

Trajectory tracking control with data fusion and geometric algorithm^{*}

L.A. Martínez-Ramírez^{*} J.F. Guerrero-Castellanos^{*}
R.C. Ambrosio-Lázaro^{*} G. Mino-Aguilar^{*}
J.P. Sánchez-Santana^{*,**} G.A. Munoz-Hernandez^{*}

^{*} *Facultad de Ciencias de la Electrónica, Benemérita Universidad Autónoma de Puebla, Puebla, México (e-mail: luis.martinezramirerami@alumno.buap.mx).*

^{**} *Universidad Politécnica de Puebla, Puebla, México (e-mail: luis.martinezramirerami@alumno.buap.mx).*

Abstract: In this research, the problem of path tracking and data fusion is addressed using the Extended Kalman Filter to improve the accuracy in states estimating of the bicycle kinematic model. The pure pursuit algorithm based on vehicle geometry is employed to achieve path tracking. A novel nonlinear control strategy is implemented for controlling electric motors in a differential traction system. The Ackermann geometry model is used to establish the reference speeds of the motors and enhance maneuver stability in curved paths. Finally, experimental results are presented for tracking a Lemniscate path under different position update data times.

Keywords: Kinematic bicycle model, Model-free control, Kalman filter, Trajectory tracking, Pure pursuit algorithm, electronic differential.

1. INTRODUCCIÓN

Un vehículo autónomo es capaz de percibir su entorno y navegar por sí mismo sin intervención humana, para ello debe estar equipado con sistemas de percepción y posicionamiento del entorno, planificación de decisiones y control de ejecución Vivacqua et al. (2018). Recientemente han presentado diversas estrategias de control, en Wang et al. (2019) se propone un control de seguimiento de ruta para vehículos autónomos basado en un modelo de control predictivo mejorado MPC, dicha mejora consiste en la asignación adaptativa del peso en la función de costo a través del algoritmo de control adaptativo difuso, en Hu et al. (2022) presentan un control conocido como “drifting” y un MPC para el seguimiento de trayectoria, el controlador propuesto integra el modelo de deriva linealizado y el modelo de seguimiento, en Tang et al. (2020) se describe el acoplamiento de un MPC en cascada con un regulador PID y un compensador de ángulo de deslizamiento lateral. Una variante del MPC se propone en Guo et al. (2020) y consiste en tener un modelo no lineal NMPC para el seguimiento de trayectoria de los vehículos eléctricos autónomos (AEV), se incorpora un algoritmo de continuación residual mínimo generalizado C/GMRES que se aplica para resolver la optimización en el NMPC.

Como alternativas al modelo de control predictivo, en Hu et al. (2019) se diseña un control de modo deslizante integral (ISMCI), se propone un filtro de Kalman exten-

dido robusto y desarrollan una red neuronal de función de base radial adaptativa mejorada (RBFNN). En Lee et al. (2019) presentan un control gaussiano cuadrático lineal (LQG) basado en modelos con matriz Q adaptativa, se incorpora un observador. En Wu et al. (2019), se presenta la estrategia de control que se basa en el modo deslizante de terminal no singular (NTSM) y el control de rechazo activo de perturbaciones (ADRC).

En este trabajo se propone diseñar un control de seguimiento de trayectoria basado en la integración de varios sistemas de control, dicho enfoque es robusto ante pérdida, latencia o ruido en las lecturas de posición del vehículo, permite un control de velocidad diferencial en la tracción para mejorar la estabilidad de maniobra en trayectorias curvas, cuenta con rechazo activo de perturbaciones en el control de los motores eléctricos. Dicho enfoque tiene un coste computacional reducido permitiendo su implementación en sistemas de bajo costo, en comparación con los (MPC) que actualmente representan una de las estrategias de control más utilizadas. El resto del documento está organizado de la siguiente manera: en la sección 2 se presenta el modelo matemático del vehículo y el enunciado del problema. En la sección 3 se describe el control de seguimiento de trayectoria con cada uno de los subsistemas que lo conforman. La plataforma de experimentación y los resultados obtenidos se muestran en la sección 4, finalmente en la sección 5 las conclusiones son presentadas.

