

UNIVERSIDAD POLITÉCNICA DE VALENCIA

DEPARTAMENTO DE SISTEMAS INFORMÁTICOS Y
COMPUTACIÓN

MASTER EN INTELIGENCIA ARTIFICIAL, RECONOCIMIENTO DE
FORMAS E IMAGEN DIGITAL



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

DSIC

**DEPARTAMENT DE SISTEMES
INFORMÀTICS I COMPUTACIÓ**

Aplicación de Algoritmos Genéticos a la
recalibración de cámaras en túnel de inspección de
carrocerías

TRABAJO FIN DE MASTER

Septiembre, 2015

Autor

Víctor Ruiz Piera

Tutores

Dr. Federico Barber

Dr. Josep Tornero

Resumen

En el presente Trabajo Final de Master se diseña un Algoritmo Genético que obtendrá la mejor configuración de cámaras para un modelo CAD que representa un sistema de visión artificial con múltiples cámaras fijas que observa un objeto fijo. Lo que se pretende es que cada cámara en el CAD visualice el objeto con la misma perspectiva en que se visualiza el objeto real.

Las pruebas y desarrollos aquí presentados se realizaron dentro del proyecto del Túnel de Inspección de Carrocerías para Factorías FORD, desarrollado por el Instituto de Diseño y Fabricación (IDF) de la Universidad Politécnica de Valencia (UPV). Estos túneles se han implantado hasta la fecha en 7 plantas de Estados Unidos y 3 plantas de Europa.

El túnel de inspección se utiliza para la detección de defectos en la pintura de los coches durante su fabricación, con el objetivo de que este proceso se realice de forma automatizada. Este sistema está basado en un sistema de visión soportado por múltiples cámaras fijas. En las implantaciones realizadas se han utilizado entre 12 y 14 cámaras por túnel.

El diseño del túnel de inspección se realiza con una herramienta CAD desde la que se obtienen distintos parámetros y patrones necesarios para la detección de defectos en el túnel real.

El objetivo del Algoritmo Genético es conseguir la mejor configuración de cámaras en el modelo CAD para obtener la misma imagen que en las cámaras del túnel real.

Palabras clave:

Algoritmo Genético, Calibración, Visión Artificial, Diseño Asistido por Computador

Resum

En aquest Treball Final de Master es dissenya un Algoritmo Genètic que obtindrà la millor configuració de càmeres per a un model CAD que representa un sistema de visió artificial amb múltiples càmeres fixes que observen un objecte fixe. El que es pretén es cada càmera en el CAD visualitze el objecte amb la mateixa perspectiva en que es visualitza el objecte real.

Les proves i desenvolupaments ací presentats es realitzaren dins del projecte del Túnel d'Inspecció de Carroceries per a Factories FORD, desenvolupat pel Institut de Disseny i Fabricació (IDF) de la Universitat Politècnica de Valencia (UPV). Aquests túnels s'han implantat fins avui en 7 plantes dels Estats Units i 3 plantes d'Europa.

El túnel d'inspecció s'utilitza per a la detecció de defectes en la pintura dels cotxes durant la seua fabricació, amb l'objectiu de que aquest procés es realitze de forma automatitzada. Este sistema està basado en un sistema de visió soportat per múltiples càmeres fixes. En les implantacions realitzades s'han utilitzat entre 12 i 14 càmeres per túnel.

El disseny del túnel d'inspecció es realitza amb una ferramenta CAD des de la que s'obtenen diferents paràmetres y patrons necessaris per a la detecció de defectes en el túnel real.

L'objectiu de l'Algoritme Genètic es conseguir la millor configuració de càmeres en el model CAD per a obtindre la mateixa image que en las càmeres del túnel real.

Paraules clau:

Algoritme Genètic, Calibració, Visió Artificial, Disseny Assistit per Computador

Abstract

In this Master Final Work is designed a Genetic Algorithm that will obtain the best camera setting for a CAD model representing an artificial vision system with multiple fixed cameras that observes a fixed object. The objective is that each camera in the CAD visualizes the object with the same perspective that is visualized the real object.

The described tests and developments were made in the environment of Carbody Inspection Tunnel Project for FORD Factories, developed by The Design and Manufacturing Institute (IDF) of Universitat Politècnica de Valencia (UPV). These tunnels were installed until now in 7 factories of USA and 3 factories in Europe.

The inspection tunnel is used for paint defects detection during car manufacturing process, with the goal that it was an automated process. This system is based on a artificial vision system supported by multiple fixed cameras, using between 12 and 14 cameras in each tunnel.

The design of the inspectin tunnel is done with a CAD tool from are obtained different parameters and patterns needed in deffect detection in the real tunnel.

The goal of this Genetic Algorithm is to obtain the best camera setting in CAD model to obtain the same image as with real tunnel cameras.

Keywords:

Genetic Algorithm, Calibration, Artificial Vision, Computer Assisted Design

Índice

Resumen	I
Resum	II
Abstract	III
1. Introducción	1
1.1. El Túnel de Inspección de Carrocerías	1
1.2. El Túnel en funcionamiento	4
1.2.1. Obtención de la imagen de fusión	5
1.2.2. Cámaras del túnel	6
1.3. Diseño y montaje del túnel	7
1.3.1. Diseño túnel con CAD	7
1.3.2. Calibración manual y Cálculo de imagen de referencia	8
1.3.3. Operaciones post-montaje con CAD	9
2. Motivación: Necesidad de la recalibración	10
2.1. Desajustes del túnel: Vista CAD vs Vista Real	10
2.2. Análisis de alternativas	11
2.3. Soluciones existentes para calibración de cámaras	12
2.4. Calibración de cámaras CAD vs Real	12
3. Algoritmo Genético de Recalibración (RGA)	13
3.1. Algoritmos Genéticos	13
3.1.1. Terminología	14
3.1.2. Estructura general	14
3.2. Individuo RGA	14
3.3. Función Fitness RGA	16
3.4. Diseño de RGA	16
3.4.1. Inicialización población	17
3.4.2. Selección	18
3.4.3. Evolución por mutación	18
3.4.4. Reemplazo	18
3.4.5. Condición de parada	19
3.4.6. Coste computacional	20
4. Cálculo de la Aptitud	21
4.1. Obtención de fenotipos: Integración con CAD	21
4.2. TPiNC	23
4.2.1. Obtención de la máscara de recalibración	23
4.2.2. Cálculo TPiNC	24
4.2.3. Validación visual con TPiNC	25
4.3. TPiNC2	25
4.3.1. Obtención de la máscara de doble contorno	25
4.3.2. Cálculo TPiNC2	26
4.3.3. Validación visual con TPiNC2	27

5. Variantes y validación de RGA	28
5.1. RGA_1	29
5.2. RGA_2	30
5.3. RGA_3	31
5.4. Validación de variantes	32
5.5. Diseño nueva variante: RGA_4	33
5.6. Validación de RGA_4	34
5.7. Comparación resultados TPiNC y TPiNC2	35
5.8. Ejecución de RGA_4	36
6. Resultados en producción	40
6.1. Resultados instalación Almussafes	41
6.1.1. Modelo CMAV. Cámara 12	41
6.1.2. Modelo KUGA. Cámara 8	42
6.2. Resultados instalación Túnel 1 Dearborn	43
6.2.1. Modelo CREW CAB. Cámara 6	43
6.2.2. Modelo CREW CAB. Cámara 7	44
6.3. Resultados instalación Túnel 2 Dearborn	45
6.3.1. Modelo REG CAB. Cámara 12	45
6.3.2. Modelo CREW CAB RAPTOR. Cámara 4	46
6.3.3. Modelo CREW CAB RAPTOR. Cámara 1	47
6.3.4. Modelo CREW 55 BOX. Cámara 11	48
7. Conclusiones	49
8. Bibliografía	50

Capítulo 1

Introducción

Este Trabajo Final de Master es de orientación profesional y tiene como objetivo la aplicación de las técnicas informáticas desarrolladas en el master para la resolución de un problema real industrial.

El trabajo aquí descrito se realizó durante la relación laboral que mantuvo el autor con el Instituto de Diseño y Fabricación de la Universidad Politécnica de Valencia, dirigido por el profesor Dr. Josep Tornero, en el año 2012.

El problema a resolver es la calibración de cámaras del túnel de inspección de carrocerías, un sistema automático de control de calidad basado en visión artificial que detecta microdefectos en pintura durante el pintado de coches en las fábricas de FORD. En este TFM, al calibrado de cámaras se le podrá denominar como recalibración ya que en este proyecto existe un proceso anterior que también es una calibración, en este caso manual.


La calibración de cámaras es un proceso que se realiza durante el montaje del túnel de inspección. Consiste en ajustar las cámaras del diseño CAD del túnel para que vean al coche a inspeccionar de la misma forma que en la realidad. Este proceso tiene gran relevancia ya que a continuación se realizan otros procesos con el CAD, relacionados con la detección, y son sensibles a las posiciones de las cámaras.

Por este proyecto se le otorgó a Josep Tornero el “Henry Ford Industrial Award 2012”, que premia los proyectos industriales realizados dentro de FORD a nivel internacional.

1.1. El Túnel de Inspección de Carrocerías

En la industria del automóvil, los productos finales han de ser tratados con diferentes capas de pintura, siendo la calidad un aspecto especialmente crítico. Los procesos de pintado automático se realizan normalmente de forma continua, con las carrocerías moviéndose a lo largo de la línea de producción de una estación a otra. Las capas de pintura se aplican bajo condiciones de temperatura,

humedad y ausencia de polvo estrictamente controladas. En este contexto, los defectos de pintura aparecen como una inevitable variación de las condiciones óptimas de operación o causadas por polvo, agresiones ocasionales causadas por los propios trabajadores, etc. Los defectos son, en realidad, alteraciones en una capa de pintura que crecen y se hacen más visibles conforme se aplican capas adicionales de pintura.



Tradicionalmente, los defectos se localizan, marcan y reparan en una etapa posterior al proceso de pintado. En ocasiones, los defectos son claramente visibles y detectables, como es el caso de golpes y rayas, mientras que en otros casos, los defectos pueden ser en realidad pequeñas partículas muy difíciles de detectar.

En algunos casos, la situación puede ser grave ya que la no detección del defecto en factoría da lugar al rechazo del vehículo por parte del cliente al no cumplirse las expectativas de calidad. En consecuencia, la imagen de marca de la empresa y la satisfacción del cliente se ven drásticamente afectados. No obstante, aunque se detectara en fábrica, sería necesario un nuevo repintado del vehículo. Además, la no detección de los defectos en las primeras etapas del proceso de pintado, supone un incremento de costes por el mayor consumo de pintura y energía y su consecuente impacto medioambiental.




Inspección Manual



Pulido

Hoy por hoy, la gran mayoría de factorías incorporan operarios expertos que inspeccionan el producto para detectar defectos. No obstante, a partir de la selección y análisis minucioso y

aleatorio fuera de línea de los vehículos, se ha podido constatar que el 80% de los defectos pequeños no son correctamente detectados. El principal motivo de esta tasa de fallo tan elevada se debe sobretodo a la fatiga ocular que sufren los operarios.



Inspección Automática



Pulido

Para automatizar este proceso de inspección se diseña el Túnel de Inspección Carrocerías, un novedoso sistema de inspección basado en visión artificial para detectar defectos en carrocerías de automóviles. La fabricación de este sistema ha sido llevada a cabo por el Instituto de Diseño y Fabricación de la Universidad Politécnica de Valencia junto a la empresa ICEMI y AUTIS.

