargar el modelo
        cascade = cv2.CascadeClassifier(modelo)

        # Detectar objetos en la imagen
        objetos = cascade.detectMultiScale(gray, scaleFactor=1.1,
            minNeighbors=5, minSize=(30, 30))

        objetos = cascade.detectMultiScale(canny, scaleFactor=1.1,
            minNeighbors=5, minSize=(30, 30))

        # Crear la carpeta de destino si no existe
        if not os.path.exists(carpeta_destino):
            os.makedirs(carpeta_destino)

        # Almacenar las imágenes detectadas en la carpeta correspondiente
        for (x, y, w, h) in objetos:
            nombre_archivo = os.path.join(carpeta_destino,
                'entrada_rotonda_{ }.jpg'.format(len(os.listdir(carpeta_destino))))
            cv2.imwrite(nombre_archivo, img[y:y+h, x:x+w])
```

3. Especificación de la imagen que se desea analizar, los modelos entrenados y la carpeta de destino:

```
imagen = 'ruta/a/la/imagen.jpg'  
  
modelos = ['modelo1.xml', 'modelo2.xml', 'modelo3.xml',  
'modelo4.xml']  
  
carpeta_destino = 'ruta/a/la/carpeta/destino'
```

4. Llamar a la función detectar_y almacenar con los parámetros adecuados:

```
detectar_y almacenar(imagen, modelos, carpeta_destino)
```

Es importante asegurarse de reemplazar 'ruta/a/la/imagen.jpg', 'modelo1.xml', 'modelo2.xml', 'modelo3.xml', 'ruta/a/la/carpeta/destino' con las rutas y nombres de archivo correctos en el sistema en el que se ejecute la función.

Este código cargará cada modelo entrenado en cascada, detectará objetos en la imagen y almacenará las regiones detectadas en la carpeta de destino correspondiente. Cada imagen almacenada se nombrará como "entrada_rotonda_x.jpg", donde "x" es un número único que incrementa cada vez que se almacena una imagen.

Una vez seleccionadas las imágenes de los carriles de entrada a la rotonda desde el interior de la glorieta se procederá a analizar la presencia de señales de prohibición de paso. En numerosas ocasiones, dichas señales no están implantadas, y en muchas otras, aunque estén presentes, su orientación no permite distinguir las desde un vehículo circulando por la glorieta en sentido normal (antihorario)



Figura 66. Señal R-101 de entrada prohibida, correctamente colocada en el carril de acceso a la glorieta




Figura 68. Señal R-101 de entrada prohibida ausente en el carril de acceso a la glorieta




Figura 67. Señal R-101 de dirección no visible desde el interior de la glorieta, al estar mal orientada

En consecuencia, el propósito fundamental radica en capacitar un modelo para categorizar un conjunto de imágenes en dos clases distintas: las positivas, que contienen la señal de entrada prohibida, y las negativas, en las que dicha señal no es claramente visible.

Este cometido se llevará a cabo mediante el empleo de la herramienta Cascade Trainer GUI.

La fase primordial consistirá en acumular un conjunto suficiente de imágenes positivas en una carpeta designada. En esta perspectiva, se definirán las imágenes positivas como aquellas que permitan la visualización de la señal de entrada prohibida.

Siguiendo las orientaciones proporcionadas por el programa, un entrenamiento exitoso requiere de miles de imágenes positivas. No obstante, se puede lograr los mismos resultados con una muestra de dimensiones considerablemente menores si se trata de formas geométricas simples.

Un elemento habilitante en la utilización de conjuntos de datos de pequeña escala en el ámbito de imágenes se asocia a la variabilidad en las condiciones de captura. Concretamente, cuando las imágenes son capturadas bajo distintas condiciones de iluminación o desde diversos

ángulos, se reduce la cantidad requerida de imágenes en el conjunto para obtener resultados precisos, disminuyendo así la probabilidad de errores en la detección o falsos positivos.

Además, con el fin de reducir la carga computacional, se sugiere utilizar imágenes de dimensiones reducidas. Con tal fin, es necesario ajustar las dimensiones de las imágenes antes de almacenarlas en el directorio de imágenes positivas. Para mantener la relación de aspecto, solo se modificará la dimensión de altura de estas imágenes, manteniendo constante la proporción entre la altura y el ancho.

La figura 69 representa de forma esquemática lo recién mencionado, al mostrar imágenes de pequeñas dimensiones en las que el objeto a detectar es claramente perceptible. Las bibliotecas de imágenes para el entrenamiento se pueden consultar en el Anexo I.

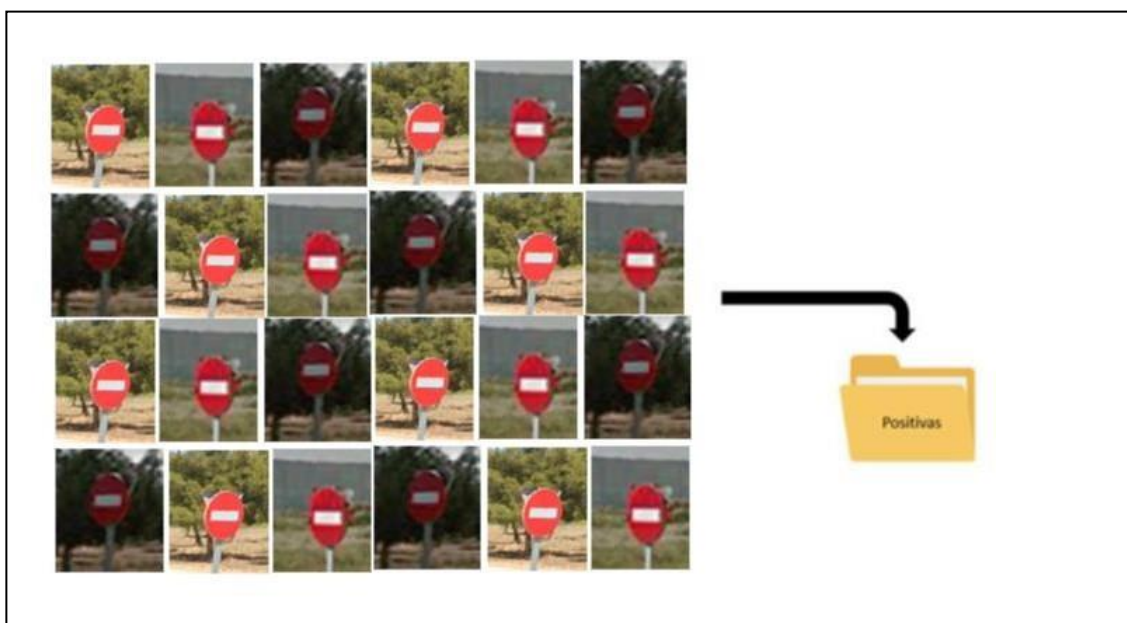


Figura 69. Biblioteca de imágenes positivas, donde aparece la señal R-101

Adicionalmente, será esencial almacenar una cantidad suficiente de imágenes negativas en una carpeta designada. En este contexto, las imágenes negativas se definen como aquellas en las que no es posible observar la mencionada señal.

Conforme a las instrucciones proporcionadas por el programa, para un entrenamiento preciso se requieren miles de imágenes negativas. Sin embargo, se puede lograr los mismos resultados con una muestra notablemente más pequeña si el objeto a detectar adopta una forma geométrica sencilla.

Para lograr un entrenamiento preciso del modelo, dos aspectos resultan cruciales:

- 1) Es imperativo que en ningún caso aparezcan imágenes positivas en la carpeta de imágenes negativas, ni que el objeto que se pretende detectar esté presente en ninguna de ellas, incluso si es solo de manera parcial. Esto tendría un impacto sumamente negativo en la eficacia del modelo.

- 2) Aunque en teoría, las imágenes negativas podrían ser cualquier imagen en la que no aparezca el objeto que se pretende detectar, se aconseja que estas estén relacionadas contextualmente. Si el objetivo es detectar señales de prohibido el paso, será más beneficioso emplear imágenes donde se muestren otras señales de tráfico, o imágenes de entradas de rotondas donde no esté presente la mencionada señal, en lugar de otro tipo de imágenes como las de animales o aviones. El propósito es que el modelo aprenda a no atribuir importancia a las formas o elementos presentes en ambas categorías de imágenes, lo que permitirá diferenciar de manera más efectiva las dos categorías de imágenes.

De manera similar a las imágenes positivas, es más práctico utilizar un conjunto mayor de imágenes de dimensiones reducidas en lugar de uno más pequeño. Para ello, se modificará el tamaño de estas imágenes, igualando sus alturas, pero evitando cualquier distorsión.

La figura 70 es una representación esquemática que ilustra lo anteriormente explicado, mostrando imágenes pequeñas que reflejan el entorno donde podrían aparecer las señales R-101, aunque no estén presentes en las imágenes. Las bibliotecas de imágenes para el entrenamiento se pueden consultar en el Anexo I.



Figura 70. Biblioteca de imágenes negativas, donde no aparece la señal R-101

A partir de estas fuentes de datos se obtiene como salida (resultado) un modelo de cascada en formato XML.

Para importar un modelo entrenado de clasificación en cascada que permita detectar señales de tráfico de limitación de velocidad en OpenCV, puedes seguir los siguientes pasos:

- 1) Descargar el archivo XML del modelo entrenado de clasificación en cascada para la detección de señales de tráfico de límite de velocidad.

- 2) Importa las bibliotecas necesarias:

```
import cv2
import os
```

- 3) Cargar el modelo entrenado en cascada:

```
modelo = 'ruta/al/modelo.xml' # Ruta al archivo XML del modelo
entrenado
cascade = cv2.CascadeClassifier(modelo)
```

Asegurarse de reemplazar 'ruta/al/modelo.xml' con la ruta y el nombre de archivo correctos en el sistema desde el cual se ejecute el código..

- 4) Leer la imagen que desee analizar:

```
imagen = 'ruta/a/la/imagen.jpg' # Ruta a la imagen que deseas analizar
img = cv2.imread(imagen)
```

Asegurarse de reemplazar 'ruta/a/la/imagen.jpg' con la ruta y el nombre de archivo correctos en el sistema desde el cual se ejecute el código..

- 5) Convertir la imagen a escala de grises:

```
gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
```

- 6) Detectar las señales de tráfico de límite de velocidad en la imagen:

```
limitacion_velocidad = cascade.detectMultiScale(gray, scaleFactor=1.1,
minNeighbors=5, minSize=(30, 30))
```

Se pueden ajustar los parámetros `scaleFactor`, `minNeighbors` y `minSize` según las necesidades.

- 7) Verificación de si se ha detectado alguna señal de tráfico de límite de velocidad y almacenamiento de la imagen en una carpeta correspondiente:

```
if len(limitacion_velocidad) == 0:
```

```

carpeta_destino = 'ruta/a/la/carpeta/destino' # Ruta a la carpeta de destino
si no se detecta ninguna señal

if not os.path.exists(carpeta_destino):
    os.makedirs(carpeta_destino)

nombre_archivo=os.path.join(carpeta_destino,'imagen_no_detectada.jpg')

