

Prediction of the Estimated Time of Arrival of Container Ships on Short-Sea Shipping: A Pragmatical Analysis

Clara I. Valero , Ángel Martínez , Raúl Oltra , Hermenegildo Gil , Fernando Boronat  (Senior Member, IEEE) and Carlos E. Palau  (Senior Member, IEEE)

Abstract—Fighting against climate change and global warming is one of the biggest challenges faced by the Maritime Industry nowadays to make the supply chain greener and environmentally sustainable. Cutting greenhouse gases (GHG) emissions and decarbonizing the international shipping has been a paramount activity for the International Maritime Organization (IMO) since the first set of international mandatory measures to improve ships' energy efficiency and reduce CO₂ emissions per transport work, as part of the International Convention for the Prevention of Pollution from Ships (MARPOL) released in 2011. Besides that, changes in consumption habits around the globe (i.e., digitalization and growth of e-commerce) plus disruptive events like the COVID-19 or the blocking of the Suez Canal, to name only a few, have also highlighted the need for building more resilient maritime transport networks. In this work, a pragmatical analysis of the principal machine learning algorithms has been carried out to provide a qualitative prediction of the Estimate Time of Arrival (ETA) of container vessels applied to short-sea shipping where the distance between ports is reduced. By exploiting both, the Automatic Identification System (AIS) and meteorological data gathered over a desired area of interest, the developed approach delivers a model capable of predicting the ETA of ships where the reaction time of the stakeholders involved in the management of the Port Call is very reduced (i.e., less than two hours of sailing between ports) and therefore, tolerance for error is low. Very positive results were obtained for the training dataset collected under real conditions for more than a year. The best results were obtained by the RF model with a Mean Absolute Error (MAE) and Root Mean Square Error (RMSE) of 11.31 and 19.56 minutes respectively.

Index Terms—Maritime Logistics, Automatic Identification System (AIS), Estimated Time of Arrival (ETA), Machine Learning, Short-Sea Shipping, Green Transition, Decarbonization

I. INTRODUCCIÓN

Las comunidades portuarias son ecosistemas complejos en los que un importante número de actores interactúan de forma coordinada para ofrecer servicios logísticos de alto valor añadido bajo una planificación dinámica y un estricto control de costes. Debido a que existe una fuerte competitividad entre ellas, éstas deben ser diseñadas y operadas para alcanzar altos

índices de productividad, asegurando la operativa diaria y satisfaciendo el cumplimiento de estándares en términos de calidad de servicio, fiabilidad y seguridad. De entre toda la casuística disponible a la hora de realizar el transporte marítimo de bienes intermedios y de consumo manufacturados destaca el realizado con buques portacontenedores. Este transporte se da mediante servicios regulares que forman una red de conexiones directas entre el origen y el destino o con transbordo en puertos intermedios de interconexión. Aunque este tipo de tráfico se redujo en un 1.2% (i.e. 815.6 millones en volumen de contenedores) en el año 2020 debido principalmente al fuerte impacto que supuso la COVID-19, la *United Nations Conference on Trade and Development* (UNCTAD) espera que esta tendencia se revierta con un incremento de un 4.3% en el 2021 y de forma sostenida en un 2.4% anual desde el 2022 hasta el 2026 [1]. Si bien es cierto que la perspectiva a corto plazo es optimista puesto que estas estimaciones suponen una recuperación económica inmediata del sector, el medio y largo plazo acrecientan la necesidad de actuar sobre determinados factores estructurales que garanticen la viabilidad y sostenibilidad del actual modelo de distribución (p. ej. acontecimientos como los vividos recientemente en el Canal de Suez [2] ponen de manifiesto la fragilidad y complejidad de un sistema donde cualquier imprevisto tiene un fuerte impacto en la cadena de suministro completa).

Entre los principales retos y desafíos [3] a los que se enfrenta la industria marítima destaca la descarbonización del sector en aras de reducir las emisiones de CO₂ a la atmósfera procedentes de los buques (de todo tipo, no sólo los portacontenedores). A través de la Organización Marítima Internacional (OMI) se está impulsando una estrategia global [4] que entrará en vigor a partir del año 2023, cuyo objetivo es disminuir drásticamente los niveles de *Carbon Intensity Indicator* (CII) para todo el transporte marítimo internacional. Concretamente, el plan de acción establece unas normas de obligado cumplimiento y recomendaciones para satisfacer determinados niveles de ambición en comparación con los indicadores que había registrados en el año 2008 relativos al CII y los gases de efecto invernadero (GEI). El objetivo: reducir las emisiones de (1) CII en un 40% para el 2030 y un 70% para el 2050, y (2) GEI anuales del tráfico marítimo internacional global en un 50% para el 2050. Para cumplir con las expectativas del plan de acción elaborado por la OMI [5], las navieras como propietarias de las flotas de buques barajan

Clara I. Valero, Fernando Boronat y Carlos E. Palau, Departamento de Comunicaciones, Universitat Politècnica de València, Valencia, Spain. E-mail: clavalpe@upv.es, fboronat@dcom.upv.es, cpalau@dcom.upv.es.