El túnel se ha implantado a nivel internacional en las distintas factorías de FORD. Hasta la fecha, se han instalado 10 túneles en las siguientes plantas:

- Unión Europea:
 - o Almussafes (España)
 - o Genk (Bélgica)
 - o Saarlouis (Alemania)

- Estados Unidos
 - o Dearborn Truck Plant (Michigan, Estados Unidos), 2 túneles
 - o Louisville Truck Plant (Kentucky, Estados Unidos), 2 túneles
 - o Detroit (Michigan, Estados Unidos)
 - o Louisville (Kentucky, Estados Unidos)
 - o Oakville (Ontario, Canada)

El sistema se basa en el principio de detección de defectos mediante la generación de un barrido de iluminación, estando el sistema de visión (cámaras) fijo, al igual que el vehículo a inspeccionar. Tras la adquisición de las imágenes de barrido de iluminación, se realiza un procesamiento que permite detectar y clasificar defectos de hasta 0.2mm de diámetro.

La principal innovación introducida por este proyecto industrial reside en el hecho de que el sistema es capaz de detectar casi el 100% de los defectos detectados mediante inspección humana. El sistema es capaz de detectar defectos milimétricos tanto en la parte superior (capó, techo y maletero) como en los laterales (aletas delanteras y traseras y puertas), cubriendo así las partes más importantes de la carrocería del vehículo [Tornero, 2011].

1.2. El Túnel en funcionamiento

El Túnel de Inspección de Carrocerías está compuesto, de forma genérica, de una estructura metálica que soporta un conjunto de luces para iluminar el coche durante la inspección y un conjunto de cámaras para tomar imágenes del mismo.

Para visualizar la superficie de la carrocería del coche se utiliza un número determinado de cámaras, entre 12 y 14 dependiendo de los modelos de coche a inspeccionar. Estas cámaras están en una posición fija, que se determina en la fase de diseño del túnel.

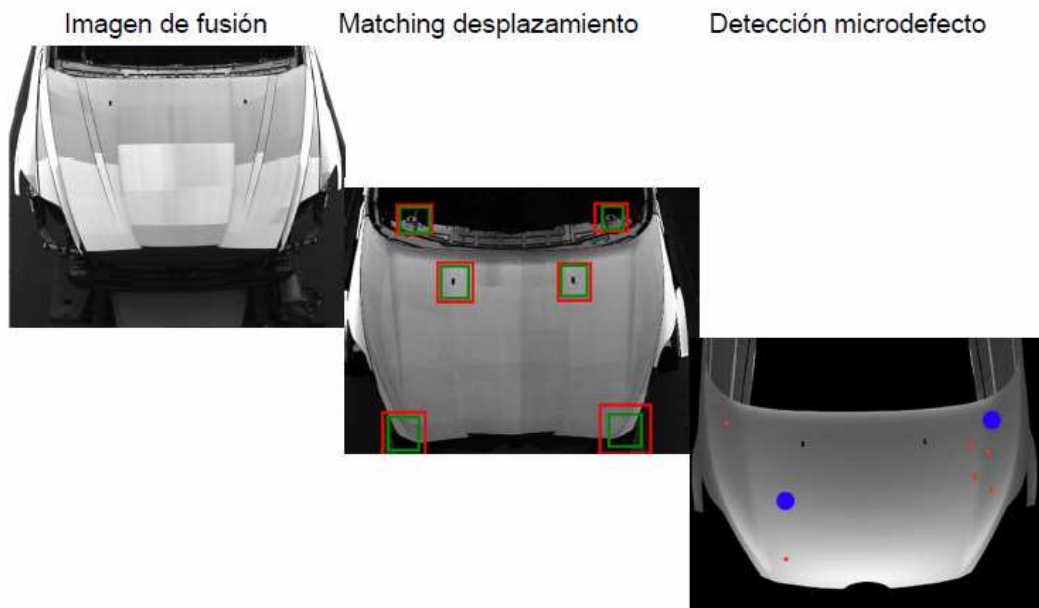
Para iluminar de forma adecuada la superficie del túnel, se utiliza un conjunto de tubos fluorescentes colocados en una estructura metálica móvil con tracción mecánica. La colocación de estos tubos, como en el caso anterior, se determina en la fase de diseño del túnel, conformando una estructura de luces que le da el aspecto característico al Túnel de Inspección.



La detección de microdefectos se realiza a partir de imágenes del coche obtenidas con las cámaras del túnel.

El proceso de detección de microdefectos tiene los siguientes pasos:


- Obtención de imagen de fusión
- Preproceso para corregir desplazamientos de la carrocería
- Detección de microdefectos



1.2.1. Obtención de la imagen de fusión

Para obtener una imagen del coche se realiza, lo que se denomina, un barrido, es decir, la estructura de luces se desplaza a lo largo de todo el recorrido del túnel y, de forma simultánea, se toman instantáneas del coche durante ese recorrido.


Con el conjunto de imágenes obtenido se genera la denominada “imagen de fusión”. Esta imagen consiste en la combinación de las instantáneas obtenidas durante el barrido para visualizar la parte de la carrocería del coche más iluminada por cada tubo de luz.



1.2.2. Cámaras del túnel

El Túnel de Inspección tiene montadas 12 cámaras para visualizar por completo la carrocería del coche a inspeccionar, aunque este número puede variar dependiendo del tamaño del coche.

Durante el diseño del CAD se colocan las cámaras de forma que se visualicen, en conjunto, todas las partes relevantes de la carrocería. Como ejemplo, se muestran las vistas del Mondeo:



Vistas del CAD para Mondeo

Las correspondientes a la vista real para este modelo serían:



1.3. Diseño y montaje del túnel

El diseño y montaje del túnel de inspección es un proceso complejo y no es objeto del presente Trabajo Final de Master.


Para ubicar el trabajo realizado en este TFM, se enumeran las principales etapas:

- Diseño túnel CAD
- Montaje en planta
- Calibración manual cámaras
- Cálculo Imagen Referencia
- Cálculos CAD post-montaje

1.3.1. Diseño túnel con CAD

En la mayoría de proyectos industriales, es indispensable el uso de herramientas CAD para su diseño.

Para este proyecto se hacía uso de la herramienta Unigraphics NX 6.0, con la que se diseñaba la estructura del túnel, la disposición de luminarias y la colocación de las cámaras.



Esta herramienta CAD también se utilizaba como simulador del túnel ya que se tenían los diseños de fabricación, adaptados para simulación, de los coches a evaluar en la realidad.

Para explotar las funciones de simulación se desarrolló una herramienta específica en C#, que se integraba con NX, para automatizar las tareas de simulación, cálculos post-montaje y recalibración.

1.3.2. Calibración manual y Cálculo de imagen de referencia


Tras el montaje de la estructura del túnel, se pone en funcionamiento la línea de producción de la factoría pasando coches a través de él. Esto se realiza para saber donde paran las carrocerías a evaluar.

Teniendo un coche parado, se colocan de forma manual las cámaras del túnel tomando como referencia la vista de la correspondiente cámara en el CAD.

Como en cualquier proceso real, la posición de parada de la carrocería no es siempre la misma pero se necesita determinar una posición como referencia y, por tanto, tener una imagen de referencia para cada cámara.

Para calcular esta imagen se hace uso un procedimiento específico que, a partir de un conjunto de imágenes de fusión de distintos coches, determina la imagen que corresponde al coche que paró en una posición promedia.

Para determinar la posición de parada de cada coche se definen, mediante un software específico, unos puntos de referencia en la carrocería. Con estos puntos de referencia se puede calcular distancias y diferencias en las paradas de cada coche.


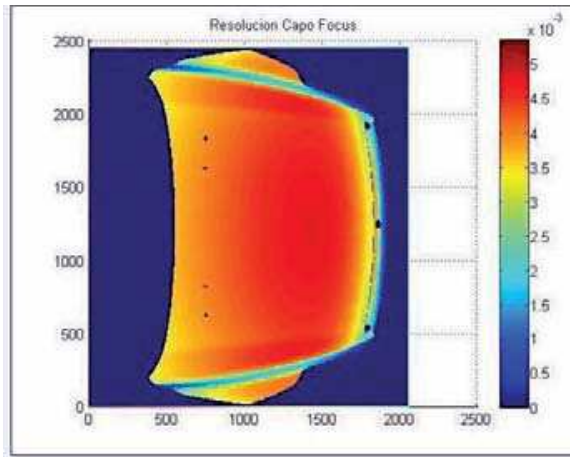


A la imagen del coche que ha parado en la posición media de entre los evaluados en esta fase, se le denomina **Imagen de Referencia**.

1.3.3. Operaciones post-montaje con CAD

A partir de la Imagen de Referencia se preparan diferentes plantillas y patrones, que se utilizarán para la detección de microdefectos durante el uso en producción del túnel de inspección.

En la mayoría de casos, se hace uso de la herramienta integrada en el CAD, ya nombrada en 1.3.1, para obtener patrones, mapas de resolución, etc.




Motivación: Necesidad de la recalibración

En el presente capítulo se motivará la creación de un nuevo proceso que se incluirá en la instalación de un nuevo Túnel de Inspección de Carrocerías detectando la necesidad de la nueva etapa, valorando las alternativas y proponiendo un tipo de solución.

2.1. Desajustes del túnel: Vista CAD vs Vista Real

Tras el montaje del túnel de inspección, se detecta que no corresponden exactamente las imágenes del coche real y las imágenes correspondientes en el CAD.



La imagen aquí mostrada es una exageración del fenómeno, pero lo ilustra claramente.

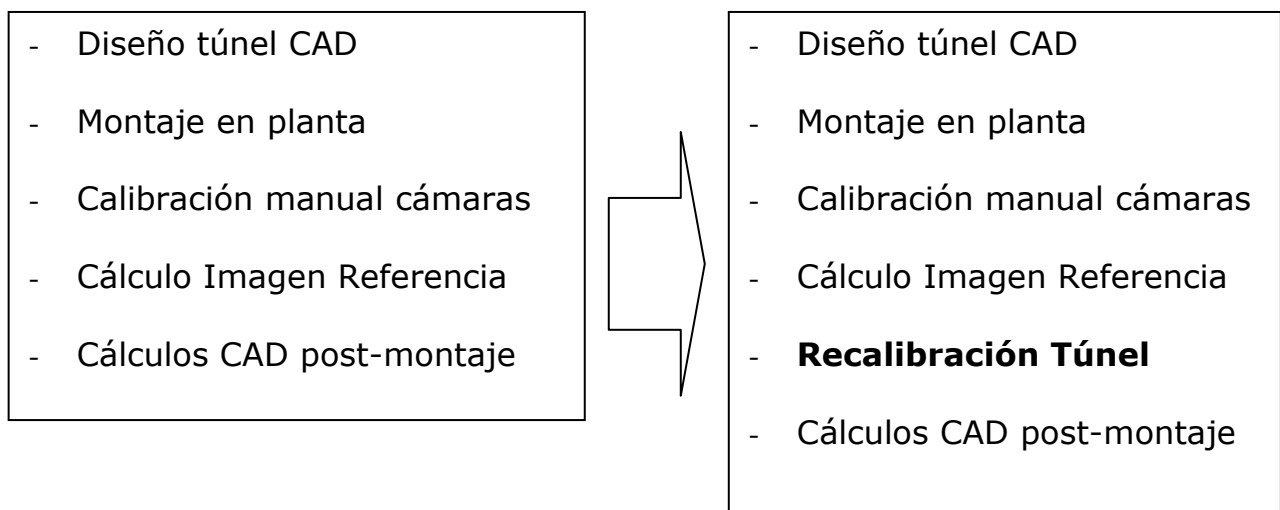
La problemática que se detecta es que el ajuste de la posición de la cámara durante el montaje del túnel se realiza respecto a un coche aleatorio, además de que el procedimiento manual de calibrado no garantiza la exactitud.

