



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Optimización de trayectorias para AGVs mediante algoritmos genéticos.

Bayona, E.^{a,*}, Sierra-García, J.E.^b, Santos, M.^c

^a Departamento de Ingeniería, Electromecánica, Universidad de Burgos, Burgos, España.

^b Departamento de Ingeniería, Electromecánica, Universidad de Burgos, Burgos, España.

^c Instituto de Tecnología del Conocimiento, Universidad Complutense de Madrid, Madrid, España.

To cite this article: Bayona, E., Sierra-García, J.E., Santos, M.. 2022. Trajectory optimisation for AGVs using genetic algorithms. XVII Simposio CEA de Control Inteligente.

Resumen

La búsqueda de la eficiencia y la mejora continua de los procesos productivos está aumentando su automatización. Los vehículos de guiado automático (AGV) usados para transporte, son elementos clave a la hora de cumplir esta función, siendo fundamental el desarrollo y mejora de sus sistemas de navegación y posicionamiento. Así, en este trabajo se propone el uso de una técnica evolutiva, los algoritmos genéticos (AG), con el fin de obtener los parámetros óptimos de un método de generación de trayectorias. Se utiliza un modelo de mapa de ocupación para el diseño del entorno con el fin de verificar posibles eventos de colisión con el AGV. Se simulan diferentes escenarios donde se busca optimizar la longitud de la trayectoria generada evitando colisiones. Los resultados de la simulación muestran que el algoritmo es capaz de minimizar la longitud de las trayectorias generadas evitando las posibles colisiones.

Palabras clave: Soft Computing, Algoritmos Genéticos, Vehículos Guiados Automáticamente (AGV), Industria 4.0, Trayectorias.

Optimization of trajectory generation for automatic guided vehicles by genetic algorithms

Abstract

Continuous improvement of industrial and production processes for efficiency optimization has led to an increase in the need for automatization. Automatic guided vehicles (AGV) are key transport elements when it comes to fulfilling this function, as well as the development and improvement of their navigation and positioning systems. Thus, in this work the use of a Soft Computing evolutive technique, genetic algorithms (GA), is proposed in order to obtain the optimal parameters of a trajectory generation method. An occupancy map model for the environment layout is used in order to check collision events with the AGV. Different scenarios have been simulated to optimize the trajectory length avoiding collisions if possible. Simulation results show that the algorithm is able to minimize the length of the path successfully.

Keywords: Soft computing, Automatic Guided Vehicle (AGV), Genetic Algorithms (GA), Industry 4.0, Trajectories.

1. Introducción

Los procesos productivos están en constante cambio y estudio para evaluar su eficiencia y posibilidad de optimización tanto en términos de productividad como de seguridad. De esta necesidad de mejora continua surge la intención de automatizar partes de un proceso donde la presencia física de una persona no es necesaria. Un aspecto clave de los procesos productivos es la intralógica o logística interna, para ello

existen diferentes tipos de soluciones que permiten automatizar el transporte interno de materia prima, productos, mercancías, etc. (Echeverri and Escolar, 2012), (Vis, 2006). Los vehículos de guiado automático (AGV) cumplen con esta función, y tienen un campo de aplicación amplio en constante aumento. Los sectores comerciales en los que se puede utilizar AGV incluyen terminales de transporte de contenedores, líneas de producción, almacenes logísticos, agricultura, operaciones militares, gestión de la salud, entre otros (Bechtis *et al.*, 2017), (Bostelman and Messina, 2016). Los AGV son robots móviles

capaces de auto-dirigirse dentro de un entorno siguiendo caminos físicos o virtuales, y aportan una notable mejora en los procesos productivos, reduciendo costes, aumentando la producción y optimizando la seguridad en los mismos (Espinosa and Sierra-García, 2021).

Mediante el uso de diferentes tecnologías de sensado y monitorización del movimiento, los AGV son capaces de realizar diferentes funciones en paralelo a sus principales funciones de movimiento, como cargar y descargar mercancías o interactuar con otros agentes dentro de su entorno operativo, como seres humanos u otros robots. Utilizando diferentes sensores de navegación y guiado para obtener información de su estado, los AGV son capaces de usar controladores (normalmente PID) para seguir caminos marcados y trayectorias correctamente (Zhang *et al.*, 2018). Algunos trabajos anteriores se han centrado en la definición de las curvas de movimiento que definen esas trayectorias (Farouki, 2000).