^{*} Este trabajo es financiado parcialmente por la Vicerrectoría de Investigación y Estudios de Posgrado, VIEP-BUAP con el proyecto No.00593/2025

2. PRELIMINARES Y FORMULACIÓN DEL PROBLEMA

Se pretende diseñar e implementar un sistema de control en lazo cerrado para que un vehículo robótico con tracción diferencial (dos ruedas motrices independientes en el eje trasero y un sistema de dirección en el eje delantero (ver Fig. 3.)) pueda seguir una trayectoria de referencia.

2.1 Modelo matemático del vehículo

Considere un vehículo como el mostrado en la Fig. 1, observe que la representación del automóvil se simplifica a un sistema de solo dos ruedas (modelo de la bicicleta), una de dirección (delantera) y una de tracción (trasera), para determinar la dinámica del movimiento, se tomará como referencia un punto sobre la rueda trasera, por tanto, el modelo cinemático queda definido como:

$$\Sigma_q := \begin{cases} \dot{x} = v_x \cos(\theta) \\ \dot{y} = v_x \sin(\theta) \\ \dot{\theta} = \omega \end{cases} \quad (1)$$

donde v_x y ω son la velocidad lineal y angular del vehículo respectivamente, (ω) puede definirse a partir de la velocidad lineal y del ángulo de dirección δ de la siguiente forma:

$$\omega = \frac{v_x}{R} = \frac{v_x}{L} \tan(\delta) \quad (2)$$

El prototipo utilizado en este trabajo posee tracción diferencial, por tanto, la velocidad lineal v_x depende de las velocidades angulares de las ruedas ω_L y ω_R a partir de la ecuación:

$$v_x = f(\omega_L, \omega_R) = \frac{r}{2}(\omega_L + \omega_R) \quad (3)$$

donde r es el radio de las ruedas, ω_L y ω_R son las velocidades angulares de las ruedas de tracción.

El control de velocidad se aplica en ambos motores, definamos:

$$\omega_{m_i}, u_{m_i} \text{ con } i \in \{R, L\} \quad (4)$$

como la velocidad angular de los motores y el voltaje, derecho (R) e izquierdo (L), respectivamente. Consideremos también la siguiente ecuación de movimiento para ambos motores.

$$\dot{\omega}_{m_i} = -a\omega_{m_i} + bu_{m_i} + \xi_i \quad (5)$$

donde $a, b \in \mathbb{R}_{>0}$ son constantes que dependen de los parámetros eléctricos y mecánicos del motor y que en este trabajo se asumirán desconocidos. $\xi_i \in \mathbb{R}$ representa una señal que concentra las perturbaciones externas, originadas por las fuerzas tangenciales presentes en las ruedas del vehículo y reflejadas como un momento de fuerzas alrededor del eje de rotación.

2.2 Enunciado del Problema

El problema de seguimiento de trayectoria consiste en diseñar una acción de control para que el sistema siga una ruta parametrizada en el tiempo y en el espacio. El objetivo es minimizar los errores de seguimiento respetando las restricciones dinámicas del sistema. Al tratarse de un vehículo con tracción diferencial se requiere controlar la velocidad de los motores eléctricos de forma independiente con la capacidad de rechazar perturbaciones tales como: resistencia por pendiente, aerodinámica, rodadura y cambios de carga. Para cerrar el lazo de control de alto nivel se precisa conocer la posición y orientación del vehículo de forma precisa, en entornos reales los sistemas de comunicación, geolocalización y sensores son susceptibles a fallas o latencias, determinar la posición y orientación del vehículo a partir de una sola fuente de información resulta inconveniente, por tal motivo, se prefiere que las entradas de posición y orientación del robot se obtengan mediante la fusión sensorial de datos de odometría y de un sistema de captura de movimiento OptiTrack usando un Filtro de Kalman Extendido (EKF). Finalmente es necesaria la validación de los algoritmos de control de forma experimental para lo cual se necesita contar con una plataforma capaz de monitorear las variables del sistema en tiempo real.

Considere el sistema dinámico no lineal en espacio de estados:

$$\dot{X} = f(q, u, t), \quad x(t_0) = 0 \quad (6)$$

donde:

$q(t) \in \mathbb{R}^n$ es el vector de estados,

$u(t) \in \mathbb{R}^m$ es el vector de entradas de control,

$f: \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R} \rightarrow \mathbb{R}^n$ es una función continua que describe la dinámica del sistema.

el vector de estados q se define como:

$$q = [x \quad y \quad \theta]^T \quad (7)$$

donde:

x, y son coordenadas de posición,

θ ángulo de orientación.