Durante el proceso de obtención de la Imagen de Referencia, proceso posterior al montaje, se determina qué coche será la referencia.

Como se puede deducir, no existe un proceso que relacione la posición del coche real (imagen de referencia) y la posición del coche en el CAD, por lo que se plantea crear un nuevo proceso para solucionar este desajuste.

2.2. Análisis de alternativas

Tras detectar este problema se plantea diseñar un nuevo proceso de recalibración del túnel, que se situaría entre la “Cálculo de la Imagen de Referencia” y “Cálculos CAD post-montaje”:



Se le denomina recalibración porque ya existe un proceso de calibrado manual inicial.

Para la recalibración del túnel se plantean los siguientes enfoques:

- Recalibración túnel físico
 - o Soporte de cámaras más precisos
 - o Validación física de cumplimiento de diseño
- Recalibración del CAD
 - o Recalibración estructura
 - o Recalibración parada coche
 - o Recalibración de cámaras (genérico)
 - o Recalibración de cámaras para cada modelo de coche

Tras un pequeño análisis de los distintos enfoques, se decide optar por la “Recalibración de cámaras para cada modelo de coche” ya que aporta las siguientes ventajas:

- No se requiere modificar la estructura física
- Se simplifica el problema al ajustar cada cámara por separado
- Permite la variabilidad de parada en diversos modelos

2.3. Soluciones existentes para calibración de cámaras

La calibración de cámaras consiste en el ajuste de sus parámetros extrínsecos e intrínsecos. Estos parámetros son:

- Traslación
- Rotación
- Distancia Focal, etc.

Para ajustar estos parámetros existen varios métodos:

- Tsai [Tsai, 1987]
- Faugeras [Faugeras, 1993]
- Zhang [Zhang, 2000], etc

Estos métodos resuelven la calibración de una cámara respecto a una referencia dentro de un mismo sistema de coordenadas.

Por el contrario, nuestro problema se trata de calibrar una cámara en un sistema de coordenadas (coche en el túnel del CAD virtual) respecto a una referencia en otro sistema de coordenadas (coche en el túnel real). Por tanto los métodos anteriormente enumerados no nos sirven para solucionar el problema planteado.

2.4. Calibración de cámaras CAD vs Real

El problema a resolver se trata en conseguir la combinación de parámetros extrínsecos de la cámara (traslación y rotación) con los que mejor se ajuste la vista de la cámara del CAD con la realidad.

Para resolver este problema se decide diseñar una solución mediante **Algoritmos Genéticos** para la búsqueda del mejor ajuste de parámetros extrínsecos de cámara (recalibración).

Este tipo de solución tiene las siguientes ventajas:

- Automatizable
- Resuelve el problema
- Solución en tiempo razonable

Algoritmo Genético de Recalibración (RGA)

En este capítulo se detalla como se diseña el Algoritmo Genético de Recalibración (RGA).

En un primer término se explicarán algunos conceptos básicos sobre Algoritmos Genéticos.

A continuación se definirá como se especifica un individuo y como se calcula la función fitness. Esta parte se explica antes de definir el RGA ya que determina muchos aspectos del diseño del algoritmo.

3.1. Algoritmos Genéticos

Los Algoritmos Genéticos son una técnica de Inteligencia Artificial, inspirada en los mecanismos de la biología, que se aplica a resolver problemas de optimización combinatoria. Se considera una técnica metaheurística y es adecuada para resolver problemas con espacios de búsqueda extensos donde otros métodos no obtendrían la solución en un tiempo razonable.

Los mecanismos de búsqueda de los Algoritmos Genéticos se basan en la genética y la selección natural. Combinan el concepto de supervivencia de los individuos más adaptados con operadores genéticos como el cruce o la mutación. Los Algoritmos Genéticos se diferencian de los métodos tradicionales de optimización de varias formas:

- Utilizan funciones objetivo para determinar la aptitud del individuo (fitness).
- Utilizan un conjunto de soluciones para encontrar la solución
- Utilizan reglas estocásticas (aleatorias)
- Este tipo de algoritmos, cuando no haya limitaciones temporales, siempre convergerá a un óptimo global

3.1.1. Terminología

Población: es el conjunto de individuos que representan el conjunto de soluciones evaluadas en una generación (iteración).

Individuo: es la representación de una de las soluciones al problema. Un individuo está compuesto por un genotipo (codificación de la solución) y un fenotipo (representación externa de la solución).

Función de aptitud o Fitness: representa el nivel de adecuación del fenotipo de un individuo al problema, siendo los individuos con mejor *fitness* los que tengan más probabilidades de reproducción.


3.1.2. Estructura general

Un Algoritmo Genético estará compuesto de los siguientes elementos:

1. Población Inicial: conjunto de soluciones al problema dentro del espacio de búsqueda
2. Fitness: evalúa la aptitud de cada individuo
3. Nueva Población: repetir los siguientes pasos para completar una nueva generación de la población
 - 3.1. Selección: seleccionar los individuos padre de acuerdo a su aptitud
 - 3.2. Cruce: combinar los genes de los padres para obtener hijos
 - 3.3. Mutación: con una probabilidad (p_x), mutar los genes del nuevo individuo
 - 3.4. Reemplazo: añadir nuevos hijos y completar la nueva población
4. Verificar la condición de parada
5. Repetir punto 2

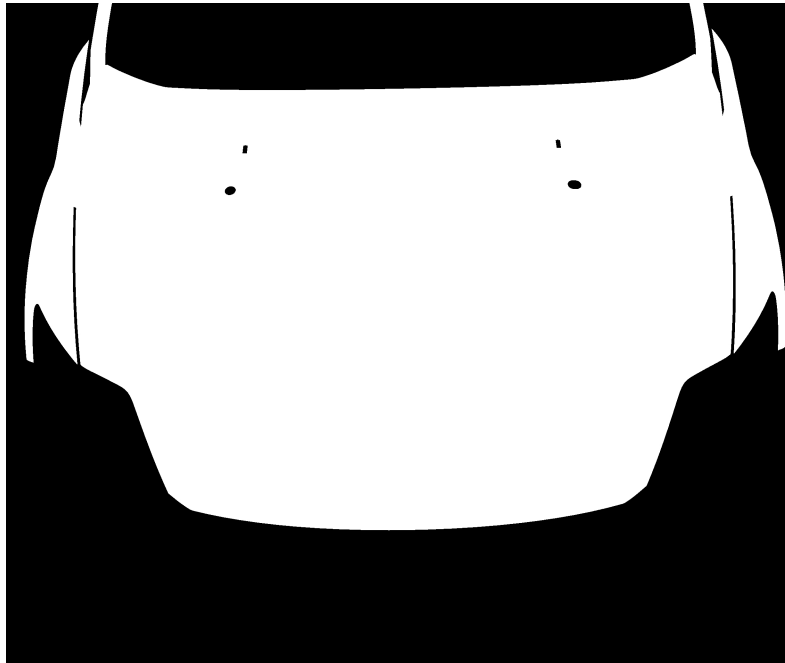
3.2. Individuo RGA

En el problema de optimización planteado, la solución que debemos buscar con el Algoritmo Genético es la posición de cámara que mejor se adecua en el CAD con la realidad. Por tanto, para codificar el **genotipo** del individuo en RGA se utilizarán los parámetros extrínsecos de la cámara: posición y rotación.



Los parámetros (X, Y, Z) son número de coma flotante que indica la posición en cada eje en milímetros (mm) mientras que los parámetros de rotación (α , β , γ) son números de coma flotante que definen grados.

El **fenotipo** del individuo será la vista en el CAD desde la cámara a recalibrar. Esta se corresponde a la proyección 2D de la carrocería del modelo 3D. A continuación se muestran algunos ejemplos:



Proyección 2D. Mondeo. Cámara 1 Túnel Genk



Proyección 2D. Mondeo. Cámara 12 Túnel Genk

3.3. Función Fitness RGA

La función fitness de RGA se calcula haciendo uso de los siguientes elementos:

- Fenotipo del individuo: proyección 2D, que se obtiene del CAD
- Máscara de Recalibración: se obtiene a partir de la Imagen de Referencia

La evaluación de la función fitness es un proceso costoso temporalmente ya que, al implicar un renderizado del CAD, puede tomar entre 10 y 30 segundos dependiendo del hardware donde se ejecute.

La función fitness es descendiente: a menor fitness, el individuo representa una mejor solución.

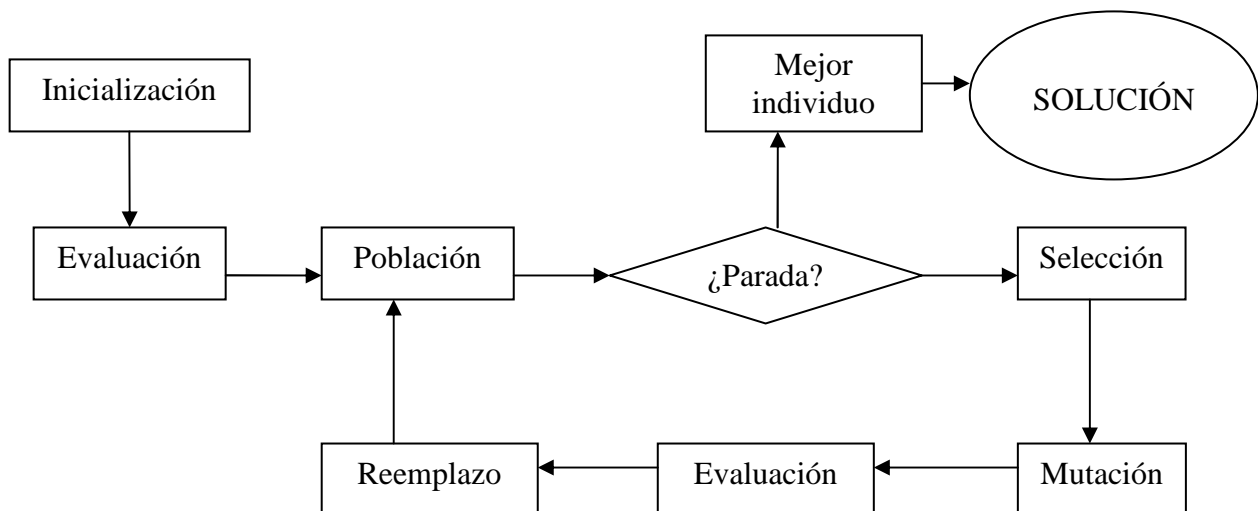
El detalle de la obtención del fitness se desarrolla en el siguiente capítulo.

3.4. Diseño de RGA

Para resolver el problema planteado se diseña un Algoritmo Genético de Recalibración o RGA que se aplicará de forma sucesiva para cada cámara de cada modelo de coche evaluado por el túnel de inspección.

Como filosofía del algoritmo, debido al alto coste computacional de la función fitness, se pretende mantener poblaciones pequeñas para evolucionarlas durante muchas generaciones aunque manteniendo un mínimo de variabilidad para evitar estancarse en un mínimo local. En este caso resultará clave la selección de los individuos a mantener y la evolución de los mismos.