Para generar las trayectorias que debe seguir el AGV, en este trabajo se utilizan métodos numéricos basados en fórmulas de Frenet-Serret. Este método ajusta una curva continua polinómica de cuarto y quinto orden de forma suave a lo largo de una serie de puntos de referencia previamente definidos. Estos puntos de paso determinan la forma final de la trayectoria. Reducir la longitud del trayecto, reduciendo así el tiempo de viaje, tiene un impacto directo en los tiempos de producción y por tanto en la productividad de los procesos donde se implementan soluciones de transporte automatizado con estos AGVs. Por ello, este trabajo se centra en la optimización mediante algoritmos genéticos del trayecto a seguir por el AGV hasta llegar a un destino sorteando obstáculos.

Estas técnicas evolutivas ya se han utilizado con éxito en trabajos anteriores. En (Larrazabal and Peñas, 2016) los algoritmos genéticos se utilizan para optimizar el control del timón de un barco no tripulado. En (Alouache and Wu, 2018), se utilizan para mejorar el seguimiento de una trayectoria de un robot móvil. En (Abajo *et al.*, 2021) se propone un método de optimización para el ajuste de un controlador PID de AGV que ordena al robot que siga diferentes trayectorias.

Las técnicas de *Soft Computing* se han venido aplicando con éxito para modelar y controlar sistemas físicos (Sierra-García and Santos, 2021), (Santos and Cantos, 2010). En este trabajo, se utilizan algoritmos genéticos para optimizar la ruta del AGV desde un punto inicial hasta un punto final. El algoritmo tiene en consideración si existe un evento de colisión entre el AGV y algún elemento del entorno físico. La función de coste está diseñada con dos objetivos en mente: minimizar la longitud total del camino entre los puntos inicial y final, y evitar que el AGV colisione con los elementos en el mapa de ocupación. Por lo tanto, la trayectoria con el valor de función de coste más bajo será aquella más corta posible que evita colisiones con el entorno. Esto puede ser de gran utilidad en la automatización del proceso de generación de rutas en una implementación de AGV en un escenario industrial.

El resto del documento está organizado de la siguiente manera. La sección 2 describe el modelo utilizado para simular el espacio de trabajo del AGV utilizando un mapa de ocupación. La Sección 3 explica la metodología y el algoritmo genético implementado para la optimización del proceso de generación

de trayectorias. En la Sección 4 se resumen y presentan los resultados de las simulaciones bajo tres escenarios diferentes. La última sección presenta las conclusiones y trabajos futuros.

2. Modelado del entorno de trabajo

La definición del entorno de trabajo que el algoritmo tiene en cuenta para detectar posibles colisiones se realiza mediante un mapa de ocupación binaria. Este tipo de mapas se utilizan para modelar y visualizar el espacio de trabajo del robot, creando una representación espacial de la ubicación de los obstáculos como una cuadrícula discreta. Las cuadrículas de ocupación se utilizan habitualmente en robótica para aplicaciones de mapeo y planificación de rutas. Cada celda de la cuadrícula tiene un valor que representa su estado de ocupación. La representación matemática de la cuadrícula de ocupación se muestra en (1)

$$a_{GRID} = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nm} \end{pmatrix} \quad (1)$$

Donde (n,m) son números enteros que representan las dimensiones del espacio de trabajo. Si una localización está ocupada en el mapa, se representa mediante un 1, si no lo está, se representa con un 0, tal y como se muestra en (2)

$$a_{nm} \in \mathbb{N} : a_{nm} = \begin{cases} 1 & \text{Occupied Location} \\ 0 & \text{Free Location} \end{cases} \quad (2)$$

Este mapa se utiliza como restricción en el método de generación de la trayectoria, comparando los puntos de la misma con cada posición del mapa de ocupación. Cuando un punto de la trayectoria $t(x,y)$ se encuentra con una celda ocupada del mapa a_{nm} , se considera un evento de colisión y la trayectoria no será factible.

$$\text{For } x,y \in t \mid \begin{cases} a_{xy} = 0 \Rightarrow \text{No Collision} \\ a_{xy} = 1 \Rightarrow \text{Collision} \end{cases} \quad (3)$$

3. Descripción del proceso de optimización de trayectorias a partir de algoritmos genéticos.

3.1. Metodología de optimización.

El objetivo del método de generación de trayectorias es obtener el camino continuo más corto que se ajuste a una serie de puntos de paso sin eventos de colisión. En este trabajo, los puntos de paso predefinidos son el punto de inicio y el punto final de la trayectoria. Los puntos de paso intermedios son determinados por el algoritmo genético para minimizar la longitud de la trayectoria, l_t , y evitar obstáculos. La arquitectura del método de generación de trayectorias que se utiliza se muestra en la Figura 1. El algoritmo es capaz de generar múltiples puntos de paso intermedios, pero en este

trabajo consideraremos solamente escenarios de simulación con un único punto de paso adicional.