La trayectoria de referencia deseada suave y acotada, físicamente realizable de acuerdo a las restricciones de movimiento del vehículo, esta dada por:

$$q_d = [x_d \quad y_d \quad \theta_d] \in \mathbb{R}^n, \quad t \in [t_0, t_f] \quad (8)$$

de manera que el error de seguimiento es:

$$e = q - q_d \quad (9)$$

el objetivo de control consiste en diseñar una ley de control u tal que:

$$\|e\| < \epsilon \quad \forall t \geq T, \quad \epsilon > 0 \quad (10)$$




Fig. 1. Modelo de la bicicleta tomando como referencia de posición el punto medio sobre el eje trasero.

3. CONTROL DE SEGUIMIENTO DE TRAYECTORIA

El control de seguimiento de trayectoria propuesto se muestra en la Fig. 2.

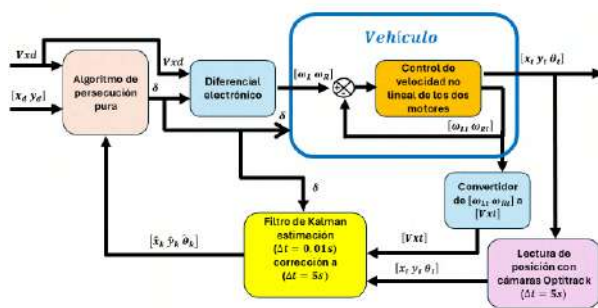


Fig. 2. Diagrama de bloques de la estrategia de control de seguimiento de trayectoria, el filtro de kalman estima la posición cada 10 milisegundos y corrige cada 5 segundos con la información de las cámaras.

3.1 Algoritmo de persecución pura (Pure pursuit)

El algoritmo pure pursuit se basa en la geometría del vehículo, la posición del mismo esta referenciada a un punto medio del eje trasero, de manera que el movimiento en ese punto es descrito por el modelo cinemático de la bicicleta (1). Para el seguimiento de trayectoria, se define a v_x como una constante o en función de la velocidad de la trayectoria, l_d representa la distancia de anticipación al punto objetivo y puede ser definida como una constante o en función de v_x (Yang et al. (2024)), luego el algoritmo se encarga de establecer el ángulo de dirección que permitirá alcanzar la posición objetivo, el ángulo de dirección δ se establece como:

$$\delta = \arctan\left(\frac{2L\sin(\alpha)}{ld}\right) \quad (11)$$

en (Yang et al. (2024); Lal et al. (2017)), definen k como la curvatura que representa el inverso de R

$$k = \frac{1}{R} = \frac{2\sin(\alpha)}{ld} \quad (12)$$

El error transversal a la trayectoria se define como la distancia lateral entre el vector de rumbo y el punto de destino. La relación entre la curvatura k y el error transversal e es:

$$k = \frac{2}{ld^2}e \quad (13)$$

La ecuación anterior muestra que la curvatura k es proporcional al error transversal a la trayectoria. A medida que aumenta el error, también lo hace la curvatura, esto permite que el vehículo vuelva a la trayectoria de forma más agresiva.

3.2 Diferencial electrónico

Considerando la geometría de Ackermann es posible determinar la velocidad de las ruedas interna y externa en una trayectoria curva, es importante mencionar que el modelo es válido a bajas velocidades, sin tomar en cuenta las fuerzas laterales y el deslizamiento de las ruedas de tracción. El modelo geométrico se muestra en la Fig. 3, este permite determinar el radio de rotación R a partir del ángulo de dirección (δ_L, δ_R) y los valores de velocidad angular que cada rueda de tracción debe tener (ω_L, ω_R).




Fig. 3. Geometría de Ackermann para un vehículo con tracción trasera y diferencial electrónico (Magallán et al. (2008)).