También se tendrá en cuenta las características del individuo, que tiene pocos parámetros, y lo comentado anteriormente, pequeñas poblaciones pero que evolucionen mucho. El operador de cruce provocaría que todos los individuos convergieran a una solución común por lo que resulta razonable, para este caso, prescindir del operador de cruce.



El Algoritmo Genético de Recalibración RGA se compone de los siguientes elementos:

- Inicialización de Población
- Evaluación Fitness
- Ciclo evolutivo
 - o Selección
 - o Mutación
 - o Evaluación Fitness
 - o Reemplazo
- Condición de parada

3.4.1. Inicialización población

La población inicial de individuos se genera de forma aleatoria a partir de la posición definida en el CAD durante el diseño del túnel.

Para acotar el espacio de búsqueda, se define un rango independiente para cada parámetro del individuo.

Estos parámetros se establecen de forma empírica ya que dependiendo de la instalación del túnel real en la factoría. Hay que tener en cuenta que si se define un rango pequeño (por ejemplo 5 mm para posición) los individuos serán muy próximos al inicial, reduciendo la variabilidad e incluso imposibilitando la convergencia al óptimo global. En cambio un rango muy amplio (por ejemplo 1000 mm) sí posibilita la convergencia al óptimo global pero la variabilidad generaría muchos individuos de baja aptitud.

Otro parámetro a tener en cuenta es el tamaño de la población inicial. Por el diseño del algoritmo, como se explica en puntos posteriores, este parámetro tiene más influencia en la variabilidad inicial de la población que en el rendimiento del mismo aunque un tamaño excesivamente elevado también penalizaría el coste computacional.

A continuación se indica una configuración de compromiso, utilizada en muchas de las ejecuciones en producción del algoritmo:

- Población Inicial 50 individuos
- Posición
 - o Rango X 100 mm
 - o Rango Y 100 mm
 - o Rango Z 100 mm
- Rotación
 - o Rango α 5 °
 - o Rango β 5 °
 - o Rango γ 5 °

3.4.2. Selección

La estrategia utilizada en este algoritmo es la de mantener poblaciones reducidas, debido al alto coste computacional por la función fitness.

Inicialmente se seleccionan todos los individuos de la población. De esta forma se intenta dar una oportunidad a los individuos para demostrar su valía para ser solución del problema.

A partir de la quinta generación se empiezan a descartar individuos, en este caso se descartan los que tengan un TPiNC mayor a la media de la población.

```
foreach(individuo in Poblacion)
{
    if( num_generacion>5 && count(Poblacion[])>3) )
    {
        if(TPiNC(individuo)>MediaTPiNC)
        {
            Poblacion.descartar(individuo);
        }
    }
}
```

Como aclaración del código, la función TPiNC() se refiere a la función fitness.

Este rechazo se realiza generación a generación hasta quedarnos con los tres mejores individuos. De esta forma garantizamos un mínimo de variabilidad.

3.4.3. Evolución por mutación

Como se ha comentado en puntos anteriores, en el algoritmo RGA no hay cruce. Esto se debe a que hay pocos parámetros y, como se indica en el punto anterior, la población es muy reducida. En caso de haber cruce es muy probable que rápidamente todos los individuos converjan a una solución común.

La evolución en RGA se realiza solamente por mutación de parámetros, seleccionando en cada generación un número aleatorio de parámetros a mutar.

Para el operador de mutación se han desarrollado varias variantes que se desarrollan en posteriores capítulos.

3.4.4. Reemplazo

Los nuevos individuos generados en cada generación reemplazarán al padre si mejoran su aptitud. Si no mejoran la aptitud se mantendrá al padre en la población siendo el hijo rechazado. De esta forma se mantiene el tamaño de la población constante sin empeorar el fitness global.

3.4.5. Condición de parada

Un algoritmo genético puede conseguir un óptimo global cuando no tiene ninguna restricción temporal.

En nuestro caso, al ser una solución aplicada a un problema real, sí tenemos una restricción temporal. El RGA forma parte de una etapa del proceso de instalación del túnel de inspección, por lo que entre los objetivos de diseño está el que este algoritmo sea predecible su tiempo máximo de ejecución.

Como primera medida para controlar el tiempo, además de las establecidas en puntos anteriores, se define un número máximo de generaciones para evolucionar la población. Este parámetro del algoritmo se establece de forma empírica y depende del hardware en el que se va a ejecutar el algoritmo.

Como medida adicional, se establece un valor objetivo del fitness para así parar la ejecución del algoritmo si se tiene una solución aceptable. En este caso, al alcanzar el fitness objetivo no se detiene la ejecución si no que se mantiene 5 generaciones más, respetando el máximo establecido, para intentar conseguir un nuevo óptimo y seguir mejorando la población.

La condición de parada se codificaría de la siguiente forma:

```
[...]
MaxGeneraciones={parámetro de entrada};
TPiNC_objetivo={parámetro de entrada};
TPiNC_optimo=Poblacion.optimo();
maxGen_enObjetivo=5;
countGen_enObjetivo=0;
countGen=0;

while(countGen<Maxgeneraciones      &&      (TPiNC_optimo>TPiNC_objetivo      ||
countGen_enObjetivo<maxGen_enObjetivo))
{
    [...]

    if(TPiNC_optimo<TPiNC_objetivo)
    {
        TPiNC_objetivo=TPiNC_optimo;
        countGen_enObjetivo=0;
    }

    countGen_enObjetivo++;
    countGen++;
}
```

Con este tipo de condición de parada hace que el algoritmo sea predecible en su cota máximo de coste temporal y permite que se pueda planificar más fácilmente dentro de un proceso de instalación de nuevos túneles de inspección.

El valor típico utilizado en producción para el Número Total de Generaciones está entre 500 y 1500. Para el TPiNC objetivo está entre el 2% y el 5%.

3.4.6. Coste computacional

El coste de ejecución del algoritmo se puede estimar por la fórmula:

$$\text{Coste_Temporal_Algoritmo} = \text{Tiempo_Evaluación_Fitness} * (\text{Tam_Poblacion} * \text{Num_Generaciones_Arranque} (5) + \text{Minima_Poblacion} (3) * (\text{Num_Generaciones_Total} - \text{Num_Generaciones_Arranque}))$$

Durante el uso en producción del algoritmo se utilizaba las siguientes configuraciones, dependiendo del tiempo de evaluación de la función fitness en cada máquina:

Tiempo cada evaluación	10 seg	30 seg
Número máximo generaciones	1500	500
Tamaño población	50	50
Total tiempo algoritmo	$10 * (50*5 + 3*(1500-5)) = 47350 \text{ seg} \rightarrow 13\text{h } 10'$	$30 * (50*5 + 3*(500-5)) = 52050 \text{ seg} \rightarrow 14\text{h } 28'$

Cálculo de la Aptitud

Como se ha comentado en el capítulo anterior, el cálculo de la aptitud de un individuo se obtiene a partir de su fenotipo. El fenotipo se corresponde a la vista desde la posición de cámara, codificada en el genotipo, desde el CAD.

En el presente capítulo se detalla como se obtiene las imágenes desde el CAD (fenotipos).

Para medir el fitness del individuo se utiliza la Tasa de Píxeles No Coincidentes (TPiNC), función que hace uso de un fenotipo y de un patrón obtenido a partir de la imagen de referencia.

En el presente capítulo se desarrollan dos variantes de TPiNC. La segunda variante de TPiNC, denominada TPiNC2, se desarrolla para corregir deficiencias detectadas con las primeras variantes de RGA, detalladas en el capítulo siguiente.

4.1. Obtención de fenotipos: Integración con CAD

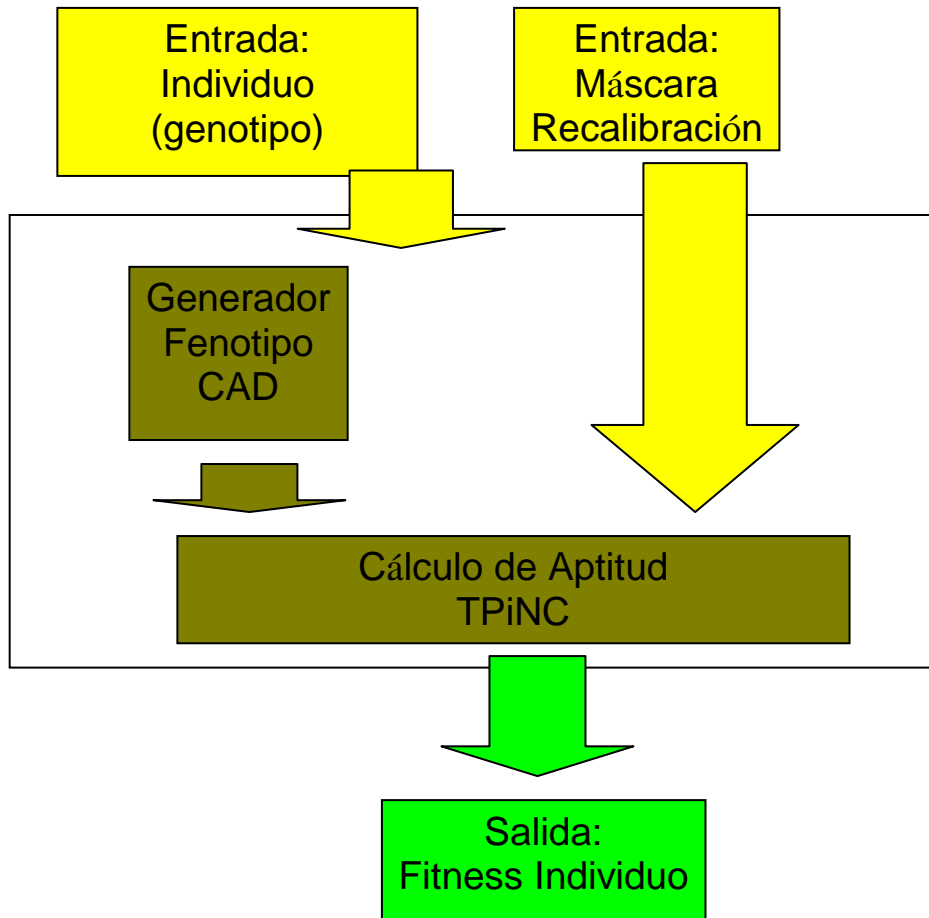
En el punto 1.3.1 y posteriores se apunta a que se ha desarrollado una utilidad para explotar las opciones de simulación de la herramienta CAD Unigraphics NX. Esta herramienta se amplía para incluir el RGA y así poder evaluar de forma correcta a los individuos.

De esta forma, cuando RGA genera nuevos individuos le indica a la herramienta CAD para que genere el fenotipo correspondiente a la posición de cámara.

Como se ha visto en el capítulo anterior, el fenotipo se corresponde con la proyección 3D en el CAD renderizada desde esa posición de cámara.