cv2.imwrite(nombre_archivo, img)

```

Es primordial asegurarse de reemplazar 'ruta/a/la/carpeta/destino' con la ruta y el nombre de carpeta correctos en el sistema desde el que se ejecute el código.

Este código cargará el modelo entrenado en cascada, detectará las señales de tráfico de límite de velocidad en la imagen y, si no se detecta ninguna señal, almacenará la imagen en la carpeta de destino especificada. El archivo de imagen se guardará como "imagen_no_detectada.jpg" en la carpeta de destino.

5. Aplicación práctica. Estudio de seguridad vial

Finalmente, después de haber delineado la metodología, se procederá a su aplicación con el fin de detectar de manera automatizada los problemas previamente mencionados en la carretera autonómica CV-31. En cuanto a las barreras metálicas mal orientadas y la ausencia de señalización en las glorietas, el proceso es automatizado. Sin embargo, es crucial subrayar que la detección automatizada de la altura de las barreras metálicas no siempre será factible, por lo que se requerirá una evaluación in situ en la carretera para medir su altura y, de esta manera, recopilar información de todos los tramos que requerirán intervención. Esto permitirá completar el análisis de seguridad vial de manera exhaustiva.

En la ejecución práctica, se delimitará con precisión el alcance del estudio, se llevará a cabo la identificación de los problemas y se propondrán soluciones concomitantes, además de estimar el presupuesto necesario para llevar a cabo dichas intervenciones.

5.1. Ámbito de estudio

La carretera CV-31 (Distribuidor Comarcal Norte) pertenece a la Red autonómica de carreteras de la Comunidad Valenciana, comunica la Ronda Norte de Valencia con la Autovía de Ademuz por la Feria de Muestras de Valencia.

La CV-31 inicia su recorrido en el enlace con la CV-30 (Ronda Norte de Valencia). Discurre como circunvalación entre Paterna y la Feria de Muestras de Valencia. También tiene acceso al Velódromo Luís Puig. Después, enlaza con la CV-365. Su itinerario continúa hasta enlazar con la CV-35 Autovía del Túria o de Ademuz. A continuación, finaliza su recorrido como autovía y pasa a ser carretera convencional con la denominación CV-310. Pasa cerca de las

poblaciones de Godella y Rocafort. Después, enlaza con la A-7 en su tramo por el By-pass de Valencia. Por último, llega hasta la población de Bétera.



Figura 71. Vista en planta de la carretera estudiada

En cuanto al trazado en planta, se puede decir que se trata de una carretera con pocas curvas hasta el PK 2+500, punto a partir del cual se puede observar una sucesión de tres curvas, aunque sus radios son amplios.

En el sentido creciente, la limitación de velocidad se establece en 80 km/h en todo el tronco, hasta el PK 3+580, punto a partir del cual se establece el límite en 60 km/h hasta terminar la carretera.



Figura 72. Limitación de velocidad de 80 km/h en el PK 0+510 en sentido ascendente.



Figura 73. Limitación de velocidad de 60 km/h en el PK 3+580 en sentido ascendente.

En el otro sentido ocurre lo mismo, es decir, existe un primer subtramo donde la velocidad se limita a 60 km/h (hasta el PK 3+520), y un segundo subtramo donde el límite de velocidad es de 80 km/h.



Figura 74. Limitación de velocidad de 60 km/h en el PK 4+120 en sentido descendente.



Figura 75. Limitación de velocidad de 80 km/h en el PK 3+520 en sentido descendente.

Asimismo, en las siguientes figuras se puede observar la ubicación de todas las señales de limitación de velocidad que afectan al tronco de la CV-31.

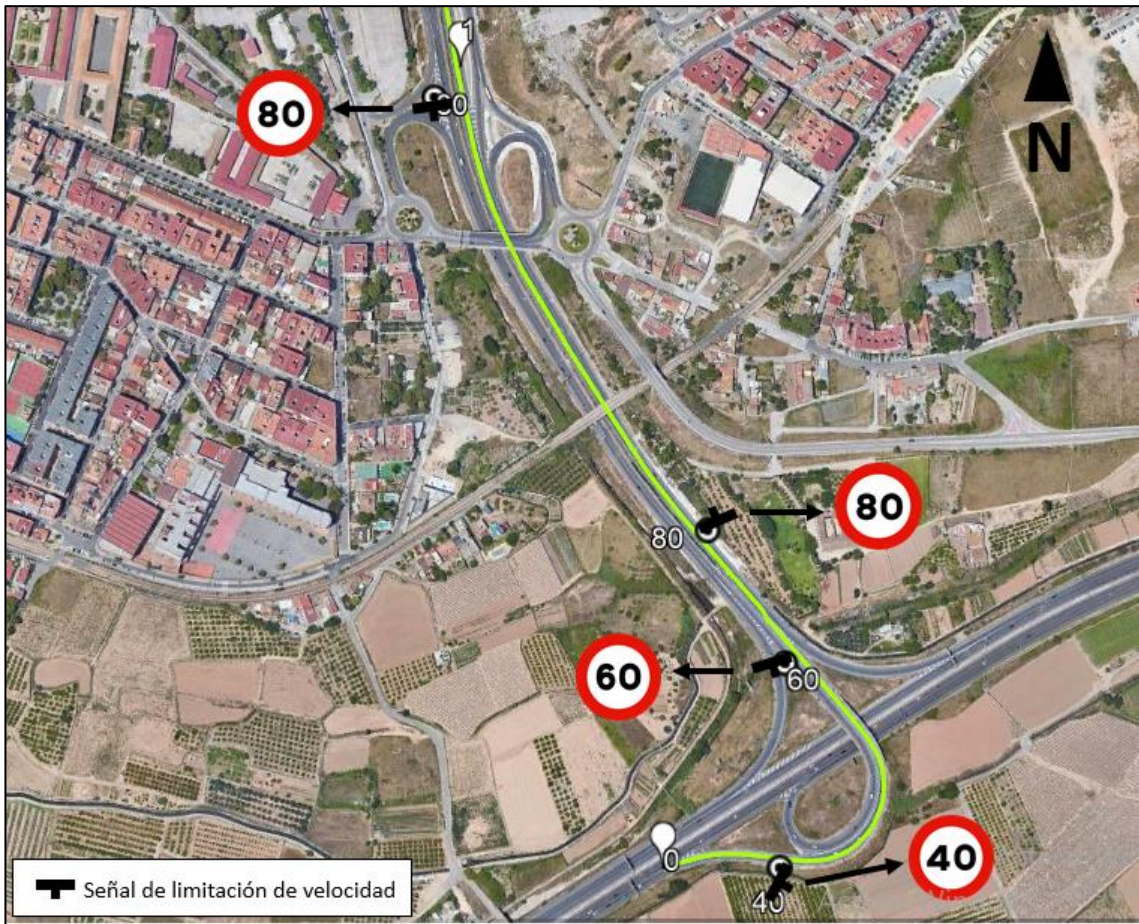


Figura 76. Limitaciones de velocidad en la CV-31 entre los PPKK 0+000 y 1+000



Figura 77. Limitaciones de velocidad en la CV-31 entre los PPKK 1+000 y 2+000




Figura 78. Limitaciones de velocidad en la CV-31 entre los PPKK 2+000 y 3+000

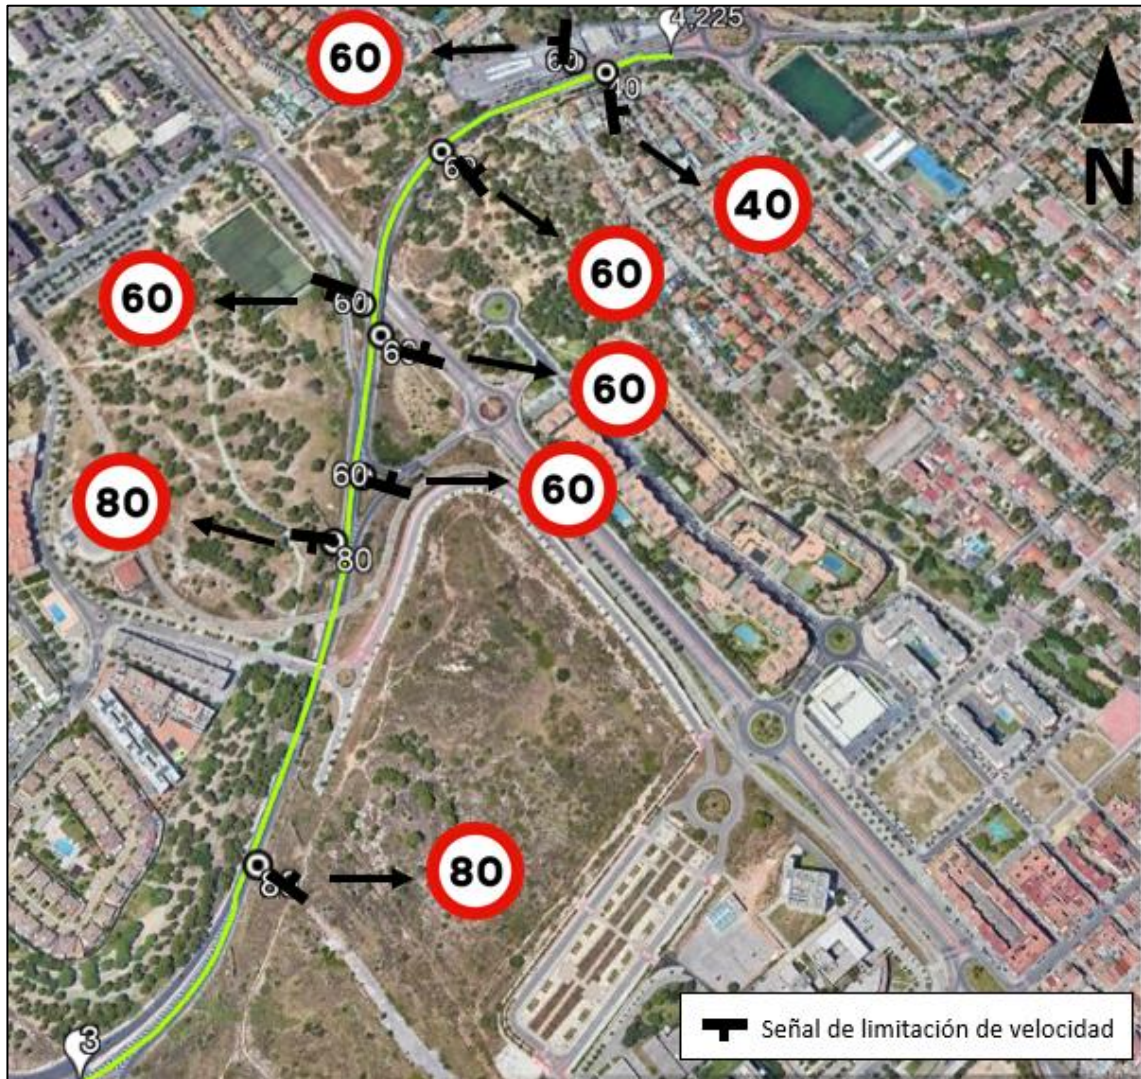


Figura 79. Limitaciones de velocidad en la CV-31 entre los PPKK 3+000 y 4+300

La sección tipo de la carretera consiste en una calzada de 2 carriles por sentido, estando separados los sentidos de circulación por una mediana de ancho variable, limitada por barreras de hormigón New Jersey.

La anchura de los carriles es de 3,60 metros, la de los arcenes exteriores de comprendida entre 1,50 metros y 2,50 metros, y la de los arcenes interiores de 1,50 metros.

No obstante, son numerosos los subtramos en los que hay carriles adicionales, sean de salida o de incorporación al tronco, e incluso los tramos en los cuales la sección de la carretera no se corresponde con la sección tipo. Atendiendo a la sección transversal se distinguen los siguientes subtramos:

- 1) PK 0+000 a PK 0+400: Enlace con CV-30. En este subtramo, solo existe un carril por sentido, estando estos separados por una barrera de hormigón New Jersey.



Figura 80. Fotografía de la sección transversal de la carretera en el PK 0+200

2) PK 0+400 a PK 0+725: Tronco 1. Sección tipo.



Figura 81. Fotografía de la sección transversal de la carretera en el PK 0+500

3) PK 0+725 a PK 0+925: Enlace con Paterna/Benimamet. Sección tipo, con un carril adicional de entrada/salida en cada sentido.



Figura 82. Fotografía de la sección transversal de la carretera en el PK 0+780

4) PK 0+925 a PK 1+175: Tronco 2. Sección tipo.



Figura 83. Fotografía de la sección transversal de la carretera en el PK 1+020

- 5) PK 1+175 a PK 1+375: Enlace Feria de Muestras/Burjassot/Terramelar. Sección tipo, con un carril adicional de entrada/salida en cada sentido.



Figura 84. Fotografía de la sección transversal de la carretera en el PK 1+280

- 6) PK 1+375 a PK 1+900: Tronco 3. Sección tipo, aunque a partir del PK 1+800 cada uno de los sentidos discurre por una plataforma diferente.



Figura 85. Fotografía de la sección transversal de la carretera en el PK 1+740

- 7) PK 1+900 a PK 2+300: Enlace con CV-365. Sección tipo, pero con un carril adicional de entrada/salida en cada sentido, y cada uno de los sentidos discurre por una plataforma diferente.



Figura 86. Fotografía de la sección transversal de la carretera en el PK 2+080, sentido ascendente



Figura 87. Fotografía de la sección transversal de la carretera en el PK 2+120, sentido descendente

- 8) PK 2+300 a PK 2+750: Tronco 4. Sección tipo, pero cada uno de los sentidos discurre por una plataforma diferente.



Figura 88. Fotografía de la sección transversal de la carretera en el PK 2+450, sentido ascendente



Figura 89. Fotografía de la sección transversal de la carretera en el PK 2+450, sentido descendente

- 9) PK 2+750 a PK 3+200: Enlace CV-35. Sección tipo, con un carril adicional de entrada/salida en cada sentido.



Figura 90. Fotografía de la sección transversal de la carretera en el PK 2+850, sentido ascendente



Figura 91. Fotografía de la sección transversal de la carretera en el PK 2+750, sentido descendente

- 10) PK 3+200 a PK 3+500: Tronco 5. Sección formada por una calzada única, de un único carril

de 3,60 metros por sentido, estando separados los sentidos por una línea continua. Los arcenes exteriores son de 2,40 metros



Figura 92. Fotografía de la sección transversal de la carretera en el PK 3+400.

11) PK 3+500 a PK 3+700: Enlace CV-3103. Sección formada por una calzada única, de un único carril de 3,60 metros por sentido, estando separados los sentidos por una línea continua. Los arcenes exteriores son de 2,40 metros. Existe un carril adicional de entrada/salida en cada sentido.



Figura 93. Fotografía de la sección transversal de la carretera en el PK 3+550.

12) PK 3+700 a PK 4+300: Tronco 6. Sección formada por una calzada única, de un único carril de 3,60 metros por sentido, estando separados los sentidos por una línea continua. Los arcenes exteriores son de 2,40 metros



Figura 94. Fotografía de la sección transversal de la carretera en el PK 4+100.

5.2. Problemáticas detectadas y medidas propuestas

Tal y como se ha ido mencionando a lo largo de anteriores capítulos, será necesario evaluar o inspeccionar los elementos que son objeto de estudio, detectando así las diferentes deficiencias existentes.