Ángel Martínez, Prodevelop, Valencia, Spain. E-mail: amartinez@prodevelop.es

Raúl Oltra y Hermenegildo Gil, Departamento de Organización de Empresas, Universitat Politècnica de València, Valencia, Spain. E-mail: rauloltra@doe.upv.es, hgil@ai2.upv.es

tres estrategias que posibiliten satisfacer el compromiso de sostenibilidad medioambiental: (1) utilización de carburantes más respetuosos con el medioambiente que contengan menos cantidad de carbono que los actuales combustibles fósiles, (2) empleo de sistemas de propulsión alternativos de alta eficiencia energética diferentes a las hélices convencionales y (3) adaptación inteligente y en tiempo real de la velocidad del buque durante su travesía de forma que ésta se adecue al contexto operativo real teniendo en cuenta, entre otros, los niveles de ocupación y productividad de las terminales de contenedores así como la congestión del puerto destino al que se dirige el barco para realizar la escala.

Aunque la casuística de imprevistos que puede suceder durante la travesía de un buque a puerto no es para nada despreciable, es frecuente que los barcos naveguen a alta velocidad para descubrir en destino que el muelle donde deben atracar no está todavía disponible. Las consecuencias directas: (1) aumento en el consumo de combustible debido a la velocidad y las millas náuticas adicionales recorridas, (2) incremento innecesario de emisiones de CO₂ a la atmósfera por la relación directa entre la velocidad y el CII y (3) tiempos muertos en las inmediaciones del puerto del todo indeseables para la comunidad portuaria en general y para las compañías navieras en particular que tienen un impacto capital en la planificación de la siguiente escala.

Así, conocer de forma precisa cuándo un buque portacontenedores llega al punto de recalada de un puerto es clave no solo para mejorar la eficiencia operativa, sino también para disminuir las emisiones de CO₂ y garantizar la sostenibilidad medioambiental de la cadena de suministro completa. Esto se debe al hecho de que una ETA fiable permite planificar los trabajos que gobiernan la carga y descarga de un buque portacontenedores con menor incertidumbre y adecuar, por tanto, la velocidad del barco al contexto operativo de la terminal de contenedores y reducir las esperas en puerto, con el consiguiente ahorro de combustible y emisiones.

Existen muchas referencias en la literatura que abordan el problema de la predicción de ETA de los buques portacontenedores a puerto [6], sin embargo, éstas ponen el foco en travesías de larga distancia que requieren días o semanas por lo que el margen de maniobra de los agentes es mayor puesto que éstos tienen tiempo suficiente como para descubrir dicha información por sí mismos recurriendo a medios de comunicación tradicionales (p. ej., actualización de ETA por parte del consignatario). Los autores de este trabajo ponen el foco en el mismo problema, aunque haciendo especial hincapié en un escenario que alberga mucha más incertidumbre dado el escaso tiempo de reacción que tienen los agentes portuarios y donde rara vez la información llega actualizada por las vías tradicionales: travesías cortas cuyo tiempo de navegación no supera las dos horas. Al leer y entender de los autores, este artículo es el primer estudio centrado en el cálculo de ETA de buques en trayectos cortos.

El presente trabajo enfrenta los principales algoritmos de aprendizaje automático con el objetivo de predecir de forma automática y precisa la llegada de un buque a puerto de forma que esta información pueda estar a disposición del resto de agentes involucrados en la operativa con suficiente

antelación como para conseguir un impacto positivo en la gestión del mismo. Para tal fin emplea dos conjuntos de datos: un histórico de mensajes AIS reales e información meteorológica correspondiente a la geolocalización de los buques durante este periodo. Los resultados obtenidos muestran que los datos meteorológicos no añaden nueva información a los modelos y, por lo tanto, es preferible no incluirlos durante el entrenamiento. El presente trabajo ha sido realizado como parte del proyecto CDTI COSIBAS [7].