Siguiendo el esquema del RGA visto en el punto 3.4, el proceso de Evaluación o Fitness tendría los siguientes pasos:

Fitness RGA

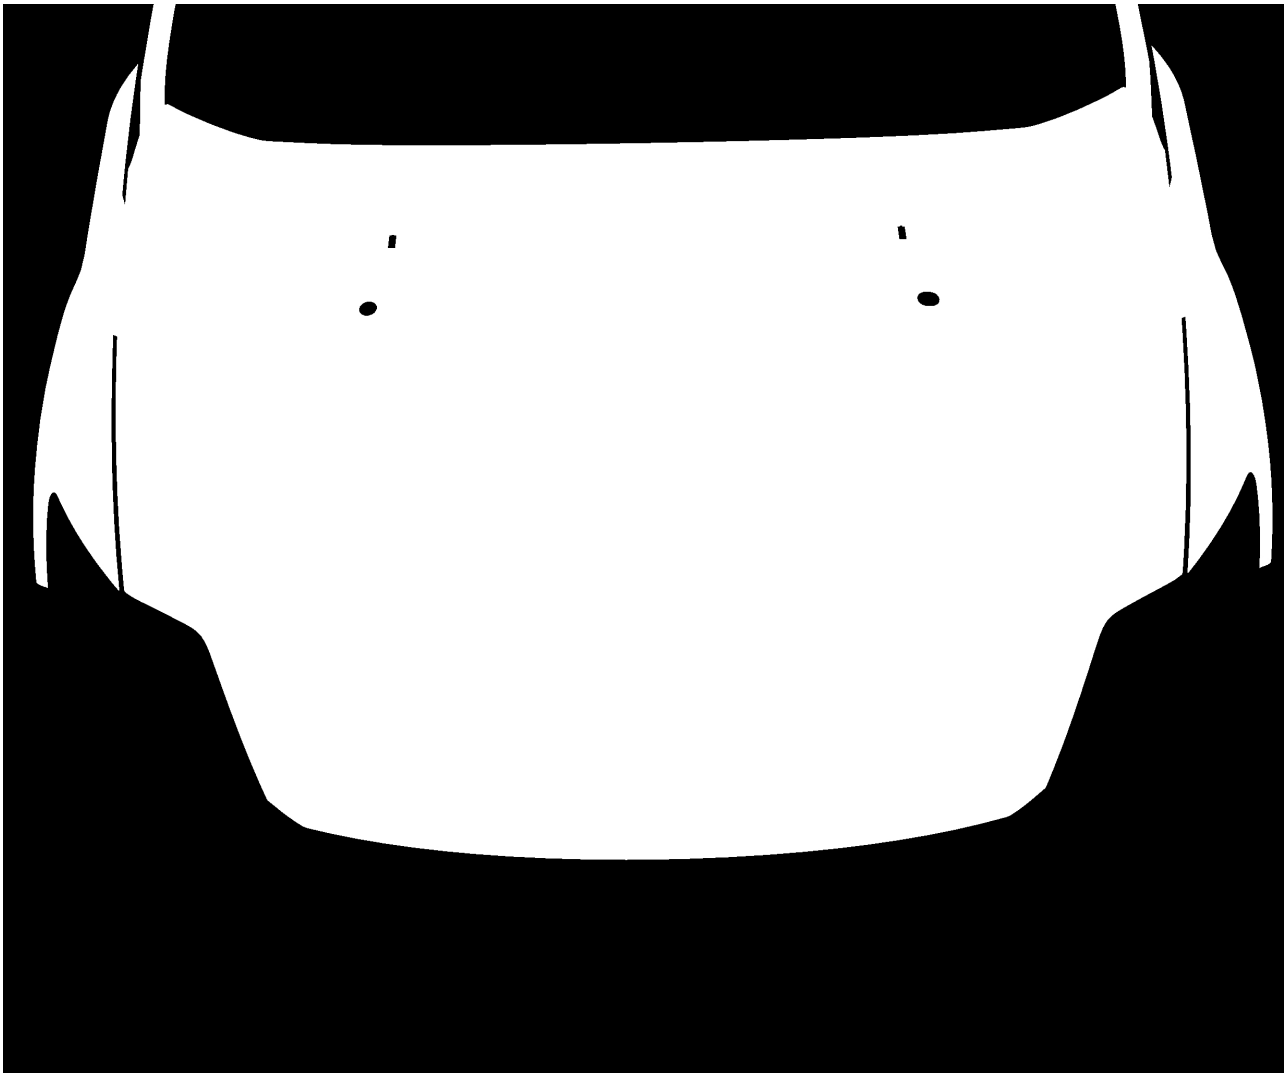


Este proceso de renderizado tiene una duración máxima de 30 segundos y mínima de 10 segundos, dependiendo del hardware desde el que se utilice creando una limitación que influye en el diseño del resto de componentes del algoritmo RGA.

En el CAD, además del túnel de inspección, se puede añadir el modelo de carrocería que se está recalibrando. Para evitar superposiciones en la proyección 2d del renderizado 3D se define un conjunto de piezas a visualizar por cada cámara. Esto se define para cada cámara en cada modelo a evaluar por el túnel de inspección.



Con la posición de cámara (genotipo) que le indica el RGA, el CAD obtiene la vista de esa cámara (fenotipo).



4.2. TPiNC

Para medir el fitness de los individuos se utilizará la Tasa de Píxeles No Coincidentes (TPiNC). Esta tasa consiste en obtener un ratio entre los píxeles de una máscara de recalibración que no coinciden con la pieza y el número total de píxeles de la máscara. Esta tasa se representará como un porcentaje.

4.2.1. Obtención de la máscara de recalibración


A partir de la imagen de referencia se obtiene, mediante un editor de gráficos, la silueta de las piezas vistas desde la cámara.

Esta silueta solo contendrá piezas visibles y que correspondan a partes externas de la carrocería que vayan a ser pintadas.

En el proceso de edición de la silueta, se eliminarán las partes internas de la carrocerías que no van a ser pintadas como piezas de soporte o las del propio túnel.

Con la silueta ya definida, se utilizará el color rojo para marcar la parte que corresponde a piezas del coche y en negro el resto.

Obtención de Máscara a partir de Imagen de Referencia



4.2.2. Cálculo TPiNC

La Tasa de Píxeles No Coincidentes o TPiNC se calcula a partir de la máscara de recalibración y del fenotipo del individuo generado por el CAD.

Como se ha comentado en puntos anteriores, el fenotipo del individuo es una imagen donde las partes que corresponden a una pieza de la carrocería son de color blanco y las que no de color negro.

Del mismo modo, en la máscara de recalibración, los píxeles que corresponden a piezas son de color rojo y los que no de color negro.

Ambas imágenes, el fenotipo y la máscara, tienen las mismas dimensiones.


Para el cálculo de TPiNC se tendrá en cuenta el total de píxeles de color rojo (piezas) y se contabilizarán los píxeles que en la máscara son rojos y que en el fenotipo no corresponden a blanco, es decir, que no coinciden con pieza. El TPiNC será el ratio (porcentaje) de entre estos píxeles no coincidentes (rojos) y el total de píxeles rojos (de pieza) de la máscara.

$$TPiNC = 100 * \text{PíxelesRojosNoCoinciden} / \text{TotalPíxelesRojosMascara}$$

El objetivo de RGA es minimizar el TPiNC.

4.2.3. Validación visual con TPiNC

Para validar visualmente los fenotipos de cada individuo respecto a la máscara de recalibración, se hará una superposición del fenotipo obtenido del CAD con la máscara de recalibración. Un ejemplo del resultado sería el siguiente:



El criterio con los colores sería el siguiente:

Color	Efecto en TPiNC2
Pink	Contorno interior de la máscara que se superpone con la pieza. No penaliza TPiNC2
Grey	Contorno interior de la máscara que no se superpone con la pieza. Penaliza TPiNC2

4.3. TPiNC2

Debido a la detección de imprecisiones en los resultados de las primeras variantes de RGA, se decide revisar el cálculo del fitness, definiendo la que se denomina como TPiNC2.

4.3.1. Obtención de la máscara de doble contorno

Para el cálculo de la nueva aptitud se plantea cambiar la tipología de máscaras de recalibración utilizadas por otro tipo para que se ajusten mejor a la pieza o piezas de la vista de la cámara a recalibrar calibrar.

Las máscaras que se utilizaban hasta este momento cubren la totalidad de las piezas que se reflejan en la vista de la cámara. La problemática detectada con estas máscaras es que no respetan los bordes de la pieza de forma correcta.

Por tanto, se plantea utilizar máscaras que se correspondan al contorno de cada pieza, para así intentar que la máscara no solo esté contenida dentro de la pieza sino que además se ajuste lo más posible a sus bordes.

Para esto, se plantea utilizar máscaras que contemplen el contorno interior de la pieza así como el contorno exterior. A estas máscaras las denominaremos Máscara de Doble Contorno.

Obtención de Máscara Doble Contorno a partir de Imagen de Referencia




Imagen de Referencia

Máscara Doble Contorno

En estas máscaras, se pintará de color rojo los píxeles del borde interno que corresponde a pieza y de color azul los que correspondan a la parte externa y por tanto no corresponde a pieza.

4.3.2. Cálculo TPiNC2


De forma similar al TPiNC, el TPiNC2 se calcula a partir de la máscara de doble contorno y del fenotipo del individuo generado por el CAD.

Para el cálculo de TPiNC2 se tendrá en cuenta el total de píxeles de color rojo (piezas) junto a los píxeles azules (exterior pieza). Se contabilizarán los píxeles que en la máscara son rojos y que en el fenotipo no corresponden a blanco, es decir, que no coinciden con pieza, y los píxeles azules de la máscara que se correspondan con un píxel blanco del fenotipo. El TPiNC2 será el ratio (porcentaje) de entre estos píxeles coincidentes (azules) y no coincidentes (rojos) y el total de píxeles rojos y azules de la máscara.

$$TPiNC2 = 100 * (PíxelesRojosNC + PíxelesAzulesSC) / TotalPíxelesMascara)$$

4.3.3. Validación visual con TPiNC2

Para validar visualmente los fenotipos de cada individuo respecto a la máscara de recalibración, se hará una superposición del fenotipo obtenido del CAD con la máscara de recalibración. Un ejemplo del resultado sería el siguiente:



El criterio con los colores sería el siguiente:

Color	Efecto en TPiNC2
Cian	Contorno exterior de la máscara que no se superpone con la pieza. No penaliza TPiNC2
Amarillo	Contorno exterior de la máscara que se superpone con la pieza. Penaliza TPiNC2
Rosa	Contorno interior de la máscara que se superpone con la pieza. No penaliza TPiNC2
Gris	Contorno interior de la máscara que no se superpone con la pieza. Penaliza TPiNC2

Variantes y validación de RGA

Como se ha comentado en puntos anteriores, a continuación se detalla las variantes evaluadas para este algoritmo. Estas variantes se centran en el operador de mutación, siendo similares en el resto de etapas.

Todas las variantes tienen en común que en cada ciclo de evolución se modifica un número aleatorio de parámetros (de 1 a 6) y que el nuevo valor para el parámetro estará, al menos, dentro del rango indicado al inicializar la población.

En los siguientes apartados se detallan las distintas variantes y los resultados obtenidos al recalibrar una cámara concreta del mismo túnel de inspección y para el mismo modelo de coche.

5.1. RGA_1


La idea con esta variante es buscar al nuevo individuo cerca del mismo individuo en la generación anterior. Para conseguir esto, se le aplica un factor de reducción al rango de búsqueda de cada parámetro definido al inicializar la población. Este factor de reducción es proporcional a la cercanía con el óptimo de esta forma los individuos con peor fitness tendrán un rango más amplio de búsqueda.

A lo largo de la ejecución, este cambio en el rango de búsqueda da como resultado que el rango de búsqueda de un parámetro es muy reducido.