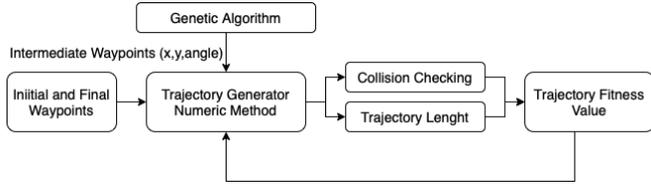


Figura 1. Metodología de generación de funciones

La trayectoria generada viene dada por las ecuaciones de Frenet, que representan una curva plana en \mathbb{R}^2 donde el vector tangente T y el vector normal N satisfacen (4). Estas ecuaciones se conocen como ecuaciones de Frenet de un trayectoria (Alencar *et al.*, 2022).

$$\begin{cases} T'(s) = k(s)N(s) \\ N'(s) = -k(s)T(s) \end{cases} \quad (4)$$

Donde s es la distancia al origen de cada punto, k es la curvatura de la trayectoria a la distancia s , $T(s)$ es el vector tangente a la distancia s , $N(s)$ es el vector normal a la distancia s , y el símbolo $'$ denota el vector perpendicular.

Basándose en la definición de una curva de Frenet, la longitud del arco puede ser calculada en coordenadas cartesianas, donde la trayectoria será una curva plana en \mathbb{R}^2 con la forma $y = f(x)$ donde f es una función continua y diferenciable. La longitud de cada uno de los segmentos infinitesimales de la curva se expresan en (5).

$$ds = \sqrt{dx^2 + dy^2} = \sqrt{1 + \left(\frac{dy}{dx}\right)^2} dx \quad (5)$$

Esto lleva a la expresión matemática de la longitud del arco de la trayectoria calculada (s) basada en (5) y expresada en (6).

$$s = \int_{(x_i, y_i)}^{(x_f, y_f)} \sqrt{1 + \left(\frac{dy}{dx}\right)^2} dx \quad (6)$$

3.2. Algoritmo genético

Los algoritmos genéticos son una técnica computacional evolutiva usada en problemas de optimización. Se basa en la evolución de una población inicial de individuos. Su correcta codificación y la correcta elección de los operadores genéticos (mutación y cruce) son claves para la convergencia del algoritmo hacia la mejor solución (Abajo *et al.*, 2021).

Las posibles soluciones para este problema se definen como un vector de 3 componentes $[x, y, \theta]$, siendo x e y las coordenadas cartesianas de los puntos de paso intermedios de la trayectoria y θ su ángulo de entrada y salida. En este trabajo se considera únicamente un único punto de paso intermedio, aunque se podría considerar múltiples puntos si fuera necesario. Los dos primeros elementos pueden ser cualquier número entero dentro de las dimensiones del mapa de ocupación y el tercero es cualquier ángulo comprendido entre

$-\pi/2$ and $\pi/2$. Estas restricciones pueden expresarse formalmente en (7-9).

$$x \in [0, a_n] \quad (7)$$

$$y \in [0, a_n] \quad (8)$$

$$\theta \in \left[-\frac{\pi}{2}, \frac{\pi}{2}\right] \quad (9)$$

Si se considera $x = r \cos \theta$, $y = r \sin \theta$ en coordenadas polares, la longitud del arco de la trayectoria obtenida como solución se puede expresar en (10).

$$l_t = \int_{\theta_i}^{\theta_f} \sqrt{r^2 + \left(\frac{dr}{d\theta}\right)^2} d\theta \quad (10)$$

Por lo tanto, l_t es la variable a considerar por el algoritmo genético para la optimizar la trayectoria generada. Además para guiar al algoritmo genético hacia la solución óptima, se utiliza una función de coste que incluye el factor de colisión en el problema de optimización.