Haciendo uso de geometría básica, los ángulos de dirección pueden expresarse en función del radio de rotación de la siguiente forma:

$$\delta_R = \tan^{-1}\left(\frac{L}{R + \frac{d}{2}}\right), \quad \delta_L = \tan^{-1}\left(\frac{L}{R - \frac{d}{2}}\right) \quad (14)$$

Para ángulos pequeños, es posible considerar ambos ángulos como un solo parámetro, denominado ángulo de Ackermann (Magallán et al. (2008)):

$$\delta = \frac{\delta_L + \delta_R}{2}, \quad \tan(\delta) = \frac{L}{R} \quad (15)$$

La velocidad angular de cada rueda de tracción se puede expresar en función de la velocidad lineal del vehículo v_x y del ángulo de Ackermann δ , esto permite implementar un sistema de control de velocidad independiente en las ruedas de tracción traseras conocido como diferencial electrónico

$$\omega_L = \frac{v_x}{r} \left(1 - \left(\frac{d \tan(\delta)}{2L} \right) \right) \quad (16)$$

$$\omega_R = \frac{v_x}{r} \left(1 + \left(\frac{d \tan(\delta)}{2L} \right) \right) \quad (17)$$

3.3 Control de velocidad NESO

El objetivo de control consiste en garantizar que $\omega_m \rightarrow \omega_{md}$, $\dot{\omega}_{md} = 0$, cuando $t \rightarrow \infty$ independientemente de las incertidumbres en el modelo denotado por a , y la perturbación ξ que representa la suma de perturbaciones endógenas y exógenas y puede ser variante en el tiempo.

Antes de definir el algoritmo de control, es necesario establecer las siguientes consideraciones:

- (1) $a > 0$ tal que $a \in [a_{min}, a_{max}]$
- (2) $\xi \in [h_{min}, h_{max}]$
- (3) $u_m(t) \in [-M, M]$, $\forall M > 0$
- (4) $|\frac{d\xi}{dt}| \leq h_0$

Definición 3.1. (Función de saturación) Dada una constante positiva M , la función continua y no decreciente $\sigma_M : \mathbb{R} \rightarrow \mathbb{R}$ es definida como:

- (1) $\sigma_M = s$ si $|s| < M$;
- (2) $\sigma_M = M \cdot \text{sign}(s)$; en otro caso

La ley de control propuesta es la siguiente:

$$\begin{aligned} \dot{z} &= \lambda_f(u - z) \\ u &= \sigma_M(\lambda(\omega_{md} - \omega_m) + z) \end{aligned} \quad (19)$$

solo es necesario sintonizar la ganancia del estimador λ_f y la del controlador λ , el desarrollo del control y análisis de estabilidad ya fueron publicados y se pueden consultar en Martínez-Ramírez et al. (2024).

3.4 Filtro de kalman extendido

En aplicaciones de navegación en interiores o exteriores es común utilizar estrategias de estimación y actualización de posición (odometría, cámaras, sensores láser, sensores ultrasonicos, GPS, etc.), para robustecer los sistemas de localización y lograr la fusión de datos de diversas fuentes se emplea el Filtro de Kalman Extendido (FKE) por tratarse de un sistema no lineal el modelo cinemático de la bicicleta (1), en este trabajo se emplea la posición medida por el sistema de cámaras Optitrack y la estimación de la posición por odometría a partir de la velocidad de los

motores. El modelo cinemático de la bicicleta en tiempo discreto X_{k+1} se define como:

$$X_{k+1} = X_k + \begin{bmatrix} v_x \cos(\theta_k) \Delta t \\ v_x \sin(\theta_k) \Delta t \\ \omega \Delta t \end{bmatrix} + W_k \quad (20)$$

con

$$X_k = [x_k \quad y_k \quad \theta_k]^T \quad (21)$$

donde x_k y y_k son las coordenadas cartesianas de posición, θ_k es la orientación, Δt es el tiempo de muestreo de actualización de los estados, y W_k es el vector del ruido del proceso. Para la implementación del FKE debemos de linealizar el modelo $f(x_k, u_k)$ definido en (1) alrededor del estado actual a lo largo de la trayectoria para usarla en la propagación de la covarianza, la matriz Jacobiana esta dada por:

$$F_k = \frac{\partial f(x_k, u_k)}{\partial X_k} = \begin{bmatrix} 1 & 0 & -v_x \sin(\theta_k) \Delta t \\ 0 & 1 & v_x \cos(\theta_k) \Delta t \\ 0 & 0 & 1 \end{bmatrix} \quad (22)$$

el modelo de medición es el siguiente:

$$Z_k = h(X_k) + V_k \quad (23)$$

donde h es la matriz de observación y determina los estados del sistema que son medidos, Z_k es el vector de mediciones y V_k representa el ruido en las mismas. La linealización del modelo de medición alrededor del estado actual se define como:

$$H_k = \frac{\partial h(X_k)}{\partial X_k} \quad (24)$$

El FKE utiliza dos matrices de covarianza para actualizar la estimación de los estados y mejorar la precisión en la determinación de la posición del vehículo, la matriz Q_k relacionada con la covarianza del ruido del proceso, y la matriz R_k asociada al ruido en las mediciones. La matriz de covarianza Q_k representa las incertidumbres en el modelo cinemático, toma en cuenta los errores debidos al deslizamiento de las ruedas, superficies irregulares y otros factores que afectan el movimiento del robot. En (Nugraha et al. (2024)) proponen que la matriz Q_k se defina basado en la variabilidad esperada en las entradas de control y las características de ruido del modelo de movimiento bajo la suposición de que el ruido en las velocidades lineales y angulares son independientes y gaussianos, así la matriz Q_k es definida por:

$$Q_k = \begin{bmatrix} \sigma_{vx}^2 & 0 & 0 \\ 0 & \sigma_{vy}^2 & 0 \\ 0 & 0 & \sigma_{\omega}^2 \end{bmatrix} \quad (25)$$

donde $\sigma_{vx}^2, \sigma_{vy}^2, \sigma_{\omega}^2$ son las varianzas de ruido en la velocidad longitudinal, lateral y angular respectivamente.

La matriz de covarianza del ruido de medición R_k generalmente se define en función de las especificaciones de los sensores y la variabilidad esperada en las mediciones

$$R_k = \sigma_m^2 \quad (26)$$

con σ_m^2 como la varianza en las mediciones del sistema Optitrack.

El algoritmo del FKE para fusionar los datos, se ejecuta de forma iterativa realizando las dos acciones principales:

3.5 Predicción

$$\hat{X}_{k|k-1} = f(\hat{X}_{k-1|k-1}, u_k) \quad (27)$$

$$P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + Q_k \quad (28)$$

3.6 Actualización y corrección

$$y_k = Z_k - h(\hat{X}_{k|k-1}) \quad (29)$$

$$K_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R)^{-1} \quad (30)$$

$$\hat{X}_{k|k} = \hat{X}_{k|k-1} + K_k y_k \quad (31)$$

$$P_{k|k} = (I - K_k H_k) P_{k|k-1} \quad (32)$$

donde K_k es conocida como la ganancia de Kalman.




Fig. 4. Plataforma basada en el sistema Optitrack para detección de posición y orientación del vehículo.

4. RESULTADOS EXPERIMENTALES

La plataforma de experimentación que se diseñó e implementó (Fig. 4), esta basada en el sistema de captura de movimiento Optitrack, se utiliza ROS2 para generar un nodo de comunicación y publicar el estado del vehículo (posición y orientación), el módulo de control se suscribe a dicho nodo y cierra el lazo de retroalimentación. El prototipo es un robot móvil con tracción trasera diferencial

y geometría de Ackermann, capaz de alcanzar una velocidad lineal máxima de $1m/s$. Los resultados obtenidos se muestran en la Fig. 5, en el inciso a) se comparan las implementación del algoritmo pure pursuit usando la lectura de las cámaras, estimación de posición por odometría y fusión de datos con kalman respectivamente, en b) se muestra el resultado obtenido con una latencia en las cámaras de $\Delta t = 0.5s$, en c) se presentan los resultados obtenidos utilizando únicamente la estimación de posición con odometría y finalmente en d) se observa el resultado de la fusión de datos con el filtro de Kalman, la predicción de posición por odometría se realiza cada $10ms$ y se corrige el error con la lectura de las cámaras cada $\Delta t = 5s$. La tabla 1, muestra los índices de desempeño obtenidos en las diferentes implementaciones, el mejor resultado corresponde con el uso de las cámaras leyendo la posición cada $10ms$. Sin embargo, a pesar de los resultados en los índices de desempeño, la implementación del filtro de kalman representa una gran ventaja en el control de sistemas reales donde la lectura de posición con sensores contiene ruido o ésta se da en intervalos de tiempo grandes (sistemas GPS), bajo esas condiciones el filtro de kalman es la opción más robusta, observese los incisos b) y d) de la Fig. 5. La evolución de las variables del sistema en la implementación del control de seguimiento de trayectoria usando el filtro de kalman, con lecturas de posición cada 5 segundos, y predicción usando el modelo cinemático de la bicicleta en tiempo discreto cada $10ms$ se presentan en Fig. 6.

