

Aprendizaje de trayectorias vía demostraciones para vehículo marino no tripulado

Becerra-Mora, Y.^{a,b,*}, Conejero, V.Q.^a, Castaño, A.R.^a, Acosta, J.Á.^a

^aDepto. de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino Descubrimientos, 41092 Sevilla, España.

^bDepto. de Ingeniería Electrónica, Corporación Unificada Nacional (CUN), Calle 12b # 4-79, 111711, Bogotá, Colombia.

To cite this article: Becerra-Mora, Y., Conejero, V.Q., Castaño, A.R., Acosta, J.A. 2023. Trajectories learning by demonstrations for unmanned superficial vehicle.

XLIV Jornadas de Automática, 1-5. <https://doi.org/10.17979/spudc.9788497498609.001>

Resumen

En los últimos años está habiendo un auge importante en el empleo de embarcaciones no tripuladas (USV en su acrónimo anglosajón) para diversas aplicaciones, debido al incremento en la eficiencia y seguridad que pueden aportar. Para ello es necesario que estos vehículos no tripulados puedan desplazarse en el entorno de un puerto de forma segura y cumpliendo con las restricciones que establecen la normativa náutica general y la específica del puerto. En la literatura se han propuesto diversos métodos de planificación, que no garantizan el cumplimiento de las restricciones marcadas por las boyas y otras señalizaciones según dichas normativas. En este artículo se propone una metodología que permite obtener las trayectorias que deben realizarse en diversas maniobras en un puerto mediante el aprendizaje automático de las operaciones realizadas por un patrón con experiencia, de forma que pueda sustituir al sistema de planificación convencional. Los datos empleados para el método de aprendizaje han sido obtenidos experimentalmente mediante pruebas realizadas con el USV Vendaval en el puerto de Ceuta.

Palabras clave: Aprendizaje por Demostración, Vehículo de Superficie no Tripulado, Mezcla Gaussiana, Lyapunov.

Trajectories learning by demonstrations for unmanned superficial vehicle

Abstract

In recent years there has been an important increase in the use of Unmanned Surface Vessels (USV) for different applications, due to the greater efficiency and safety they can provide. This requires that these unmanned vehicles can navigate safely in a port area and in compliance with the general and port-specific regulations. Various planning methods have been proposed in the literature, which do not guarantee compliance with the restrictions set by buoys and other signaling according to these regulations. This paper proposes a methodology to obtain the trajectories to be performed in various maneuvers in a port by automatic learning the operations performed by an experienced skipper, so that it can replace the conventional planning system. The data used for the learning method have been obtained experimentally through tests carried out with the USV Vendaval in the port of Ceuta.

Keywords: Learning from Demonstrations, Unmanned Surface Vehicle, Gaussian Mixture, Lyapunov.

1. Introducción

Los Vehículos de Superficie No tripulados (USV)¹ han tomado gran relevancia en los últimos años, debido a que estos incrementan la seguridad y eficiencia en su operación, al igual que minimizan los errores humanos que pueden llevar a pérdidas financieras e inclusive accidentes. Diversas aplicaciones co-

mo el transporte de personas o carga, rescate, reconocimiento, entre otras, pueden ser realizadas por los USV; sin embargo, son los humanos los que aún desempeñan estas tareas en la mayoría de los casos. Debido a su alto grado de repetibilidad, se puede usar la experiencia humana y enseñarle a las máquinas como realizar este tipo de tareas a través de técnicas de Inteligencia Artificial.

*Autor para correspondencia: yeyson_becerra@cun.edu.co

Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

¹Toda las siglas se dejan en la denominación inglesa de uso común.

Las trayectorias realizadas por un USV son inherentemente no lineales, lo cual lleva a buscar métodos o estrategias que permitan tratar estas dinámicas. Diversos métodos tales como planificación de rutas, aprendizaje por refuerzo, procesos Gaussianos, entre otros, han sido propuestos para el control de vehículos marinos autónomos. La planificación de rutas es un método usualmente empleado en estos sistemas Wang and Xu (2020); Gonzalez-Garcia et al. (2022) cuando se cuenta con una serie de puntos de referencia, así como la sensores suficientes para conocer su estado actual y ubicación en tiempo real; también se ha usado en los USV el aprendizaje por refuerzo, generando políticas que permiten el seguimiento de una trayectoria utilizando puntos de referencia Deraj et al. (2023); en los casos en los que se cuenta con un experto, los procesos Gaussianos son una opción para aprender de las demostraciones realizadas por éste, replicando las dinámicas complejas en este tipo de sistemas Xu et al. (2023).