La función de coste se define en (11), como el producto entre la longitud de la trayectoria y el coeficiente de colisión C . Este coeficiente es 1 cuando no existen eventos de colisión y 1000 cuando sucede alguno de estos eventos, haciendo a la trayectoria no factible. Este coeficiente convierte a trayectorias más cortas que otras opciones en opciones no válidas debido a las colisiones con el mapa de ocupación. Las ecuaciones (11-12) definen la función de coste descrita y el valor del coeficiente de colisión.

$$f_{fitness} = l_t \cdot C \quad (11)$$

$$C = \begin{cases} 1, & \text{No collision Event} \\ 1000, & \text{Collision Event} \end{cases} \quad (12)$$

4. Simulación y resultados

Para las simulaciones del método de generación de trayectorias y su optimización se han usado las herramientas Matlab/Simulink. Se ha configurado un mapa de ocupación para verificar los eventos de colisión. Los puntos inicial y final y sus respectivos ángulos de salida y llegada se han fijado previamente. Asimismo se ha restringido el ángulo de entrada y salida del punto de paso intermedio a 0° . Las coordenadas del punto intermedio y el ángulo de entrada y salida son las variables utilizadas por el algoritmo genético para optimizar la longitud de la trayectoria en función de las restricciones.

Se han simulado tres escenarios diferentes para comprobar diferentes comportamientos del algoritmo genético optimizando la función de generación de trayectorias. El primero de ellos no limita la posición del punto de paso intermedio dentro de mapa de ocupación. El segundo escenario establece restricciones para la posición del punto de paso intermedio, restringiendo las posibles coordenadas del punto dentro de un área delimitada del mapa de ocupación y su ángulo de llegada y salida. El tercer escenario simula un caso en el que las restricciones de posición y ángulo de llegada y

salida no permiten que el algoritmo sea capaz de encontrar una trayectoria sin suceder una colisión.

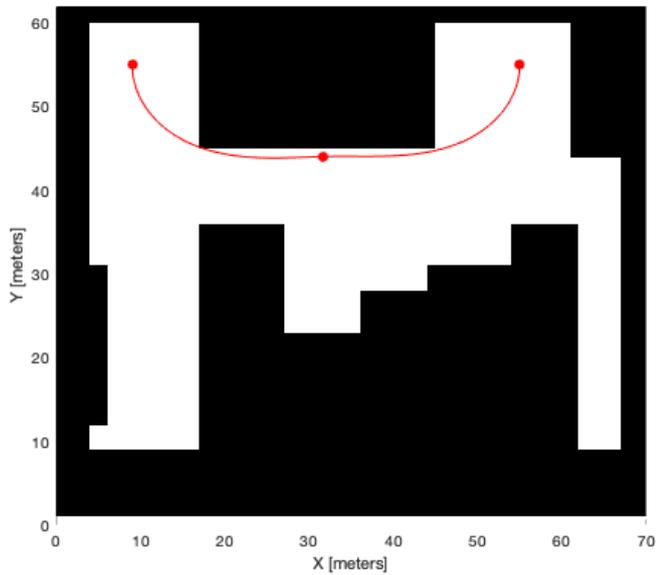


Figura 2. Escenario 1: Trayectoria óptima sin restricciones de área

La Figura 2 muestra los resultados de la trayectoria optimizada para el primer escenario. En este caso no se han utilizado limitaciones para la posición del punto de paso intermedio, restringiendo el ángulo de entrada y salida a 0°. En rojo se muestra la trayectoria óptima y el punto de paso intermedio calculado por el algoritmo genético, así como los puntos inicial y final predefinidos. Se comprueba como en la búsqueda de optimizar la longitud de la trayectoria, el algoritmo genético apura el paso de la curva con los obstáculos del mapa de ocupación.