Siempre y cuando sea posible, se aplicará la metodología descrita en el apartado 4, para que se detecten las deficiencias de manera automatizada.

Sin embargo, en algunos casos no será posible hacerlo conforme a la metodología, por lo que se evaluará in situ.

A continuación, se resumirá la metodología descrita en el apartado 4, y se mostrarán los resultados de la inspección, detectando los problemas, ubicándolos geográficamente y proponiendo medidas para su subsanación.

5.2.1. Orientación incorrecta de las barreras metálicas

La metodología propuesta consistiría en recopilar imágenes, tratarlas mediante visión artificial con el objetivo de obtener imágenes más simplificadas de manera que puedan aplicarse las técnicas de *machine learning*. Estas técnicas permitirían detectarse similitudes entre las imágenes recopiladas y las imágenes de comparación. Estas últimas imágenes serán imágenes tratadas de la misma manera que las recopiladas, en las que se sabe de antemano que se da el problema que se pretende identificar. De esta manera se podrían detectar aquellas imágenes en las que se puede percibir la cara dorsal de las barreras de seguridad.

De manera resumida, el procedimiento consistirá en:

- 1) Recopilación de imágenes.
- 2) Tratamiento previo de las imágenes recopiladas, de manera que sean simplificadas mediante el filtro *Canny*.
- 3) Detección de barreras metálicas que orientan hacia la carretera su cara posterior mediante un algoritmo de clasificación en cascada, consistente en la recopilación de imágenes positivas (en las que se pueden percibir características propias de las caras dorsales de las barreras metálicas) y negativas, y en su comparación con las imágenes que se desean analizar.
- 4) Obtención de las imágenes resultantes tras pasar por el el programa que se ha creado para este propósito.

A continuación, se mostrarán los resultados de la inspección, detectando los problemas, ubicándolos geográficamente y proponiendo medidas para su subsanación.

Tabla 1. Ficha: Barrera metálica mal orientada entre los PPKK 1+975 y PK 1+950

1) CV-31 (Sentido decreciente): Del PK 1+975 al PK 1+950	
Coordenadas iniciales	39°30'29,82" N 0°26'0,99" O
Coordenadas finales	39°30'27,02" N 0°25'59,17" O
Concepto	Defensas y barreras
Problemática detectada	Cara dorsal de la barrera metálica orientada hacia la carretera
Detectado de manera automatizada	SI
Medida propuesta	Instalación de barrera de seguridad metálica BMS-NA4 incluyendo terminales abatidas de 4,32 metros en ambos extremos de la barrera.



Figura 95. Deficiencia detectada tras la evaluación de la imagen en OpenCV. PK 1+950. Recorte obtenido a partir de la imagen de salida proporcionada por OpenCV.




Figura 96. Elemento característico de la cara dorsal de las barreras metálicas, detectado en la imagen tratada. PK 1+950.



Figura 97. Ubicación de la deficiencia y solución propuesta. Vista en planta

Tabla 2. Ficha: Barrera metálica mal orientada entre los PPKK 1+755 y PK 1+780

2) CV-31 (Sentido creciente): Del PK 1+755 al PK 1+780	
Coordenadas iniciales	39°30'22,90" N 0°25'57,86" O
Coordenadas finales	39°30'21,29" N 0°25'55,81" O
Concepto	Defensas y barreras
Problemática detectada	Cara dorsal de la barrera metálica orientada hacia la carretera
Detectado de manera automatizada	SI
Medida propuesta	Instalación de barrera de seguridad metálica BMS-NA4 incluyendo terminales abatidas de 4,32 metros en ambos extremos de la barrera.



Figura 98. Deficiencia detectada tras la evaluación de la imagen en OpenCV. PK 1+780. Recorte obtenido a partir de la imagen de salida proporcionada por OpenCV.



Figura 99. Elemento característico de la cara dorsal de las barreras metálicas, detectado en la imagen tratada. PK 1+780.



Figura 26. Ubicación de la deficiencia y solución propuesta. Vista en planta. PK 1+780.

Tabla 3. Ficha: Barrera metálica mal orientada entre los PPKK 1+190 y 1+295

3) CV-31 (Sentido creciente): Del PK 1+190 al PK 1+295	
Coordenadas iniciales	39°30'04,01" N 0°25'48,33" O
Coordenadas finales	39°30'07,36" N 0°25'49,36" O
Concepto	Defensas y barreras
Problemática detectada	Cara dorsal de la barrera metálica orientada hacia la carretera
Detectado de manera automatizada	SI
Medida propuesta	Medida propuesta: Instalación de barrera de seguridad metálica BMS-NA4 incluyendo terminales abatidas de 4,32 metros en ambos extremos de la barrera. La barrera metálica se instalará pasados los bordillos en el PK 1+190 y se prolongará hasta la sección donde la diferencia de cota entre la cara dorsal detectada y la rasante de la carretera sea significativa, en el PK 1+295



Figura 100. Deficiencia detectada tras la evaluación de la imagen en OpenCV. PK 1+190. Recorte obtenido a partir de la imagen de salida proporcionada por OpenCV.



Figura 101. Elemento característico de la cara dorsal de las barreras metálicas , detectado en la imagen tratada. PK 1+190.



Figura 102. Deficiencia detectada tras la evaluación de la imagen en OpenCV. PK 1+295. Recorte obtenido a partir de la imagen de salida proporcionada por OpenCV.



Figura 103. Elemento característico de la cara dorsal de las barreras metálicas , detectado en la imagen tratada. PK 1+295.



Figura 104. Ubicación de la deficiencia y solución propuesta. Vista en planta. PK 1+190 a 1+295

Tabla 4. Ficha: Barrera metálica mal orientada entre los PPKK 1+370 y 1+345

4) CV-31 (Sentido decreciente): Del PK 1+370 al PK 1+345	
Coordenadas iniciales	39°30'11,50" N 0°25'55,32" O
Coordenadas finales	39°30'09,14" N 0°25'51,40" O
Concepto	Defensas y barreras
Problemática detectada	Cara dorsal de la barrera metálica orientada hacia la carretera
Detectado de manera automatizada	SI
Medida propuesta	Instalación de barrera de seguridad metálica BMS-NA4 incluyendo terminales abatidas de 4,32 metros en ambos extremos de la barrera.



Figura 105. Deficiencia detectada tras la evaluación de la imagen en OpenCV. PK 1+345. Recorte obtenido a partir de la imagen de salida proporcionada por OpenCV.




Figura 106. Elemento característico de la cara dorsal de las barreras metálicas, detectado en la imagen tratada. PK 1+345.



Figura 107. Ubicación de la deficiencia y solución propuesta. Vista en planta. PK 1+345

En cuanto a los resultados obtenidos, se pueden afirmar que la detección de las barreras metálicas mal orientadas ha sido un éxito total. En el 100% de los casos, el modelo en cascada entrenado y el código desarrollado han sido capaces de detectar esta problemática.

5.2.2. Altura insuficiente de las barreras metálicas

La metodología propuesta, al igual que en la sección anterior, consistiría en recopilar imágenes, tratarlas mediante visión artificial con el objetivo de obtener imágenes más simplificadas de manera que puedan detectarse los postes de las barreras metálicas mediante técnicas de *machine learning* y *deep learning* y ser estimada su altura. No obstante, cabe recalcar que, para proceder de esta manera, será necesario conocer previamente la dimensión de algún objeto situado en el mismo plano vertical (y además paralelo al eje de la carretera), con el fin de evitar problemas en la estimación debidos a la perspectiva. Por lo tanto, el problema principal consistiría en encontrar algún elemento fiable, que cumpla las condiciones recién mencionadas que se pudiera tomar como elemento de referencia. Uno de estos elementos podría ser un hito de arista, cuyas medidas y dimensiones de sus partes están homologadas.

De manera resumida, el procedimiento consistirá en:

- 1) Recopilación de imágenes.

- 2) Tratamiento previo de las imágenes recopiladas
- 3) Detección del elemento de referencia (franja negra de los hitos de arista)
- 4) Establecimiento del factor de conversión (equivalencia píxeles-centímetros)
- 5) Detección de las zonas de las barreras metálicas con postes
- 6) Estimación de la altura de las barreras metálicas
- 7) Obtención de las imágenes resultantes tras pasar por el el programa que se ha creado para este propósito.