El aprendizaje basado en demostraciones Calinon (2009) es un método que permite enseñar a un sistema autónomo, tareas complejas que no son fáciles de programar en éste; además, un usuario experto en dicha tarea puede transmitir su conocimiento al robot sin necesidad de un programador que interprete y escriba el código para ello. Este método ha sido empleado para programar manipuladores Vogt et al. (2017), robots bípedos Farchy et al. (2013), vehículos terrestres no tripulados (UGV) Li et al. (2017), vehículos aéreos no tripulados (UAV) Loquercio et al. (2018), vehículos submarinos autónomos (AUV) Birk et al. (2018), entre otros. Una de las ventajas que tiene este método sobre los basados en planificadores de rutas o inclusive aprendizaje por refuerzo, es que no se tiene que discretizar la ruta en puntos de referencia, así como tampoco es necesario un mapa del entorno una vez se aprende la ruta.

La mayoría de estudios referentes a realizar seguimiento de trayectoria con USV, se han basado en métodos de planificación de rutas y aprendizaje por refuerzo; sin embargo, poco se ha propuesto en aprendizaje basado en demostraciones. Un controlador basado en un set de datos para USV es presentado en este estudio. cuyas principales ventajas son la baja carga computacional y la convergencia asegurada. Las demostraciones de las trayectorias realizadas por un experto son aprendidas a través de un modelo de mezcla Gaussiana (GMM), para posteriormente ser reconstruidas a través de las estimaciones realizadas con la regresión de mezcla gaussiana (GMR), garantizando la convergencia al objetivo empleando una ley de control no lineal basada en la fórmula de Sontag.

El resto del artículo se estructura de la siguiente manera. En la Sección 2 se describe el planteamiento del problema y el sistema empleado. En la sección 3, se presenta el método de aprendizaje utilizado. En la sección 4, se describen los experimentos realizados el USV y su aprendizaje. Finalmente, en la sección 5, se resume los principales aportes y se extraen conclusiones del estudio.

2. Descripción del problema

El problema que se plantea es el guiado de un USV en el entorno de un puerto. Esto incluye tanto maniobras de entrada y salida del puerto como desplazamientos en su interior. En una embarcación convencional el patrón, en base a su experiencia,

conocimiento del puerto y normativa aplicable, se encarga de trazar las trayectorias correctas teniendo en cuenta la topología del puerto y la señalización marítima. Así por ejemplo, tanto al arribar como al zarpar se debe navegar por el lado derecho del canal delimitado por las boyas rojas y verdes que definen la zona navegable de entrada y salida. Esto supone navegar siempre dentro de dicho canal, pero dejando las boyas rojas a babor (izquierda) y las verdes a estribor (derecha) en la región de balizamiento A (Europa, África, Oceanía y Asia, excluidos Japón, Corea y Filipinas) definida por la IALA (International Association of Marine Aids to Navigation and Lighthouse Authorities). Ya dentro del puerto el patrón se encarga de evitar zonas de poco calado, además de aplicar la reglamentación especial de que pueden disponer los puertos comerciales.




Figura 1: Vista del puerto de Ceuta donde se realizan los experimentos.

En el caso de los USV, se han propuesto diversos algoritmos de planificación para realizar las maniobras descritas anteriormente (Zhou et al. (2020); Ni et al. (2023)). Esto exige, como mínimo, disponer de una cartografía precisa del puerto para evitar las zonas no navegables, pero esos métodos no consideran las restricciones establecidas por la normativa náutica señaladas anteriormente. En particular, este trabajo se centra en el puerto de Ceuta, cuya cartografía se muestra en la Figura 1. En este artículo se plantea la posibilidad de aprender la dinámica compleja de una embarcación a través de las trayectorias que debe trazar en las maniobras en puerto. Para ello, con el set de datos obtenido durante el pilotaje de un patrón experto se aprende la dinámica que describe dicho proceso, de modo que pueda ser usada posteriormente para el guiado autónomo del USV en las distintas maniobras. Tal como se muestra en la Figura 2, la arquitectura general de un USV cuenta con los siguientes sistemas principales:

- Definición de misión, que permite generar las coordenadas objetivo.
- Planificador, que a partir de las coordenadas objetivo, la posición del USV y la cartografía genera una lista de puntos que definen la trayectoria a ejecutar.
- Evitación de colisiones, que a partir de los obstáculos detectados por los sensores y del camino planificado, propone desviaciones locales respecto al camino de referencia en caso necesario.
- Controlador del barco, que se encarga de accionar los actuadores para alcanzar los puntos del camino planificado (o evitar una colisión), manteniendo el rumbo y velocidad adecuados.