Características principales de esta variante:

- Parámetros a mutar: `aleatorio(6)`
 - Rango de búsqueda de cada parámetro: `rangoInicial * FactorReduccion`
- `FactorReduccion = max(0.01, (TPiNC_individuo- TPiNC_optimo) /TPiNC_optimo)`

A continuación se muestra la evolución del mejor individuo, para una ejecución con un máximo de 500 ciclos y un TPiNC objetivo de 0%, para la cámara 12 del Mondeo en el túnel de Genk.



Mejor TPiNC: 3,15%

5.2. RGA_2

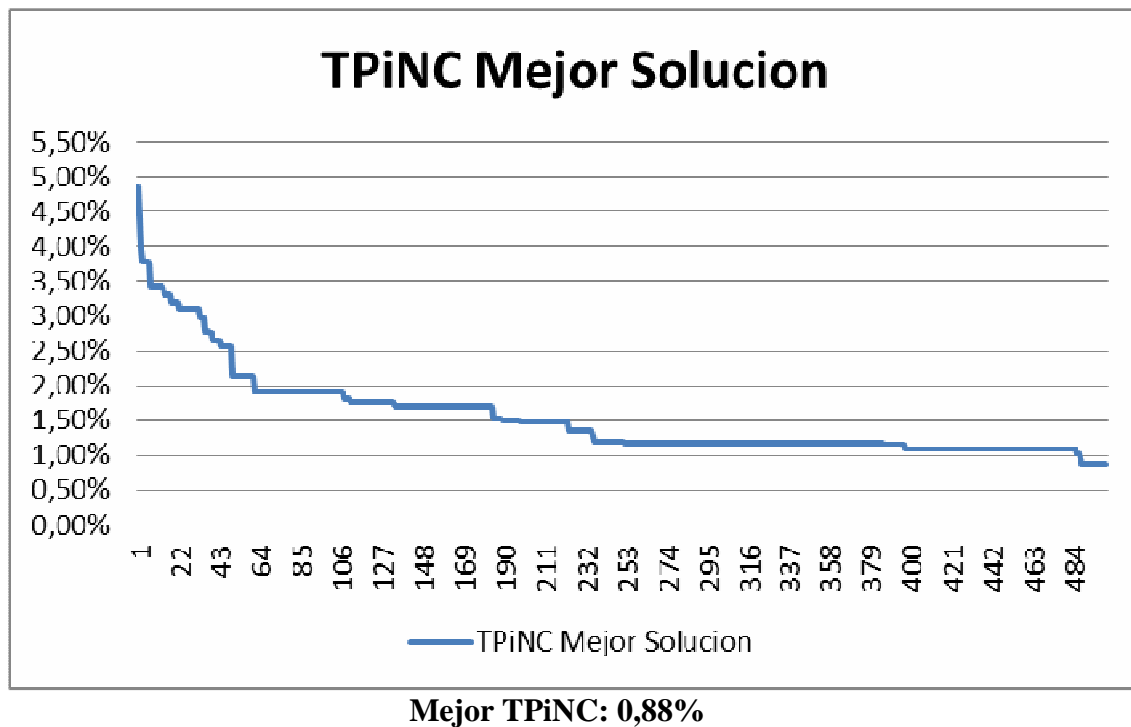
En esta variante la idea es realizar la búsqueda en la totalidad del rango definido en la inicialización. Este cambio da como resultado que el rango de búsqueda de un parámetro se mantiene amplio.

Características principales de esta variante:

- Parámetros a mutar: `aleatorio(6)`
- Rango de búsqueda de cada parámetro: `rangoInicial * FactorReduccion`

`FactorReduccion = 1`

A continuación se muestra la evolución del mejor individuo, para una ejecución con un máximo de 500 generaciones y un TPiNC objetivo de 0%, para la cámara 12 del Mondeo en el túnel de Genk.



5.3. RGA_3

En esta variante, se reduce el rango de búsqueda de cada parámetro proporcionalmente al TPiNC.

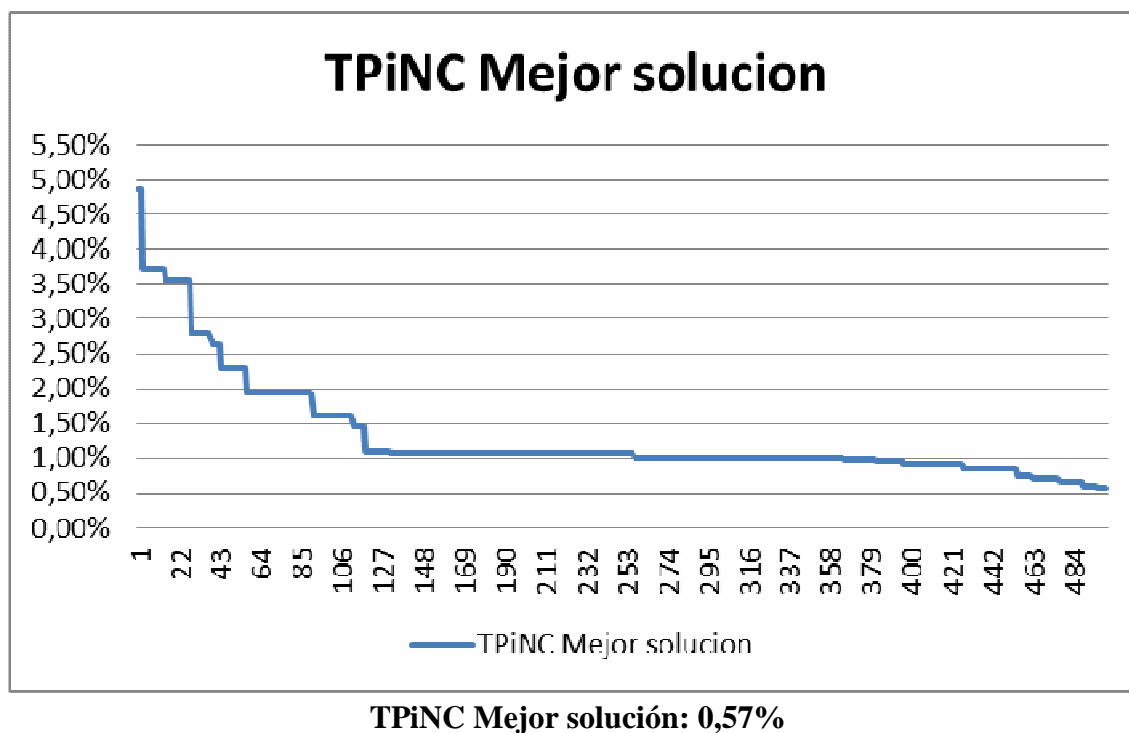
Este cambio en el rango de búsqueda da como resultado que inicialmente el rango de búsqueda del parámetro es amplio para, conforme mejora la solución, reducirlo. De esta forma los mejores individuos buscarán la nueva solución cerca, en cambio los peores individuos explorarán en el espacio de búsqueda para mejorar más rápidamente. Esta forma de proceder se conoce como “enfriamiento simulado”.

Características principales de esta variante:

- Parámetros a mutar: aleatorio(6)
- Rango de búsqueda de cada parámetro: rangoInicial * FactorReduccion

$$\text{FactorReduccion} = \text{TPiNC}$$

A continuación se muestra la evolución del mejor individuo, para una ejecución con un máximo de 500 generaciones y un TPiNC objetivo de 0%, para la cámara 12 del Mondeo en el túnel de Genk.




5.4. Validación de variantes

Con las variantes presentadas hasta ahora, en base al fitness, resolvemos el problema de forma automatizada.

Concluimos que con rangos amplios de búsqueda se obtienen buenas soluciones iniciales y con rangos pequeños se consigue afinar mejor el resultado, por lo que concluimos que con enfriamiento simulado (RGA_3) conseguimos los mejores resultados, ya que es con la que se obtiene mejor fitness.

Con la mejor solución obtenida, realizamos una validación cualitativa del resultado. La superposición con la imagen de referencia es la siguiente:



Como se puede ver en la imagen, los píxeles de la máscara de recalibración coinciden con los píxeles de la vista con la cámara en el CAD. Esto se representa con los píxeles color rosa.

Este resultado es muy bueno a nivel de aptitud, ya que el TPiNC es cercano a cero, pero a nivel cualitativo no satisface los requisitos del sistema por lo que se plantea realizar algunas mejoras adicionales.

5.5. Diseño nueva variante: RGA_4

En el punto anterior se ha comprobado que la solución obtenida no es adecuada tras una valoración cualitativa, aunque en base al fitness sí que parecía adecuada.

En este punto nos planteamos utilizar una métrica diferente para la aptitud, por lo que optamos por utilizar TPiNC2 para representar de forma más fiel la bondad o no de una solución con RGA.


En esta variante, se sigue la misma estrategia que en RGA_3, el enfriamiento simulado. Tan solo se cambia el cálculo de la aptitud, que pasa a ser TPiNC2.

Características principales de esta variante:

- Parámetros a mutar: `aleatorio(6)`
- Rango de búsqueda de cada parámetro: `rangoInicial * FactorReduccion`

`FactorReduccion= TPiNC2`


A continuación se muestra la evolución del mejor individuo, para una ejecución con un máximo de 500 generaciones y un TPiNC2 objetivo de 0%, para la cámara 12 del Mondeo en el túnel de Genk.



TPiNC2 Mejor solución: 4,66%

5.6. Validación de RGA_4

Con la mejor solución obtenida, realizamos una validación cualitativa del resultado. La superposición con la imagen de referencia es la siguiente:




Con este resultado confirmamos que la alternativa RGA_4 es con la que se obtiene la mejor solución al problema.


5.7. Comparación resultados TPiNC y TPiNC2

Con la variante RGA_3 se había obtenido el mejor resultado con la medida de la aptitud TPiNC.

Para poder comparar resultados con las nuevas variantes que se han desarrollado con TPiNC2, se actualiza la aptitud de la mejor solución con RGA_3 para la nueva aptitud:



RGA_3 TPiNC: 0,57%



RGA_3 TPiNC2: 10,22%

A continuación la posición de cámara recalibrada con los dos métodos, comparando el TPiNC2 obtenido en cada caso.


Se concluye que con RGA_4 se consigue la mejor solución de forma más consistente.