Sin embargo, no en todos los tramos de la carretera será posible aplicar dicha metodología, pues existen tramos de la carretera donde hay barrera metálica, pero sin hitos de arista cuyos dibujos se puedan tomar como elemento de referencia. Por lo tanto, en esos tramos se medirán las alturas manualmente, con el objetivo de detectar todas las deficiencias de este tipo en la CV-31.

A continuación, se mostrarán los resultados de la inspección, detectando los problemas, ubicándolos geográficamente y proponiendo medidas para su subsanación.

Tabla 5. Ficha: Barrera metálica de altura insuficiente, del PK 0+550 al PK 0+750

1) CV-31 (Sentido creciente): Del PK 0+550 al PK 0+750	
Coordenadas iniciales	39°29'44,15" N 0°25'37,35" O
Coordenadas finales	39°29'50,59" N 0°25'43,26" O
Concepto	Defensas y barreras
Problemática detectada	Barrera metálica de altura insuficiente
Detectado de manera automatizada	SI
Medida propuesta	Desmontaje de las barreras existentes incluidos los postes e instalación de barrera de seguridad metálica BMS-NA4 incluyendo los solapes con los tramos de barrera contiguos, garantizando una altura de 75 centímetros sobre el pavimento.



Figura 108. Altura de la barrera de metálica suficiente en el PK 0+550 en sentido ascendente. (80cm)



Figura 109. Altura de la barrera metálica insuficiente. PK 0+600 en sentido ascendente.



Figura 110. Altura de la barrera metálica insuficiente. PK 0+650 en sentido ascendente




Figura 111. Altura de la barrera metálica insuficiente. PK 0+700 en sentido ascendente




Figura 112. Altura de la barrera metálica suficiente. PK 0+750 en sentido ascendente



Figura 113. Ubicación de la deficiencia y solución propuesta entre los PPKK 0+550 y 0+750. Vista en planta.

Tabla 6. Ficha: Barrera metálica de altura insuficiente, del PK 0+750 al PK 0+900

2) CV-31 (Sentido creciente): Del PK 0+750 al PK 0+900	
Coordenadas iniciales	39°29'50,59" N 0°25'43,26" O
Coordenadas finales	39°29'55,29" N 0°25'46,14" O
Concepto	Defensas y barreras
Problemática detectada	Barrera metálica de altura insuficiente
Detectado de manera automatizada	SI
Medida propuesta	Desmontaje de las barreras existentes incluidos los postes e instalación de barrera de seguridad metálica BMS-NA4 incluyendo los solapes con los tramos de barrera contiguos, garantizando una altura de 75 centímetros sobre el pavimento.




Figura 114. Altura de la barrera metálica suficiente. PK 0+750 en sentido ascendente




Figura 115. Altura de la barrera metálica insuficiente. PK 0+775 en sentido ascendente



Figura 116. Altura de la barrera metálica insuficiente. PK 0+800 en sentido ascendente

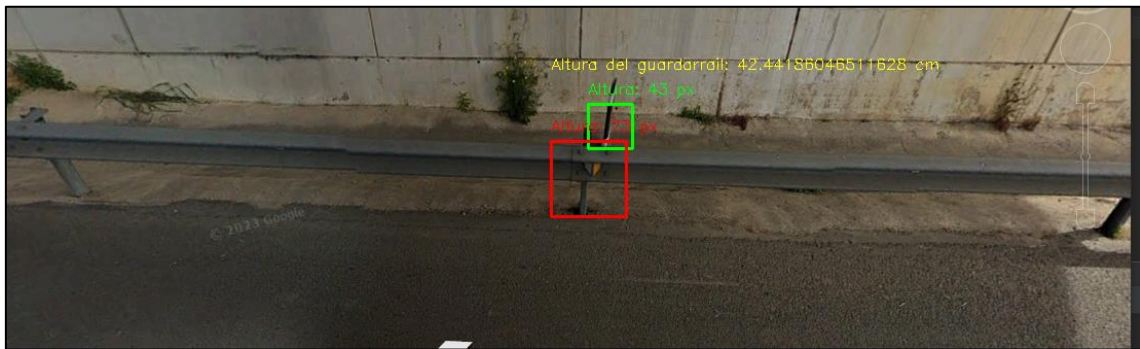


Figura 117. Altura de la barrera metálica insuficiente. PK 0+850. en sentido ascendente



Figura 118. Altura de la barrera metálica insuficiente. PK 0+875 en sentido ascendente



Figura 119. Altura suficiente de la barrera metálica en el PK 0+900 en sentido ascendente (79cm)



Figura 120. Ubicación de la deficiencia y solución propuesta entre los PPKK 0+750 y 0+900. Vista en planta.

Tabla 7. Ficha: Barrera metálica de altura insuficiente, del PK 1+750 al PK 2+250

3) CV-31 (Sentido creciente): Del PK 1+750 al PK 2+250	
Coordenadas iniciales	39°30'21,19" N 0°25'56,03" O
Coordenadas finales	39°30'37,10" N 0°25'58,86" O
Concepto	Defensas y barreras
Problemática detectada	Barrera metálica de altura insuficiente
Detectado de manera automatizada	SI
Medida propuesta	Desmontaje de las barreras existentes incluidos los postes e instalación de barrera de seguridad metálica BMS-NA4 incluyendo los solapes con los tramos de barrera contiguos, garantizando una altura de 75 centímetros sobre el pavimento.



Figura 121. Altura suficiente de la barrera metálica en el PK 1+750 en sentido ascendente (75cm)



Figura 122. Altura de la barrera metálica insuficiente. PK 1+850 en sentido ascendente.



Figura 123. Altura de la barrera metálica insuficiente. PK 1+900 en sentido ascendente.



Figura 124. Altura de la barrera metálica insuficiente. PK 2+100 en sentido ascendente.



Figura 125. Altura de la barrera metálica insuficiente. PK 2+250 en sentido ascendente.



Figura 126. Altura suficiente de la barrera metálica en el PK 2+275 en sentido ascendente (76cm)



Figura 127. Ubicación de la deficiencia y solución propuesta entre los PPKK 1+750 2+275.
Vista en planta.

Tabla 8. Ficha: Barrera metálica de altura insuficiente, del PK 3+000 al PK 3+200

4) CV-31 (Sentido creciente): Del PK 3+000 al PK 3+200	
Coordenadas iniciales	39°30'55,49" N 0°25'48,02" O
Coordenadas finales	39°31'00,49" N 0°25'43,29" O
Concepto	Defensas y barreras
Problemática detectada	Barrera metálica de altura insuficiente
Detectado de manera automatizada	SI
Medida propuesta	Desmontaje de las barreras existentes incluidos los postes e instalación de barrera de seguridad metálica BMS-NA4 incluyendo los solapes con los tramos de barrera contiguos, garantizando una altura de 75 centímetros sobre el pavimento.



Figura 128. Altura suficiente de la barrera metálica en el PK 3+000 en sentido ascendente (75cm)



Figura 129. Altura de la barrera metálica insuficiente. PK 3+050 en sentido ascendente.



Figura 130. Altura de la barrera metálica insuficiente. PK 3+075 en sentido ascendente.



Figura 131. Altura de la barrera metálica insuficiente. PK 3+100 en sentido ascendente.



Figura 132. Altura de la barrera metálica insuficiente. PK 3+125 en sentido ascendente.



Figura 133. Altura de la barrera metálica insuficiente. PK 3+150 en sentido ascendente.



Figura 134. Altura suficiente de la barrera metálica en el PK 3+200 en sentido ascendente (75cm)



*Figura 135. Ubicación de la deficiencia y solución propuesta entre los PPKK 3+000 y 3+200.
Vista en planta.*

Tabla 9. Ficha: Barrera metálica de altura insuficiente, del PK 3+250 al PK 3+000

5) CV-31 (Sentido decreciente): Del PK 3+250 al PK 3+000	
Coordenadas iniciales	39°31'01,79" N 0°25'42,78" O
Coordenadas finales	39°30'55,51" N 0°25'48,19" O
Concepto	Defensas y barreras
Problemática detectada	Barrera metálica de altura insuficiente
Detectado de manera automatizada	NO
Medida propuesta	Desmontaje de las barreras existentes incluidos los postes e instalación de barrera de seguridad metálica BMS-NA4 incluyendo los solapes con los tramos de barrera contiguos, garantizando una altura de 75 centímetros sobre el pavimento.



Figura 136. Altura de la barrera metálica insuficiente. PK 3+200 en sentido descendente. (68 cm)



Figura 137. Altura de la barrera metálica insuficiente. PK 3+100 en sentido descendente. (67cm)



Figura 138. Altura de la barrera metálica insuficiente. PK 3+000 en sentido descendente. (67cm)



Figura 139. Ubicación de la deficiencia y solución propuesta entre los PPKK 3+250 y 3+000. Vista en planta.

Tabla 10. Ficha: Barrera metálica de altura insuficiente, del PK 2+750 al PK 2+500

6) CV-31 (Sentido decreciente): Del PK 2+750 al PK 2+500	
Coordenadas iniciales	39°30'51,49" N 0°25'57,50" O
Coordenadas finales	39°30'44,67" N 0°26'01,62" O
Concepto	Defensas y barreras
Problemática detectada	Barrera metálica de altura insuficiente
Detectado de manera automatizada	SI
Medida propuesta	Desmontaje de las barreras existentes incluidos los postes e instalación de barrera de seguridad metálica BMS-NA4 incluyendo los solapes con los tramos de barrera contiguos, garantizando una altura de 75 centímetros sobre el pavimento.




Figura 140. Altura de la barrera metálica insuficiente. PK 2+750 en sentido descendente. (69 cm)



Figura 141. Altura de la barrera metálica insuficiente. PK 2+700 en sentido descendente. (70 cm)



Figura 142. Altura de la barrera metálica insuficiente. PK 2+600 en sentido descendente. (68 cm)




Figura 143. Altura de la barrera metálica insuficiente. PK 2+500 en sentido descendente. (64 cm)



Figura 144. Ubicación de la deficiencia y solución propuesta entre los PPKK 2+750 y 2+500. Vista en planta.

Para contrastar los resultados respectivos a la altura de las barreras de seguridad, ha sido necesario visitar la carretera, porque no es posible hacerlo de otra manera. En la siguiente