- Estimador de estado, que calcula la posición, velocidad y rumbo del USV a partir de los sensores inerciales y GNSS embarcados.

El objetivo de la metodología propuesta, por tanto, es sustituir los sistemas marcados en amarillo en la Figura 2 (planificador y cartografía), de forma que, a partir de una posición inicial y de una posición objetivo se genere una trayectoria de referencia que cumpla con las condiciones y particularidades del puerto.

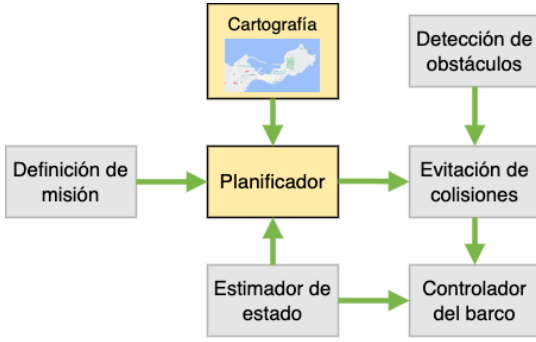


Figura 2: Estructura general de sistemas de un USV.

3. Método de aprendizaje

En esta sección se presenta el método empleado para que el USV aprenda de las demostraciones realizadas por el experto, y asegure la convergencia al objetivo, rechazando las perturbaciones inducidas por un entorno marítimo. Este método puede ser dividido en tres partes para su mejor comprensión: por un lado, se encuentra el GMM que se encarga de describir el set de datos a partir de parámetros de media y varianza, y el GMR que se encarga de reconstruir una estimación a partir de estos parámetros; por otro lado, un controlador basado en la teoría de Lyapunov garantiza la estabilidad asintótica de las reproducciones; y por último, se define un problema de optimización para el aprendizaje que determina los parámetros óptimos del GMM y del controlador (no lineal) con convergencia al objetivo.

Observación 1. Es importante destacar que no se le proporciona al método de aprendizaje parámetros físicos de la embarcación o del propio entorno marítimo, siendo ese el principal motivo de incorporar un controlador en el aprendizaje.

3.1. Estimación de la trayectoria con GMM/GMR

El GMM se encuentra dentro de los métodos de aprendizaje no supervisado y se basa a su vez en el algoritmo de maximización de la esperanza (EM) para encontrar los mejores parámetros (probabilidad a priori π_k , media μ_k y matrices de varianza y covarianza Σ_k) que representen el set de datos,

$$\mu_k = \begin{bmatrix} \mu_k^x \\ \mu_k^y \end{bmatrix}, \quad \Sigma_k = \begin{bmatrix} \Sigma_k^{xx} & \Sigma_k^{xy} \\ \Sigma_k^{yx} & \Sigma_k^{yy} \end{bmatrix}. \quad (1)$$

El número de funciones Gaussianas K a utilizar en GMM se encuentra relacionado con la complejidad de la trayectoria a estimar, i.e. a mayor complejidad de trayectoria, mayor número de Gaussianas a utilizar, así que para inicializar estos parámetros se puede utilizar el algoritmo K-means y estimar K . Las

demostraciones en las cuales se basa el aprendizaje del sistema, están dadas en posiciones y velocidades. Tal y como se afirma en Cohn et al. (1996), uno de los beneficios de GMM es que no se hace distinción entre salidas y entradas; para el presente trabajo, esto permite obtener una velocidad estimada \hat{v} a partir del set de datos por medio del GMR a través de la fórmula

$$\hat{v} = \sum_{k=1}^K h_k(x) \left(\mu_k^v + \frac{\Sigma_k^{vx}}{\Sigma_k^{xx}} (x - \mu_k^x) \right), \quad h_k(x) = \frac{\pi_k P(x|k)}{\sum_{i=1}^K \pi_i P(x|i)}, \quad (2)$$

donde h_k es un término no lineal Bishop (2006), $P(x|k)$ es una función de densidad de probabilidad que se encuentra definida por la distribución normal Gaussiana y x representa el vector que contiene la de posición del set de datos.