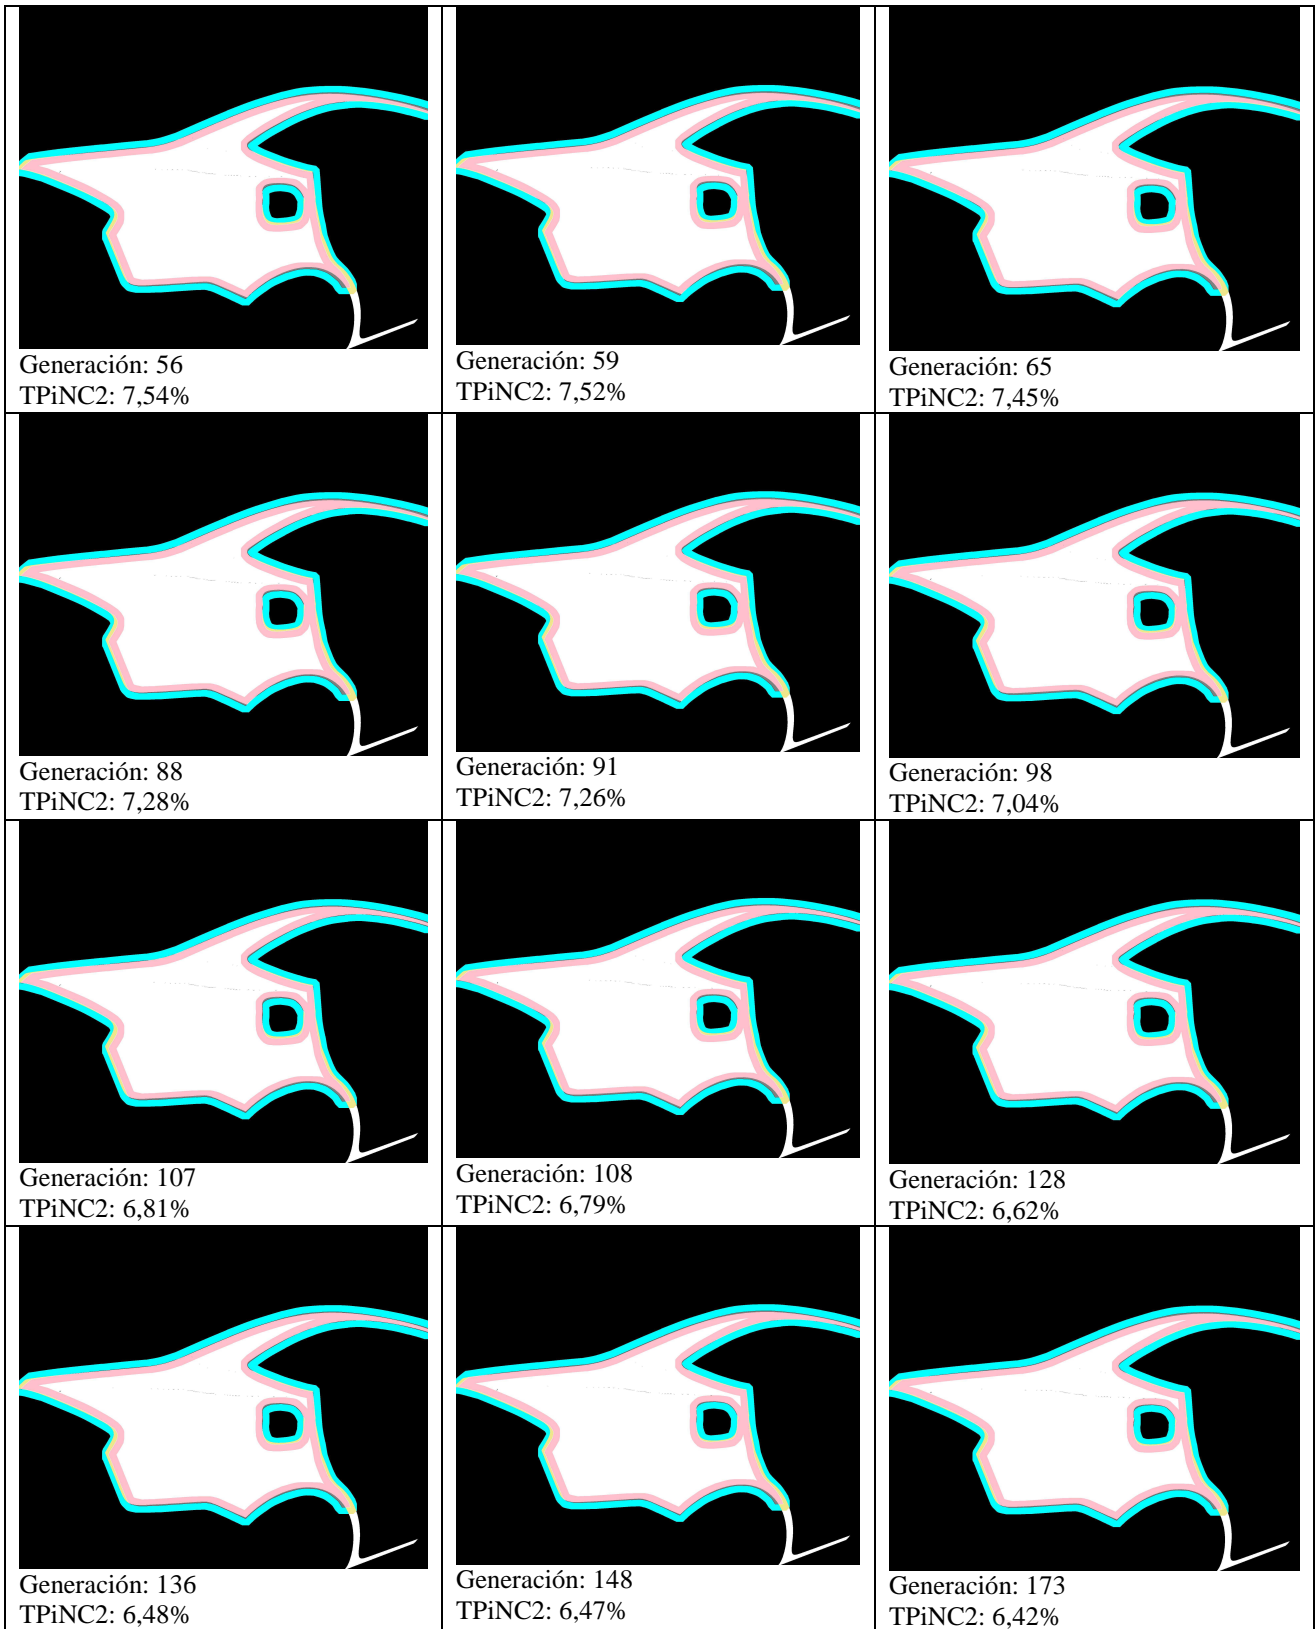
El ejemplo analizado en los ejemplos de las variantes es la cámara 12 para modelo MONDEO del túnel de inspección de la planta de Genk. A continuación se muestran los resultados obtenidos con los métodos RGA_3 y RGA_4.


	INICIAL	RGA_3	RGA_4
X	4720	4704,17637208443	4758,56739926059
Y	2000	1964,54285026972	1951,16989595896
Z	1100	1100,39702789709	1133,49904025530
α	94	94,45736096	96,00000001
β	328	328,1215387	326,3428575
γ	0	0,394974685	1,04669963
TPiNC2	20,43%	10,22%	4,66%