tabla se puede apreciar una comparativa entre los valores estimados por el modelo en cascada y el código en OpenCV, y las medidas in situ.

Tabla 11. Alturas de barreras metálicas. Comparativa de valores estimados y valores medidos.

PK	Altura estimada (cm)	Altura medida (cm)	Error (%)	Validez	Foto medición
0+600	57,03	62	-8,02%	Válido	Anexo II, Figura 1
0+650	64,84	65	-0,25%	Válido	Anexo II, Figura 2
0+700	65	69	-5,80%	Válido	Anexo II, Figura 3
0+750	75	76	-1,32%	Válido	Anexo II, Figura 4
0+775	56,71	63	-9,98%	Válido	Anexo II, Figura 5
0+800	50	61	-18,03%	Impreciso	Anexo II, Figura 6
0+850	42,44	64	-33,69%	Impreciso	Anexo II, Figura 7
0+875	58,62	67	-12,51%	Válido	Anexo II, Figura 8
1+850	37,5	65	-42,31%	Impreciso	Anexo II, Figura 9
1+900	57,81	64	-9,67%	Válido	Anexo II, Figura 10
2+100	71,09	74	-3,93%	Válido	Anexo II, Figura 11
2+250	55,48	64	-13,31%	Válido	Anexo II, Figura 12
3+050	63,33	66	-4,05%	Válido	Anexo II, Figura 13
3+075	48,75	64	-23,83%	Impreciso	Anexo II, Figura 14
3+100	58,86	65	-9,45%	Válido	Anexo II, Figura 15
3+125	45,5	65	-30,00%	Impreciso	Anexo II, Figura 16
3+150	45,75	59	-22,46%	Impreciso	Anexo II, Figura 17
%Validez				65%	

Tal y como se puede observar, en el 100% de los casos se puede determinar si la altura de las barreras metálicas es suficiente, aunque sólo en el 65% de los casos el error en la estimación es realmente despreciable. Esto se debe a que el modelo de clasificación detecta los elementos y los encuadra en un rectángulo. Si se pudiera encuadrar en una poligonal que se adaptara mejor al contorno de los elementos, se obtendría una precisión mayor en las estimaciones. En el Anexo II, se pueden consultar las imágenes de las medidas reales de las barreras de seguridad.

5.2.3. Ausencia de señal de entrada prohibida

La metodología propuesta, al igual que en la sección anterior, consistiría en recopilar imágenes, tratarlas mediante visión artificial con el objetivo de obtener imágenes más simplificadas de manera que se facilite la clasificación mediante técnicas de *machine learning*.

De manera resumida, el procedimiento consistirá en:

- 1) Recopilación de imágenes, y creación de biblioteca de imágenes positivas (en las que no aparece la señal R-101) y negativas (en las que sí aparece).

- 2) Tratamiento previo de las imágenes recopiladas.
- 3) Detección de ausencia de señal de entrada prohibida en las imágenes , ejecutando el código que se ha desarrollado para este propósito.

A continuación, se mostrarán los resultados de la inspección, detectando los problemas, ubicándolos geográficamente y proponiendo medidas para su subsanación.

Tabla 12. Ficha: Comprobación de presencia de señal R-101 en la glorieta Este del enlace con Paterna/Benimamet

1) CV-31 - Enlace con Paterna/Benimamet. Glorieta ESTE	
PK enlace	PK 0+725 a PK 0+925
Coordenadas iniciales	39°29'55,20" N 0°25'47,87" O
Concepto	Señalización
Problemática detectada	Ausencia de señal R-101 en carriles de acceso a la rotonda
Detectado de manera automatizada	SI
Medida propuesta	Instalación de señal R-101 en cada uno de los 5 carriles de entrada a la rotonda, incluido el anclaje del poste mediante hormigonado en el terreno. La señal deberá orientarse de manera que sea visible para los usuarios que recorran la rotonda.




Figura 145. Ubicación de la deficiencia y solución propuesta. Vista en planta de la glorieta Este del enlace con Paterna/Benimamet



Figura 146. Ausencia de señal R-101 en el carril de entrada NNO



Figura 147. Ausencia de señal R-101 en el carril de entrada O



Figura 148. Ausencia de señal R-101 en el carril de entrada S



Figura 149. Ausencia de señal R-101 en el carril de entrada SE



Figura 150. Ausencia de señal R-101 en el carril de entrada NE

Tabla 13. Ficha: Comprobación de presencia de señal R-101 en la glorieta Oeste del enlace con Paterna/Benimamet

2) CV-31 - Enlace con Paterna/Benimamet. Glorieta OESTE	
PK enlace	PK 0+725 a PK 0+925
Coordenadas iniciales	39°29'54,84" N 0°25'51,09" O
Concepto	Señalización
Problemática detectada	Ausencia de señal R-101 en carriles de acceso a la rotonda
Detectado de manera automatizada	SI
Medida propuesta	Instalación de señal R-101 en cada uno de los 3 carriles de entrada a la rotonda, incluido el anclaje del poste mediante hormigonado en el terreno. La señal deberá orientarse de manera que sea visible para los usuarios que recorran la rotonda.



Figura 151. Ubicación de la deficiencia y solución propuesta. Vista en planta de la glorieta Oeste del enlace con Paterna/Benimamet



Figura 152. Ausencia de señal R-101 en el carril de entrada NNO



Figura 153. Ausencia de señal R-101 en el carril de entrada O



Figura 154. Detección de señal R-101 en el carril de entrada S



Figura 155. Ausencia de señal R-101 en el carril de entrada E

Tabla 14. Ficha: Comprobación de presencia de señal R-101 en la glorieta del enlace con Feria de Muestras/Burjassot/Terramelar.

3) CV-31 - Enlace con Paterna/Benimamet. Glorieta .	
PK enlace	PK 1+175 a PK 1+375
Coordenadas iniciales	39°30'06,90" N 0°25'56,92" O
Concepto	Señalización
Problemática detectada	Ninguna
Detectado de manera automatizada	SI
Medida propuesta	No se ha detectado ninguna problemática




Figura 156. Vista en planta de la glorieta del enlace con la Feria de muestras de Valencia



Figura 157. Vista en planta de la rotonda del enlace con la Feria de muestras de Valencia



Figura 158. Detección de señal R-101 en el carril de entrada NO



Figura 159. Detección de señal R-101 en el carril de entrada S




Figura 160. Detección de señal R-101 en el carril de entrada NE

Tabla 15. Ficha: Comprobación de presencia de señal R-101 en la glorieta del enlace la CV-3103

4) CV-31 - Enlace con Enlace CV-3103. Glorieta	
PK enlace	3+500 a PK 3+700
Coordenadas iniciales	39°31'18,01" N 0°25'42,67" O
Concepto	Señalización
Problemática detectada	Ausencia de señal R-101 en carriles de acceso a la rotonda
Detectado de manera automatizada	SI
Medida propuesta	Instalación de señal R-101 en cada uno de los 4 carriles de entrada a la rotonda donde no existe esta señal, incluido el anclaje del poste mediante hormigonado en el terreno. La señal deberá orientarse de manera que sea visible para los usuarios que recorran la rotonda.




Figura 161. Ubicación de la deficiencia y solución propuesta. Vista en planta de la glorieta del enlace con la CV-3103



Figura 162. Ausencia de señal R-101 en el carril de entrada SO



Figura 163. Ausencia de señal R-101 en el carril de entrada SE



Figura 164. Ausencia de señal R-101 en el carril de entrada NE



Figura 165. Ausencia de señal R-101 en el carril de entrada NO

Tabla 16. Ficha: Comprobación de presencia de señal R-101 en la glorieta del final del tramo

5) CV-31 - Enlace con Enlace CV-3103. Glorieta	
PK enlace	4+300
Coordenadas iniciales	39°31'32,87" N 0°25'42,67" O
Concepto	Señalización
Problemática detectada	Ausencia de señal R-101 en carriles de acceso a la rotonda
Detectado de manera automatizada	SI
Medida propuesta	Instalación de señal R-101 en cada uno de los 5 carriles de entrada a la rotonda donde no existe esta señal, incluido el anclaje del poste mediante hormigonado en el terreno. La señal deberá orientarse de manera que sea visible para los usuarios que recorran la rotonda.




Figura 166. Ubicación de la deficiencia y solución propuesta. Vista en planta de la glorieta del final del tramo.



Figura 167. Ausencia de señal R-101 en el carril de entrada O



Figura 168. Ausencia de señal R-101 en el carril de entrada S



Figura 169. Ausencia de señal R-101 en el carril de entrada E



Figura 170. Ausencia de señal R-101 en el carril de entrada N



Figura 171. Ausencia de señal R-101 en el carril de entrada NO

En cuanto a los resultados obtenidos, se pueden afirmar que la detección de ausencia de señal R-101 de entrada prohibida en los carriles de acceso a glorietas también se ha saldado por un éxito del 100%. El modelo en cascada y el código en OpenCV permiten la detección de la presencia y ausencia de dichas señales de manera automática.

5.3. Medición de las medidas propuestas

A continuación, se mostrará en la tabla 16 cada una de las unidades de obra previstas y sus mediciones