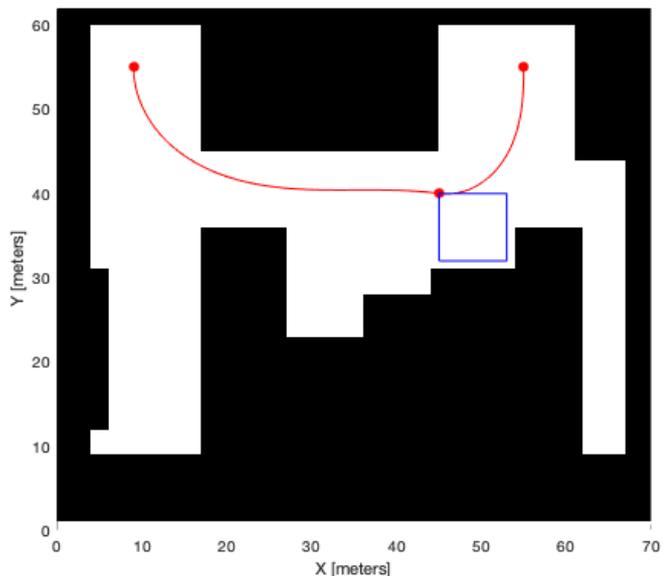


Figura 3. Escenario 2: Trayectoria óptima con restricción de área

Las Figuras 3 y 4 muestran los resultados para el segundo y tercer escenarios, respectivamente. En estos casos se ha restringido la posición del punto de paso intermedio y, en consecuencia, la forma de la trayectoria se adapta al camino más corto de acuerdo a esa condición.

En la Figura 3, se representa el segundo escenario, donde un cuadrado azul representa el área utilizada como restricción para la posición del punto intermedio de la trayectoria que se ha fijado entre $x \in [45,55]$, $y \in [33,40]$, restringiendo su ángulo de entrada y salida a 0°. Con esta restricción, el algoritmo busca las soluciones cuya posición esté dentro del espacio definido en el cuadrado azul. En este caso el algoritmo encuentra una trayectoria diferente al primer escenario para cumplir con los requisitos, alcanzando una mayor curvatura y un camino más largo que en caso del primer escenario sin restricciones. Esta situación es significativa cuando se consideran diferentes modelos de AGV con diferente capacidad de movimiento y curvaturas posibles, ya que dependiendo de las condiciones que se den a las puntos de paso intermedios, estos parámetros de la trayectoria pueden cambiar significativamente.

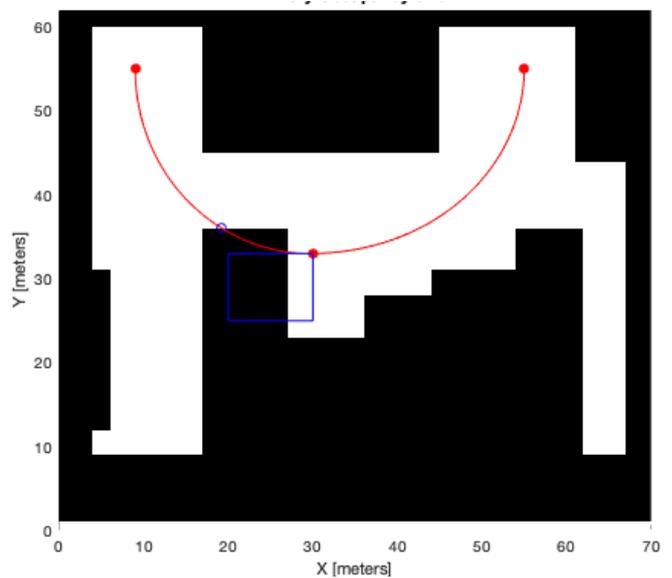


Figura 4. Escenario 3: Trayectoria óptima con restricción de área y colisión

La Figura 4 muestra el resultado para el tercer escenario. En esta simulación, el área restringida para el punto de paso intermedio de la trayectoria imposibilita al algoritmo genético encontrar un camino sin chocar con las posiciones ocupadas del mapa. En este caso, también se selecciona el camino más corto, aunque la función de coste dada por el algoritmo tendrá un valor muy alto acorde a esta situación. En este tercer escenario, la zona de posibles puntos intermedios se ha fijado entre $x \in [20,30]$, $x \in [25,33]$, restringiendo su ángulo de entrada y salida a 0°. Al igual que en el caso anterior, un cuadrado azul representa el área condicionada para el punto intermedio y un círculo azul marca el punto en el que la función reconoce que existe un evento de colisión.

Table 1. Resultados óptimos para los tres escenarios de simulación

Escenario	Restricciones Punto Intermedio	Mejor Individual	Función de Coste	Valido
1	$\theta = 0$	[31.61,44.04]	57.15	✓
2	$x \in [45,55]$ $y \in [33,40]; \theta = 0$	[45,40]	63.88	✓
3	$x \in [20,30]$ $y \in [25,33]; \theta = 0$	[30,33]	70783	X

Los resultados de la Tabla 1 muestran que, dependiendo de las restricciones que se establezcan para la trayectoria, el conjunto de parámetros optimizados devueltos por el algoritmo genético son diferentes. De hecho, en los casos en los que las condiciones son muy restrictivas (escenario 3), el algoritmo genético no puede encontrar una solución de parámetros de ajuste para una trayectoria óptima que no choque con el mapa de ocupación. Sin embargo, cuando no se especifica ninguna restricción, el algoritmo encuentra una trayectoria óptima sin eventos de colisión y con valor de función de coste, por tanto, mucho más bajo.