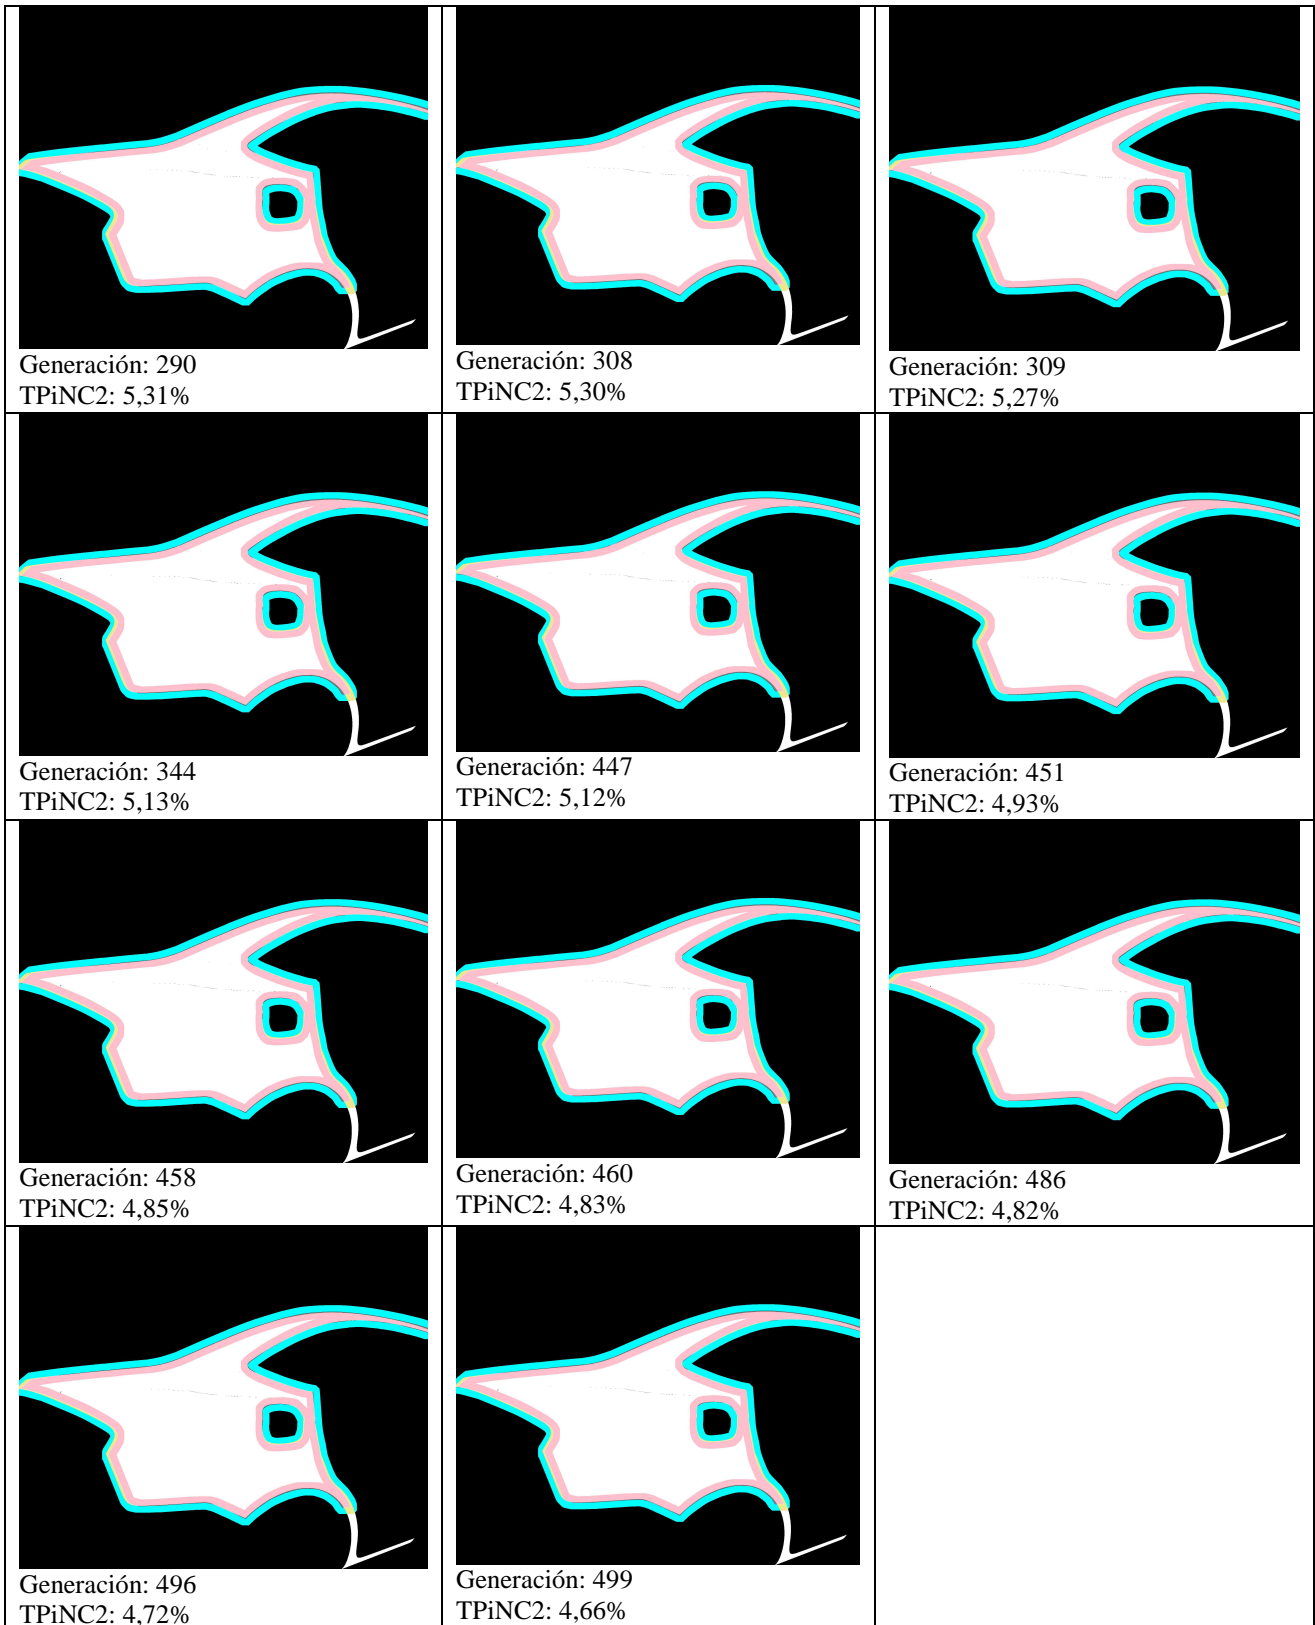
5.8. Ejecución de RGA_4

Para ilustrar la evolución del algoritmo con la variante RGA_4, se muestran la secuencia completa de los fenotipos de los mejores individuos para 500 generaciones con un TPiNC2 objetivo de 0% para la cámara 12 del Mondeo en el túnel de Genk:









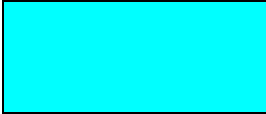
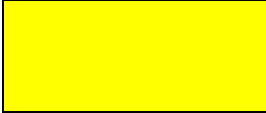


Resultados en producción

Como se ha comentado en varios puntos de este TFM, el algoritmo RGA se ha utilizado en producción para la instalación de varios túneles de inspección.

En este apartado se mostrarán los resultados de varias recalibraciones realizadas con la variante RGA_4 durante la instalación del túnel de Almussafes y los dos túneles de Dearborn, realizadas en el año 2012.

En cada caso se mostrará el fenotipo con la máscara superpuesta tanto antes de recalibrar como después, así como la evolución del TPiNC2 del mejor resultado y para la media así como el TPiNC2 de cada individuo de la población inicial.

En la superposición del fenotipo con la máscara de doble contorno, los colores que aparecen tendrán el siguiente significado:


Color	Efecto en TPiNC2
	Contorno exterior de la máscara que no se superpone con la pieza. No penaliza TPiNC2
	Contorno exterior de la máscara que se superpone con la pieza. Penaliza TPiNC2
	Contorno interior de la máscara que se superpone con la pieza. No penaliza TPiNC2
	Contorno interior de la máscara que no se superpone con la pieza. Penaliza TPiNC2

6.1. Resultados instalación Almussafes


6.1.1. Modelo CMAV. Cámara 12

Recalibración de cámara 12 para el modelo CMAV de la instalación para la planta de Almussafes del túnel de inspección. Se utiliza la siguiente configuración:




- Tamaño población: 100 individuos
- N° máximo de generaciones: 100
- TPiNC2 objetivo: 4%



Fenotipo Inicial



Fenotipo mejor solución




	Inicial	Mejor Solución
X	4880	4891,26932
Y	1950	1951,8595
Z	1300	1304,93681
α	100	100,3034514
β	330	330,055313
γ	-90	-90,3492741
TPiNC2	9,02%	4,97%


6.1.2. Modelo KUGA. Cámara 8

Recalibración de cámara 8 para el modelo KUGA de la instalación para la planta de Almussafes del túnel de inspección. Se utiliza la siguiente configuración:




- Tamaño población: 20 individuos
- N° máximo de generaciones: 550
- TPiNC2 objetivo: 4%



Fenotipo Inicial



Fenotipo mejor solución




	Inicial	Mejor Solución
X	4794	4846,97728
Y	-1890	-1908,81214
Z	1313	1308,51933
α	80	78,8918656
β	210	210,266432
γ	90	90,6983278
TPiNC2	19,92%	4,76%

6.2. Resultados instalación Túnel 1 Dearborn

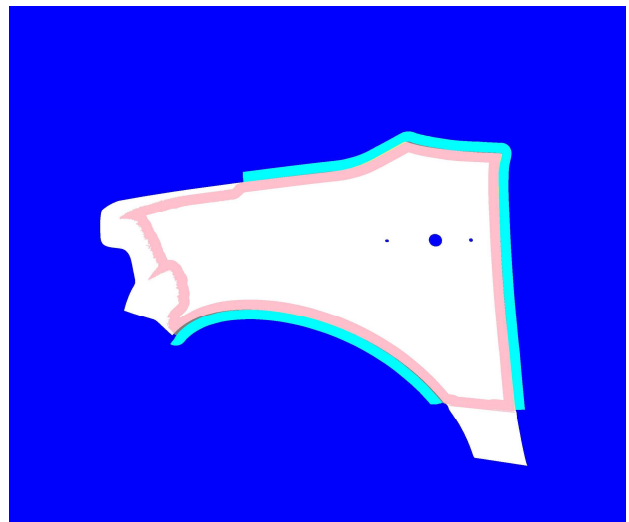
6.2.1. Modelo CREW CAB. Cámara 6

Recalibración de cámara 6 para el modelo CREW CAB de la instalación del Túnel 1 para la planta de Dearborn. Se utiliza la siguiente configuración:




- Tamaño población: 50 individuos
- N° máximo de generaciones: 950
- TPiNC2 objetivo: 1%



Fenotipo Inicial



Fenotipo mejor solución




	Inicial	Mejor Solución
X	1675	1668,9339
Y	-2073	-2061,70911
Z	1450	1443,73062
α	60	60,0323821
β	204	203,633211
γ	0	0,05398448
TPiNC2	7,42%	1,69%


6.2.2. Modelo CREW CAB. Cámara 7

Recalibración de cámara 7 para el modelo CREW CAB de la instalación del Túnel 1 para la planta de Dearborn. Se utiliza la siguiente configuración:




- Tamaño población: 100 individuos
- N° máximo de generaciones: 1500
- TPiNC2 objetivo: 2%



Fenotipo Inicial



Fenotipo mejor solución




	Inicial	Mejor Solución
X	2970	2987,7723
Y	-2067	-2032,03053
Z	785	767,914772
α	83	83,6814492
β	209	210,245271
γ	-0,6	0,30493477
TPiNC2	13,38%	2,57%

6.3. Resultados instalación Túnel 2 Dearborn

6.3.1. Modelo REG CAB. Cámara 12

Recalibración de cámara 12 para el modelo REG CAB de la instalación del Túnel 2 para la planta de Dearborn. Se utiliza la siguiente configuración:




- Tamaño población: 50 individuos
- N° máximo de generaciones: 1500
- TPiNC2 objetivo: 1%



Fenotipo Inicial



Fenotipo mejor solución




	Inicial	Mejor Solución
X	3993	3977,121
Y	2086	2162,651
Z	1007	926,799479
α	94	91,2239607
β	-26	-23,0005296
γ	270	268,116597
TPiNC2	35,68%	1,97%

6.3.2. Modelo CREW CAB RAPTOR. Cámara 4


Recalibración de cámara 4 para el modelo CREW CAB RAPTOR de la instalación del Túnel 2 para la planta de Dearborn. Se utiliza la siguiente configuración:

- Tamaño población: 10 individuos
- N° máximo de generaciones: 500
- TPiNC2 objetivo: 1%




En esta ejecución, el algoritmo para de forma prematura al conseguir el TPiNC2 objetivo.



Fenotipo Inicial



Fenotipo mejor solución




	Inicial	Mejor Solución
X	4150	4137,49216
Y	20	13,4634444
Z	2796	2811,53832
α	22	-0,06342219
β	208	207,044665
γ	270	269,924936
TPiNC2	2,22%	0,76%


6.3.3. Modelo CREW CAB RAPTOR. Cámara 1

Recalibración de cámara 1 para el modelo CREW CAB RAPTOR de la instalación del Túnel 2 para la planta de Dearborn. Se utiliza la siguiente configuración:




- Tamaño población: 100 individuos
- N° máximo de generaciones: 800
- TPiNC2 objetivo: 2%



Fenotipo Inicial



Fenotipo mejor solución




	Inicial	Mejor Solución
X	-780	-716,282447
Y	-375	-319,977589
Z	2810	2855,88453
α	-2	-3,837792
β	144	145,415977
γ	0	3,44255707
TPiNC2	24,83%	3,56%


6.3.4. Modelo CREW 55 BOX. Cámara 11

Recalibración de cámara 11 para el modelo CREW 55 BOX de la instalación del Túnel 2 para la planta de Dearborn. Se utiliza la siguiente configuración:




- Tamaño población: 50 individuos
- N° máximo de generaciones: 1500
- TPiNC2 objetivo: 3%



Fenotipo Inicial



Fenotipo mejor solución



	Inicial	Mejor Solución
X	2977	2947,11408
Y	2071	2079,51489
Z	780	743,852996
α	97	94,3610853
β	-30	-27,0122737
γ	0,30	-0,25948665
TPiNC2	29,24%	3,52%

Capítulo 7

Conclusiones

En base a los resultados obtenidos y a la posterior aplicación en producción del algoritmo diseñado, se puede concluir:

- Se ha aplicado la metodología de Algoritmos Genéticos para resolver un problema real.
- El algoritmo converge a una solución óptima tanto en el caso de partir de una buena solución (ejemplos en apartados 6.1.1, 6.2.1, 6.2.2 y 6.3.2) como partiendo de una solución con baja aptitud (ejemplos en apartados 6.3.1, 6.3.3 y 6.3.4).
- La confiabilidad en la convergencia del algoritmo permite reducir el tiempo dedicado durante el montaje físico y calibración manual de las cámaras, por lo que reduce los tiempos globales de instalación del túnel de inspección en la factoría.
- El rendimiento de la variante RGA_4, que se utilizó en producción, permite tener un algoritmo predecible en su resultado y limitado en su tiempo máximo de ejecución. Esto permite tener un proceso que se pueda planificar, ya que se conoce su duración, dentro del proceso de instalación del túnel de inspección.

[Tornero, 2011] J. Tornero et al (2011). Detección de Defectos en Carrocerías de Vehículos Basado en Visión Artificial: Diseño e Implantación. *Revista Iberoamericana de Automática en Informática Industrial*, RIAI Elsevier (00): 1-12.

[Faugeras, 1993] O. Faugeras (1993). *Three-dimensional computer vision: a geometric viewpoint*. MIT Press.

[Tsai, 1987] R. Y. Tsai (1987). A versatile camera calibration technique for high-accuracy 3d machine vision metrology using off-the shelf tv cameras and lenses. *IEEE Journal of Robotics and Automation*, RA-3(4):323–344.

[Zhang, 2000] Z. Zhang (2000). A flexible new technique for camera calibration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(11):1330–1334.

[Holland, 1975] J. H. Holland (1975). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. University of Michigan Press, Ann Arbor.