Tabla 17. Mediciones

Unidad de obra	Ubicación en el tronco de la CV-310			Ubicación		Medición	
	PK inicial	PK final	Sentido	Rotonda		Metro	Unidad
Instalación de barrera de seguridad metálica BMS-NA4 incluyendo terminales abatidas de 4,32 metros en ambos extremos de la barrera. Protección contra la cara dorsal de la barrera metálica contigua.	1+975	1+950	Descendente	-	-	25	-
	1+755	1+780	Ascendente	-	-	25	-
	1+190	1+295	Ascendente	-	-	105	-
	1+370	1+345	Descendente	-	-	25	-
						180	
Desmontaje de las barreras existentes, de altura insuficiente, incluidos los postes	0+550	0+750	Ascendente	-	-	200	-
	0+750	0+900	Ascendente	-	-	150	-
	1+750	2+250	Ascendente	-	-	500	-
	3+000	3+200	Ascendente	-	-	200	-
	3+250	3+000	Descendente	-	-	250	-
	2+750	2+500	Descendente	-	-	250	-
						1550	
Instalación de barrera de seguridad metálica BMS-NA4 garantizando un correcto solape con las barreras contiguas, así como la altura correcta.	0+550	0+750	Ascendente	-	-	200	-
	0+750	0+900	Ascendente	-	-	150	-
	1+750	2+250	Ascendente	-	-	500	-
	3+000	3+200	Ascendente	-	-	200	-
	3+250	3+000	Descendente	-	-	250	-
	2+750	2+500	Descendente	-	-	250	-
						1550	
Instalación de señal R-101, de entrada prohibida en cada uno de los carriles de entrada a la glorieta donde no existe esta señal, incluido el anclaje del poste mediante hormigonado en el terreno.	-	-	-	Enlace con Paterna/Benimamet. Rot ESTE	39°29'55,20" N 0°25'47,87" O	-	5
	-	-	-	Enlace con Paterna/Benimamet. Rot OESTE	39°29'54,84" N 0°25'51,09" O	-	3
	-	-	-	Rotonda con Enlace CV-3103	39°31'18,01" N 0°25'42,67" O	-	4
	-	-	-	Rotonda final	39°31'32,87" N 0°25'42,67" O	-	5
							17

5.4. Estimación del presupuesto

A continuación, se mostrarán los informes presupuestarios obtenidos desde el programa PRESTO, y que son:

- 1) El cuadro de precios nº1
- 2) El cuadro de precios nº2
- 3) Presupuesto y mediciones
- 4) Resumen del presupuesto

CUADRO DE PRECIOS 1

CÓDIGO	UD	RESUMEN	PRECIO
01		Demoliciones	
01.01	m	Desmontaje de barreras metálicas	14,70
01.01		Desmontaje de barrera de seguridad tipo bionda incluso postes, incluido carga y transporte a lugar indicado por el director de obra.	

CATORCE EUROS con SETENTA CÉNTIMOS

02 Defensas

02.01	m	Instalación de barreras metálicas	47,76
02.01		Barrera de seguridad semirrígida tipo BMS-NA4/120a, de acero laminado y galvanizado en caliente de 3 mm. de espesor, con poste metálico tipo C-120 hormigonado , con p.p. de postes, amortiguadores, juego de tornillería, captafaros y cimentacion.	

CUARENTA Y SIETE EUROS con SETENTA Y SEIS CÉNTIMOS

03 Señalización

03.01	ud	Instalación de señales verticales	354,45
03.01		Señal circular de diámetro 90 cm., reflexiva y troquelada, incluso poste galvanizado de sustentación y cimentación, colocada.	

TRESCIENTOS CINCUENTA Y CUATRO EUROS con CUARENTA Y CINCO CÉNTIMOS

CUADRO DE PRECIOS 2

CÓDIGO	UD	RESUMEN	PRECIO
01		Demoliciones	
01.01	m	Desmontaje de barreras metálicas	
01.01		Desmontaje de barrera de seguridad tipo bionda incluso postes, incluido carga y transporte a lugar indicado por el director de obra.	
		Mano de obra	1,09
		Maquinaria	12,91
		Suma la partida	14,00
		Costes indirectos.....	
		5%.....	0,70
		TOTAL PARTIDA	14,70
02		Defensas	
02.01	m	Instalación de barreras metálicas	
02.01		Barrera de seguridad semirrígida tipo BMS-NA4/120a, de acero laminado y galvanizado en caliente de 3 mm. de espesor, con poste metálico tipo C-120 hormigonado , con p.p. de postes, amortiguadores, juego de tornillería, captafaros y cimentacion.	
		Mano de obra	6,56
		Maquinaria	2,51
		Resto de obra y materiales	36,42
		Suma la partida	45,49
		Costes indirectos.....	
		5%.....	2,27
		TOTAL PARTIDA	47,76
03		Señalización	
03.01	ud	Instalación de señales verticales	
03.01		Señal circular de diámetro 90 cm., reflexiva y troquelada, incluso poste galvanizado de sustentación y cimentación, colocada.	
		Mano de obra	9,84
		Maquinaria	3,76
		Resto de obra y materiales	323,97
		Suma la partida	337,57
		Costes indirectos.....	
		5%.....	16,88
		TOTAL PARTIDA	354,45

PRESUPUESTO Y MEDICIONES

CÓDIGO	RESUMEN	IMPORTE
01	Demoliciones	
01.01	m Desmontaje de barreras metálicas	
01.01	Desmontaje de barrera de seguridad tipo bionda incluso postes, incluido carga y transporte a lugar indicado por el director de obra.	
		CANTIDAD: 1.550,00
		PRECIO UNITARIO: 14,70
		IMPORTE: 22.785,00
	TOTAL 01	22.785,00
02	Defensas	
02.01	m Instalación de barreras metálicas	
02.01	Barrera de seguridad semirrígida tipo BMS-NA4/120a, de acero laminado y galvanizado en caliente de 3 mm. de espesor, con poste metálico tipo C-120 hormigonado , con p.p. de postes, amortiguadores, juego de tornillería, captafaros y cimentacion.	
		CANTIDAD: 1.730,00
		PRECIO UNITARIO: 47,76
		IMPORTE: 82.624,80
	TOTAL 02	82.624,80
03	Señalización	
03.01	ud Instalación de señales verticales	
03.01	Señal circular de diámetro 90 cm., reflexiva y troquelada, incluso poste galvanizado de sustentación y cimentación, colocada.	
		CANTIDAD: 17,00
		PRECIO UNITARIO: 354,45
		IMPORTE: 6.025,65
	TOTAL 03	6.025,65
	TOTAL	111.435,45

RESUMEN DE PRESUPUESTO

CAPÍTULO	RESUMEN	IMPORTE	%
01	Demoliciones	22.785,00	20,45
02	Defensas	82.624,80	74,15
03	Señalización.....	6.025,65	5,41

PRESUPUESTO DE EJECUCIÓN MATERIAL 111.435,45

13,00 % Gastos generales .. 14.486,61
6,00 % Beneficio industrial 6.686,13

Suma 21.172,74

PRESUPUESTO BASE DE LICITACIÓN SIN IVA 132.608,19

21% IVA..... 27.847,72

PRESUPUESTO BASE DE LICITACIÓN 160.455,91

Asciede el presupuesto a la expresada cantidad de **CIENTO SESENTA MIL CUATROCIENTOS CINCUENTA Y CINCO EUROS con NOVENTA Y UN CÉNTIMOS**

Valencia, 30 de Agosto de 2023.

PROMOTOR

Aymané Ismail Abou Zahr

6. Conclusiones

La metodología descrita en este trabajo ya se está empleando para la detección de anomalías en otros elementos de carreteras y de sus márgenes en otros países como Alemania, Australia o Estados Unidos. En España, podría suponer una buena oportunidad de negocio implementar un programa capaz de realizar inspecciones de seguridad vial. Unas de las funciones de este posible programa, podrían ser las subrutinas mediante las cuales se da solución a los problemas descritos en este trabajo. En manos de un buen equipo multidisciplinar, con medios suficientes para realizar tomas de datos de mejor calidad que a través de la herramienta de Streetview de Google, y contando con expertos en tratamiento digital de imágenes y machine learning, estas ideas podrían resultar en un programa competente, con una buena interfaz y que resultaría atractivo para empresas dedicadas a la realización de inspecciones de seguridad vial, e incluso para administraciones públicas.

Futuros trabajos desarrollando mejor estas ideas y puliéndolas podrían consistir en la implementación de un código que permita la comparación de imágenes dato e imágenes de prueba de manera optimizada, o en obtener imágenes tratadas de mejor calidad, que resulten más fáciles de identificar por una computadora.

En este trabajo, se ha descrito la metodología para detectar las problemáticas anteriormente mencionadas, y se ha aplicado para inspeccionar la carretera CV-31, obteniéndose resultados. En los próximos apartados, se contrastarán dichos resultados, y también se comentarán algunas limitaciones encontradas.

6.1. Limitaciones encontradas

En cuanto a las limitaciones encontradas, podemos citar las siguientes:

- 1) Calidad de las imágenes de entrada: En numerosas ocasiones, las capturas realizadas desde Google Street View no son las mejores para realizar un trabajo así, pues no se pueden obtener imágenes desde un ángulo óptimo, presentando discontinuidad, o simplemente viéndose borrosas, dificultando así su uso para la creación de bibliotecas de imágenes y para la detección de elementos en ellas.



Figura 172. Ejemplo de imagen con discontinuidad