5. CONCLUSIONES

Se implementó un sistema de control de seguimiento de trayectoria que integra un control de alto nivel basado en la geometría del vehículo (pure pursuit). Se utilizó el modelo de la geometría de Ackermann para determinar las velocidades de referencia de los motores eléctricos, se implementó una novedosa estrategia de control no lineal libre de modelo con rechazo activo de perturbaciones para el control de regulación en los motores, se diseñó un filtro de Kalman extendido para la fusión de datos. Los resultados muestran que la integración de los algoritmos bajo este enfoque es adecuada para muchas aplicaciones que requieran del seguimiento de trayectoria. En trabajos futuros se pretende cambiar el control de alto nivel por un control basado en modelo (MPC) además de realizar pruebas en exteriores con GPS.

REFERENCES

Guo, N., Zhang, X., Zou, Y., Lenzo, B., and Zhang, T. (2020). A computationally efficient path-following control strategy of autonomous electric vehicles with yaw motion stabilization. *IEEE Transactions on*

Tabla 1. Índices de desempeño ISE e IAE para el seguimiento de trayectoria con $\Delta t = 10ms$.

Índice	Cámaras	Odometría	Kalman
ISE posición en x	1.35	1.87	1.78
IAE posición en x	5.51	6.51	6.41
ISE posición en y	0.77	1.17	0.99
IAE posición en y	3.74	4.91	4.27

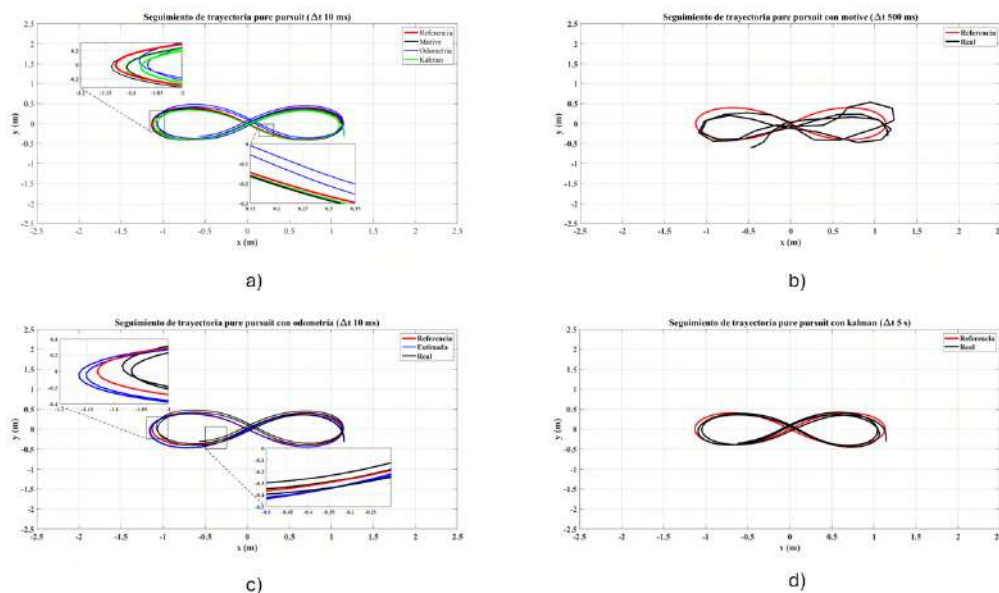


Fig. 5. Resultados de seguimiento de trayectoria en diferentes escenarios.