3.2. Controlador

Como se observó en la anterior sección, GMM/GMR realiza una estimación de la data; sin embargo, esta estimación no permite converger al objetivo e inclusive puede verse afectada por las perturbaciones del entorno. Por tal razón, se propone un controlador basado en la fórmula universal de Sontag Sontag (1989) cuya función de control o energía es una suma ponderada de funciones asimétricas bi-cuadráticas $V(x; P_l, \beta_l, \mu_l)$, $l = 1, \dots, L$, donde L es el número de funciones asimétricas y P_l, β_l y μ_l sus parámetros Khansari and Billard (2014). Esta función es suficientemente flexible para las trayectorias complejas utilizadas.

3.3. Problema de optimización

A través del problema de optimización se buscan los parámetros óptimos para el GMM (π_k, μ_k, σ_k) de (2) y (P_l, μ_l) de la función V . La función objetivo empleada busca minimizar el error entre la velocidad proveniente de las demostraciones v y la velocidad estimada \hat{v} . No se puede garantizar una solución óptima debido a que es un problema no convexo, pero sí es posible encontrar un mínimo local con el método propuesto. El problema de optimización con restricciones se define como

$$\begin{aligned} \min_{\theta} \quad & J(x^{m,n}; \theta) := \frac{1}{2MN} \sum_{m=1}^M \sum_{n=1}^N |v^{m,n} - \hat{v}^{m,n}|^2 \\ \text{s.t.} \quad & \sum_{k=1}^K \pi_k = 1; \quad 0 < \pi_k < 1, \\ & \Sigma_k > 0; \quad k = 1, \dots, K, \\ & P_l + (P_l)^T > 0; \quad l = 0, \dots, L, \end{aligned} \quad (3)$$

donde M representa el número de demostraciones y N el número de puntos de cada demostración.

4. Experimentos

Los experimentos se han realizado en el puerto de Ceuta (Figura 1) con el USV Vendaval (Figura 3). El USV Vendaval es una embarcación de 10 m de eslora, 3m de manga y que puede alcanzar una velocidad de 25 nudos (46 km/h) gracias a su motor fueraborda de 350 hp. Puede ser pilotado manualmente, teleoperado desde un puesto de control o navegar de forma autónoma siguiendo rutas preprogramadas.



Figura 3: Imagen del USV Vendaval.

En este caso, la embarcación es pilotada manualmente, de forma que el patrón dirige el barco desde una posición inicial hasta un punto objetivo señalado en la pantalla que muestra la cartografía del puerto. El patrón de forma manual, y apoyado en las indicaciones del ECDIS (Electronic Chart Display and Information System) navega hacia el punto señalado y detiene la embarcación cuando considera que se ha alcanzado. Durante este recorrido se registran los datos de posición y orientación del barco, repitiéndolo varias veces variando la posición inicial de la embarcación pero manteniendo el punto objetivo.

Una vez realizadas las demostraciones por el patrón, se le transfiere la data recolectada al método con el fin de obtener estimaciones de las mismas, partiendo estas de los mismos puntos de origen hacia un único objetivo. Para la adaptación de la información grabada se procesa cada conjunto de demostraciones de la siguiente forma:

1. Se transforman de coordenadas geográficas a UTM (*Universal Transverse Mercator*). Para ello se utiliza el datum geodésico estándar en Europa ETRS89 (*European Terrestrial Reference System 1989*), que designa ejes de coordenadas a cada región de la superficie terrestre, minimizando el error de no considerar la curvatura terrestre.
2. El punto final (objetivo) de cada una de las demostraciones realizadas, se establece en el origen de coordenadas.
3. El factor humano hace que las demostraciones en entorno real no alcancen el mismo objetivo, así que se trasladan las para que converjan al mismo punto final.

Para la correcta estimación de las trayectorias, así como la convergencia al objetivo; se deben ajustar el número de funciones Gaussianas K asociadas al GMM/GMR, el número de funciones asimétricas asociadas a la función de energía L , y una ganancia asociada al controlador empleado. Como se mencionó previamente, tanto las funciones Gaussianas como las asimétricas se establecen de acuerdo a la complejidad de la trayectoria que se desea aprender. En el caso de la ganancia del controlador, se busca un valor pequeño que fuerce al sistema converger al objetivo, ya que una mayor acción de control priorizará la convergencia, afectando la calidad en la estimación.