- 2) Problemas de detección y falsos positivos. Los problemas de falsos positivos en la detección mediante cascadas de Haar pueden surgir por varias razones. Una de ellas es la complejidad del entorno en el que se encuentra el objeto de interés. Si la imagen contiene elementos con patrones visuales similares a los del objeto que se busca detectar, la cascada de Haar podría generar detecciones erróneas. Por ejemplo, si se está buscando un hito de arista en una imagen que contiene patrones similares en una pared o en una superficie texturizada, la técnica podría generar falsos positivos al confundir esos patrones con el elemento buscado.



Figura 173. Falsos positivos en la detección de elementos característicos de las caras dorsales de las barreras metálicas.

Otro factor que contribuye a los falsos positivos es la configuración de los parámetros del detector y la calidad de los clasificadores utilizados en la cascada. Si los umbrales de decisión no se ajustan correctamente o si los clasificadores no están entrenados de manera óptima para el objeto de interés, es probable que la cascada identifique objetos incorrectos, dando lugar a falsos positivos, aunque lo que más ha afectado a los modelos empleados en este trabajo ha sido el tamaño muestral de imágenes de entrenamiento.

- 3) Problemas a la hora de entrenar los modelos: Pese a haber sido una herramienta fácil de emplear, Cascade Trainer GUI sigue siendo un programa simple, no optimizado para generar modelos entrenados si el tamaño muestral de imágenes de entrenamiento es muy grande. Las limitaciones del programa, y las del ordenador empleado para la realización de este trabajo, han impedido el uso de bibliotecas de imágenes positivas y negativas muy amplias, pues para entrenar un modelo con 150 imágenes, fueron necesarias más de 12 horas.

6.2. Ventajas económicas, sociales y ambientales. Objetivos de Desarrollo Sostenible

La aplicación de esta metodología en el campo profesional comportaría numerosas ventajas, tanto económicas como sociales y ambientales.

- 1) Ventajas económicas: Las inspecciones de seguridad vial en España pueden resultar bastante caras. Los motivos son simples: la Red de Carreteras es muy extensa. Cuenta con más de 165.000 kilómetros de carreteras, que hay que inspeccionar con regularidad. Realizándose de manera convencional, una inspección in situ, requiere de más de un trayecto para identificar todas las anomalías. Eso comportaría un coste elevado, tanto en combustible como en personal. Sin embargo, si se sigue el método propuesto en este trabajo, sería necesario realizar un único viaje, en el cual se obtendrían datos que se procesarán a posteriori, identificando todos los problemas existentes. En cuanto a los objetivos al desarrollo sostenible a los que nos podría acercar la implantación de este modo de operar, podríamos citar el noveno (Industria, innovación e infraestructura) y el duodécimo (Producción y consumo responsables)
- 2) Ventajas sociales: Hoy en día, el impacto contra barreras metálicas provoca el 44% de las muertes de los motoristas. En cuanto a las lesiones y fatalidades debidas al impacto contra las caras dorsales de las barreras de seguridad no se han encontrado datos, pero está claro que estos elementos mal colocados implican un riesgo muy grande. El principal problema es que esta anomalía es más común de lo que nosotros, o los inspectores de seguridad vial, percibimos. Esta es la única explicación que le encuentro a que siga siendo tan corriente el hecho de encontrarse barreras de seguridad cuya cara dorsal es la más próxima a la vía. Por eso, tal vez sea necesaria una modernización en el proceso de las inspecciones de seguridad vial. Probablemente así, estos problemas (además de otros), sean detectados y solucionados, reduciendo así las consecuencias de los accidentes, y dando un paso hacia la consecución del tercer objetivo de desarrollo sostenible (Salud y bienestar).
- 3) Ventajas ambientales: Tal y como se ha visto en el primer apartado (ventajas económicas), si las inspecciones de seguridad vial se realizaran de la manera propuesta en este trabajo, se reduciría el consumo de combustible necesario para realizar la toma de datos, y por consiguiente, se reducirían las emisiones

degases nocivos como el CO₂. Esto supondría una importantísima acción por el clima (trigésimo objetivo de desarrollo sostenible).



Figura 174. Objetivos de Desarrollo Sostenible. Agenda 2030.

7. Referencias bibliográficas.

- [1] G. Bradski. A. Kaehler. OpenCV. Dr. Dobb's journal of software tools, 3, 120. *Open Source Computer Vision Library* 2000 Recuperado el 20 de Mayo de 2022 de: <https://opencv.org/opencv/>
- [2] OpenCV . Cuda gpu port. *Open Source Computer Vision Library* 2015. Recuperado el 20 de Mayo de 2022: <https://opencv.org/cuda/>.
- [3] I. Culiak, D. Abram, T. Pribanic,, H. Dzapo,, &, M. Cifrek. A brief introduction to OpenCV. In 2012 proceedings of the 35th international convention MIPRO (pp. 1725- 1730). IEEE. 2012
- [4] D. Kaur. Remove Noise Effects From Degraded Document Images Using Matlab Algorithm. *International Journal of Engineering Sciences & Research Technology*, Vol. 4, No. 9, pp. 544–549. 2015
- [5], A. Mordvintsev, & K. Abid. Opencv-python tutorials documentation. Obtenido de <https://media.readthedocs.org/pdf/opencv-python-tutroals/latest/opencv-python-tutroals.pdf>. "Opencv." 2014. [Recuperado el 30 de Mayo de 2022 de: https://opencv-python-tutroals.readthedocs.io/en/latest/py_tutorials/py_imgproc/py_canny/py_canny.html/.
- [6] J. Canny A computational approach to edge detection. *IEEE Transactions on patternanalysis and machine intelligence*, (6), 679-698. 1986
- [7] M. P. RAVI and A. ASHOKKUMAR, "Analysis of various image processing techniques," *International Journal of Advanced Networking & Applications (IJANA)* Volume, vol. 8, p.86–89, 2017.
- [8] B. Mahesh. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], 9, 381-386. 2020
- [9] S. Chilamkurthy, R., Tanamala, S., Biviji, M., Campeau, N. G., V. K. Venugopal,... & P. Warier. Deep learning algorithms for detection of critical findings in head CT scans: a retrospective study. *The Lancet*, 392(10162), 2388-2396. 2018
- [10] N. Latysheva. Implementing Your Own k-Nearest Neighbor Algorithm Using Python "Knn algorithm." 2016 Recuperado el día 10 de Junio de 2022 de: <https://www.kdnuggets.com/2016/01/implementing-your-own-knn-using-python.html/>.
- [11] T. Guo, J. Dong, H. Li, and Y. Gao, "Simple convolutional neural network on image classification," in 2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA), (pp. 721–724, IEEE, 2017.

[12] T. Ojala, M. Pietikainen and D. Harwood, "Performance evaluation of texture measures with classification based on Kullback discrimination of distributions," Proceedings of 12th International Conference on Pattern Recognition, Jerusalem, Israel, 1994, pp. 582-585 vol.1, doi: 10.1109/ICPR.1994.576366.

[13] de Sampaio, W. B., Silva, A. C., de Paiva, A. C., & Gattass, M. (2015). Detection of masses in mammograms with adaption to breast density using genetic algorithm, phylogenetic trees, LBP and SVM. *Expert Systems with Applications*,42(22),8911-8928

[14] Silva, C., Bouwmans, T., & Frélicot, C. (2015, March). An extended center-symmetric local binary pattern for background modeling and subtraction in videos. In *International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, VISAPP 2015*.

[15] Berlanga, A. (2016). El camino desde la inteligencia artificial al Big Data. *Revista de Estadística y Sociedad*,(68), 9-11.

[16] Gupta, A., & Tiwari, R. (2015). Face detection using modified Viola jones algorithm. *International Journal of Recent Research in Mathematics Computer Science and Information Technology*, 1(2), 59-66.

[17] Freund, Y., & Schapire, R. E. (1996, July). Experiments with a new boosting algorithm. In *icml* (Vol. 96, pp. 148-156).

[18] Ozhiganov, I. V., & Tumanova, E. I. (2020, January). Analysis of Ways to Create Augmented Reality. In *2020 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EConRus)* (pp. 59-61). IEEE.

Valencia, 1 de septiembre de 2023.

Ayman Ismail Abou Zahr

Anexo I. Bibliotecas de imágenes para entrenamiento de los modelos de detección

Anexo II. Imágenes de la medición de altura de las barreras metálicas