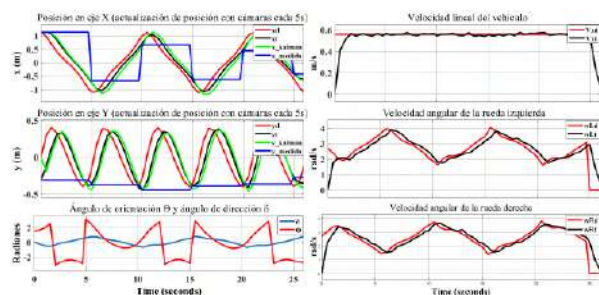


Fig. 6. Variables del sistema en la implementación con filtro de Kalman.

Transportation Electrification, 6, 728–739. doi: 10.1109/TTE.2020.2993862.

Hu, C., Zhou, X., Duo, R., Xiong, H., Qi, Y., Zhang, Z., and Xie, L. (2022). Combined fast control of drifting state and trajectory tracking for autonomous vehicles based on mpc controller. Institute of Electrical and Electronics Engineers Inc. doi: 10.1109/ICRA46639.2022.9812185.

Hu, C., Wang, Z., Taghavifar, H., Na, J., Qin, Y., Guo, J., and Wei, C. (2019). Mme-ekf-based path-tracking control of autonomous vehicles considering input saturation. *IEEE Transactions on Vehicular Technology*, 68, 5246–5259. doi:10.1109/TVT.2019.2907696.

Lal, D.S., Vivek, A., and Selvaraj, G. (2017). Lateral control of an autonomous vehicle based on pure pursuit algorithm. In *2017 international conference on technological advancements in power and energy (tap energy)*, 1–8. IEEE.

Lee, K., Jeon, S., Kim, H., and Kum, D. (2019). Optimal path tracking control of autonomous vehicle: Adaptive full-state linear quadratic gaussian (lqg) control. *IEEE Access*, 7, 109120–109133. doi: 10.1109/ACCESS.2019.2933895.

Magallán, G.A., De-Angelo, C.H., Bisheimer, G., and Garcia, G. (2008). A neighborhood electric vehicle

with electronic differential traction control. IEEE. doi: 10.1109/IECON.2008.4758395.

Martínez-Ramírez, L.A., Guerrero-Castellanos, J.F., Ambrosio-Lázaro, R.C., Jiménez-Rodríguez, J.M., and Muñoz-Hernández, G.A. (2024). Model-free control for the angular speed regulation on bldc motor. In *Memorias del 2024 Congreso Nacional de Control Automático*, 518–523. AMCA.

Nugraha, M.H., Abdul, F., Bramantyo, L., Rijanto, E., Saputra, R.P., and Mahendra, O. (2024). Mobile robot localization via indoor positioning system and odometry fusion. In *2024 IEEE International Conference on Smart Mechatronics (ICSMech)*, 1–6. IEEE.

Tang, L., Yan, F., Zou, B., Wang, K., and Lv, C. (2020). An improved kinematic model predictive control for high-speed path tracking of autonomous vehicles. *IEEE Access*, 8, 51400–51413. doi: 10.1109/ACCESS.2020.2980188.

Vivacqua, R.P.D., Bertozzi, M., Cerri, P., Martins, F.N., and Vassallo, R.F. (2018). Self-localization based on visual lane marking maps: An accurate low-cost approach for autonomous driving. *IEEE Transactions on Intelligent Transportation Systems*, 19, 582–597. doi: 10.1109/TITS.2017.2752461.

Wang, H., Liu, B., Ping, X., and An, Q. (2019). Path tracking control for autonomous vehicles based on an improved mpc. *IEEE Access*, 7, 161064–161073. doi: 10.1109/ACCESS.2019.2944894.

Wu, Y., Wang, L., Zhang, J., and Li, F. (2019). Path following control of autonomous ground vehicle based on nonsingular terminal sliding mode and active disturbance rejection control. *IEEE Transactions on Vehicular Technology*, 68, 6379–6390. doi: 10.1109/TVT.2019.2916982.

Yang, Y., Chen, G., and Wang, X. (2024). Differential steering control method for autonomous vehicles based on pure-pursuit algorithm. In *2024 4th Asia-Pacific Conference on Communications Technology and Computer Science (ACCTCS)*, 356–360. IEEE.