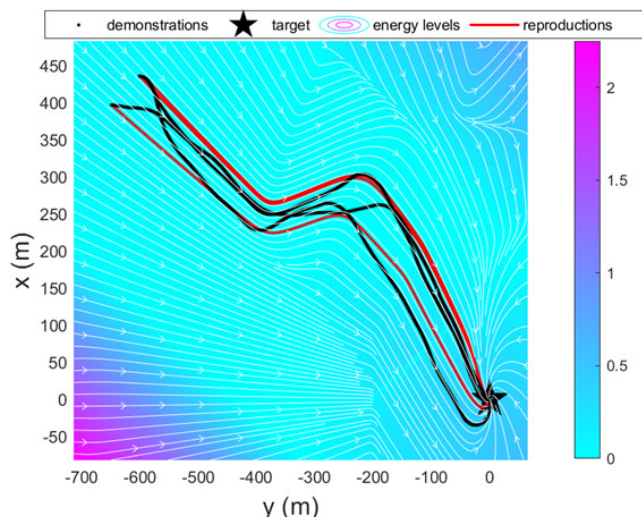


Figura 4: Aprendizaje de las trayectorias a partir de las demostraciones.

En la Figura 4 se observa las demostraciones (curvas negras) y las estimaciones (curvas rojas), así como las líneas de flujo (curvas blancas) y la reducción del nivel de energía que hace converger al sistema a su objetivo; estos niveles de energía se representan a través del mapa de color del fondo de la Figura 4 con su escala en el margen derecho, donde cero es la ausencia total de energía que hace al sistema asintóticamente estable.




Figura 5: Trayectorias registradas durante la navegación de la embarcación.

Como puede verse en la Figura 5, la embarcación parte de posiciones situadas en el área de poniente del puerto y navega hacia el punto objetivo situado en la zona de levante. Durante esa trayectoria debe evitar el muelle España donde se ubica la torre de control del puerto. Las líneas punteadas negras representan las demostraciones realizadas por el patrón, mientras que las líneas continuas rojas representan las estimaciones de las mismas.

Cualitativamente se puede observar la semejanza entre las demostraciones y las estimaciones; sin embargo, una forma de cuantificar los resultados obtenidos es a través del error del barrido de área, el cual se basa en calcular el área que se forma entre la enésima demostración y su respectiva estimación; para el caso presentado, el error del barrido de área medio se encuentra en $24,80 \times 10^3 \text{ m}^2$.

5. Conclusiones

En este estudio se ha presentado un método para el control basado en datos para USV. Se puede corroborar que el aprendizaje basado en demostraciones permite que una persona no experta programe automáticamente este tipo de sistemas basándose tan solo en la experiencia que se tiene en el desempeño de la tarea por un patrón experto.

Con estos primeros resultados, se propone para futuros trabajos, aprender no solo la posición del sistema, sino también la orientación del mismo, teniendo en cuenta las perturbaciones que establece el entorno. Además, realizar un análisis probabilístico que permita medir la efectividad del método propuesto ante diversas entradas aleatorias.

Agradecimientos

El trabajo presentado en este artículo ha sido financiado parcialmente por el Ministerio de Ciencia e Innovación mediante el proyecto "Sistema robótico híbrido aéreo-acuático para muestreo, monitorización e intervención" (PID2020-119027RB-I00) y el proyecto "HOMPOT" (P20.00597) bajo el marco de trabajo PAIDI 2020.

Referencias

Birk, A., Doernbach, T., Mueller, C., Łuczynski, T., Gomez Chavez, A., Koehntopp, D., Kupcsik, A., Calinon, S., Tanwani, A. K., Antonelli, G., Di Lillo, P., Simetti, E., Casalino, G., Indiveri, G., Ostuni, L., Turetta, A., Caffaz, A., Weiss, P., Gobert, T., Chemisky, B., Gancet, J., Siedel, T., Govindaraj, S., Martinez, X., Letier, P., 2018. Dexterous underwater manipulation from onshore locations: Streamlining efficiencies for remotely operated underwater vehicles. *IEEE Robotics Automation Magazine* 25 (4), 24–33.
DOI: [10.1109/MRA.2018.2869523](https://doi.org/10.1109/MRA.2018.2869523)

Bishop, C., 2006. *Patter Recognition and Machine Learning*. Springer New York, NY.

Calinon, S., 2009. *Robot Programming by Demonstration: A Probabilistic Approach*. EPFL/CRC Press, ePFL Press ISBN 978-2-940222-31-5, CRC Press ISBN 978-1-4398-0867-2.