5. Conclusiones y líneas futuras

En este trabajo se han aplicado algoritmos genéticos en una función de generación de trayectorias para AGV para la optimización su longitud y evitar colisiones. Los eventos de colisión se comprueban entre un mapa de ocupación binaria y cada uno de los segmentos entre los puntos de la trayectoria. Un punto de paso intermedio de la trayectoria a generar es el parámetro utilizado por el algoritmo para el proceso de optimización. Se comparan y analizan tres escenarios con diferentes restricciones, extrayendo de los resultados las siguientes conclusiones.

Las restricciones de los puntos de paso intermedios de la trayectoria son una decisión importante, ya que afecta directamente a su longitud y su curvatura para evitar las posibles colisiones con el mapa de ocupación.

Esta aplicación se adapta perfectamente a casos de generación automática de trayectorias en procesos de implementación de AGV en industria o modificación de las rutas ya existentes, encontrando de forma automática la trayectoria óptima para este tipo de vehículos a partir de restricciones introducidas por usuario.

Como trabajos futuros, se propone la mejora de la metodología para poder considerar más parámetros y restricciones durante el cálculo de la solución óptima. Además, se propone asimismo la mejora del proceso de detección de

colisiones para poder considerar el modelo físico del AGV que se utilizará para seguir la trayectoria óptima calculada.

Referencias

- Abajo, M. R., Sierra-García, J. E., & Santos, M. (2021, September). Evolutionary Tuning Optimization of a PID Controller for Autonomous Path-Following Robot. In International Workshop on Soft Computing Models in Industrial and Environmental Applications (pp. 451-460). Springer, Cham.
- Alencar, H., Santos, W., & Neto, G. S. (2022). Differential Geometry of Plane Curves (Vol. 96). American Mathematical Society.
- Alouache, A., & Wu, Q. (2018, September). Genetic algorithms for trajectory tracking of mobile robot based on PID controller. In 2018 IEEE 14th International Conference on Intelligent Computer Communication and Processing (ICCP) (pp. 237-241). IEEE.
- Bechtis, D., Tzolakis, N., Vlachos, D., & Iakovou, E. (2017). Sustainable supply chain management in the digitalisation era: The impact of Automated Guided Vehicles. *Journal of Cleaner Production*, 142, 3970-3984.
- Bostelman, R., & Messina, E. (2016). Towards development of an automated guided vehicle intelligence level performance standard. *Autonomous Industrial Vehicles: From the Laboratory to the Factory Floor*, 1-22.
- Echeverri Estrada, J. M., & Escobar Murcia, P. A. (2012). Caracterización de un AGV (vehículo guiado automáticamente) en el sistema de manufactura flexible, caso Centro Tecnológico de Automatización CTAI de la Pontificia Universidad Javeriana.
- Espinosa, F., Santos, C., & Sierra-García, J. E. (2021). Multi-AGV transport of a load: state of art and centralized proposal. *Revista Iberoamericana de Automática e Informática Industrial*, 18(1), 82-91.
- Farouki, R. T. (2000). Curves from motion, motion from curves. California Univ. Davis Dept. of Mechanical and Aeronautical Engineering.
- Kühnel, W. (2002). Differential Geometry. Student Mathematical Library, vol. 16. American Mathematical Society, Providence, RI.
- Larrazabal, J. M., & Peñas, M. S. (2016). Intelligent rudder control of an unmanned surface vessel. *Expert Systems with Applications*, 55, 106-117.
- Santos, M., & Cantos, A. J. (2010). Classification of plasma signals by genetic algorithms. *Fusion Science and Technology*, 58(2), 706-713.
- Sierra-García, J. E., & Santos, M. (2021). Switched learning adaptive neuro-control strategy. *Neurocomputing*, 452, 450-464.
- Vis, I. F. (2006). Survey of research in the design and control of automated guided vehicle systems. *European Journal of Operational Research*, 170(3), 677-709.
- Zhang, H., Wu, D., & Yao, T. (2018, September). Research on AGV trajectory tracking control based on double closed-loop and PID control. In *Journal of Physics: Conference Series* (Vol. 1074, No. 1, p. 012136). IOP Publishing.