Cohn, D. A., Ghahramani, Z., Jordan, M. I., 1996. Active learning with statistical models. *Journal of Artificial Intelligence Research* 4, 129–145.

Deraj, R., Kumar, R. S., Alam, M. S., Somayajula, A., 2023. Deep reinforcement learning based controller for ship navigation. *Ocean Engineering* 273, 113937.
URL: <https://www.sciencedirect.com/science/article/pii/S0029801823003219>
DOI: <https://doi.org/10.1016/j.oceaneng.2023.113937>

Farchy, A., Barrett, S., MacAlpine, P., Stone, P., 2013. Humanoid robots learning to walk faster: From the real world to simulation and back. In: *Proceedings of the 2013 International Conference on Autonomous Agents and Multi-Agent Systems. AAMAS '13*. International Foundation for Autonomous Agents and Multiagent Systems, Richland, SC, p. 39–46.

Gonzalez-Garcia, A., Collado-Gonzalez, I., Cuan-Urquiza, R., Sotelo, C., Sotelo, D., Castañeda, H., 2022. Path-following and lidar-based obstacle avoidance via nmpc for an autonomous surface vehicle. *Ocean Engineering* 266, 112900.
URL: <https://www.sciencedirect.com/science/article/pii/S0029801822021837>
DOI: <https://doi.org/10.1016/j.oceaneng.2022.112900>

Khansari, S. M., Billard, A., 2014. Learning control lyapunov function to ensure stability of dynamical system-based robot reaching motions. *Robotics and Autonomous Systems* 62 (6), 752–765.

Li, Y., Song, J., Ermon, S., 2017. Infogail: Interpretable imitation learning from visual demonstrations. In: *Proceedings of the 31st International Conference on Neural Information Processing Systems. NIPS'17*. Curran Associates Inc., Red Hook, NY, USA, p. 3815–3825.

Loquercio, A., Maqueda, A. I., del Blanco, C. R., Scaramuzza, D., 2018. Drone: Learning to fly by driving. *IEEE Robotics and Automation Letters* 3 (2), 1088–1095.
DOI: [10.1109/LRA.2018.2795643](https://doi.org/10.1109/LRA.2018.2795643)

Ni, S., Wang, N., Qin, Z., Yang, X., Liu, Z., Li, H., 2023. A distributed coordinated path planning algorithm for maritime autonomous surface ship. *Ocean Engineering* 271, 113759.
URL: <https://www.sciencedirect.com/science/article/pii/S0029801823001439>
DOI: <https://doi.org/10.1016/j.oceaneng.2023.113759>

Sontag, E., 1989. A 'universal' construction of artstein's theorem on nonlinear stabilization. *Systems & Control Letters* 13 (2), 117–123.
DOI: [https://doi.org/10.1016/0167-6911\(89\)90028-5](https://doi.org/10.1016/0167-6911(89)90028-5)

Vogt, D., Stepputtis, S., Grehl, S., Jung, B., Ben Amor, H., 2017. A system for learning continuous human-robot interactions from human-human demonstrations. In: *2017 IEEE International Conference on Robotics and Automation (ICRA)*. pp. 2882–2889.
DOI: [10.1109/ICRA.2017.7989334](https://doi.org/10.1109/ICRA.2017.7989334)

Wang, N., Xu, H., 2020. Dynamics-constrained global-local hybrid path planning of an autonomous surface vehicle. *IEEE Transactions on Vehicular Technology* 69 (7), 6928–6942.
DOI: [10.1109/TVT.2020.2991220](https://doi.org/10.1109/TVT.2020.2991220)

Xu, P., Qin, H., Ma, J., Deng, Z., Xue, Y., 2023. Data-driven model predictive control for ships with gaussian process. *Ocean Engineering* 268, 113420.
URL: <https://www.sciencedirect.com/science/article/pii/S0029801822027032>
DOI: <https://doi.org/10.1016/j.oceaneng.2022.113420>

Zhou, C., Gu, S., Wen, Y., Du, Z., Xiao, C., Huang, L., Zhu, M., 2020. The review unmanned surface vehicle path planning: Based on multi-modality constraint. *Ocean Engineering* 200, 107043.
URL: <https://www.sciencedirect.com/science/article/pii/S0029801820301177>
DOI: <https://doi.org/10.1016/j.oceaneng.2020.107043>