El artículo se estructura como sigue: en la primera sección se introduce el contexto operativo que justifica la investigación realizada. A continuación, se hace una revisión bibliográfica de los principales trabajos disponibles orientados a predecir la ETA a puerto de buques portacontenedores aplicando algoritmos de aprendizaje automático. Seguidamente, se presenta tanto el conjunto de datos disponibles, se describe el proceso de adquisición y preparación de los mismos, así como los algoritmos de aprendizaje automático probados y los diferentes procesos de experimentación. Por último se enumeran las conclusiones obtenidas así como las lecciones aprendidas, y principales referencias sobre las que se sostiene este trabajo de investigación.

II. TRABAJOS RELACIONADOS

Como parte del trabajo realizado, se revisan las siguientes fuentes de referencia [8] [9] en busca de artículos científicos que contribuyan al estado del arte del siguiente tópico: predicción de ETA (Estimated Time of Arrival) a puerto de buques portacontenedores por medio de la utilización de algoritmos de aprendizaje automático. Los autores no han encontrado ningún artículo dedicado a predecir la hora de llegada al punto de recalada para travesías de corto alcance. Por este motivo, se ha decidido no incluir la restricción de la distancia en la palabra clave de búsqueda. Como punto de partida nos hemos apoyado en una revisión exhaustiva [6] del estado del arte que analiza una década de artículos científicos, desde el 2012 hasta el 2021, complementándola con los nuevos trabajos que se han publicado desde entonces (2021 y 2022). Como se ha mencionado anteriormente, la principal limitación encontrada en trabajos anteriores es que ninguno de ellos se centra en la problemática del cálculo de la ETA en viajes cortos cuya casuística es de gran importancia en el presente trabajo. Es importante mencionar que de entre todas las áreas de aplicación, los autores han incluido en esta revisión bibliográfica aquellos algoritmos de aprendizaje automático orientados a predecir la llegada (i.e., instante temporal) de un buque a puerto, excluyendo cualquier otro tipo de escenario de aplicación (p. ej., optimización de procesos, mejora de rutas, detección de anomalías, etc.).

La estimación de las horas de llegada de los buques a zonas portuarias mediante la explotación de datos históricos es un tema extensamente estudiado en la literatura. En [10], los autores proponen un modelo de árboles de clasificación y regresión (CART, del inglés *Classification and Regression Trees*) para reducir el rango de incertidumbre de las llegadas de buques a puerto, aplicándolo sobre datos registrados en la terminal de transbordo de contenedores de Cagliari (Italia). Durante este

TABLA I
ALGORITMOS DE APRENDIZAJE AUTOMÁTICO ORDENADOS
POR RECURRENCIA EN PUBLICACIONES.

Palabra clave	Algoritmos
machine learning	random forest
prediction of	gradient boosting
the Estimated Time	classification tree
of Arrival of	regression tree
container ship	bagging
	k-nearest neighbors
	decision trees
	support vector machines
	adaboost.m1
	support vector regression
	extremely randomized trees
	adaptive boosting
	back-propagation neural networks
	fuzzy rule-based bayesian network
	logistic regression
	wavenet
	natural gradient boosting
	extreme gradient boosting
	linear regression trees
	linear support vector regression
	non-linear support vector regression
	random forest regression
	deep neural network
	graph neural networks
	dynamic graph convolutional recurrent network
	linear regression
	regression trees with different sizes
	regression trees ensembles
	gaussian process regression
	multinomial logistic regression

trabajo se generó una base de datos que contiene información sobre los buques que llegaron a la terminal de contenedores durante el año 2010. En [11], los investigadores emplearon técnicas de minado de datos para abordar este problema. Concretamente, aplicaron *back-propagation neural networks*, CART y *Random Forest* (RF) para predecir la hora de llegada de los buques a una terminal de contenedores en China. Los experimentos mostraron que el modelo RF proporcionaba una mejor estimación a los otros dos. Un estudio similar en [12] propone un modelo que utiliza una técnica híbrida de toma de decisiones, *Fuzzy Rule-Based Bayesian Network*. En [13] se presenta un enfoque de aprendizaje automático basado en datos para la predicción de la velocidad de los buques mediante regresión, utilizando un conjunto de datos operativos de alta calidad de acceso público del ferry "M/S Smyril". Por último, [14] propone un método de predicción del tráfico marítimo para prever el panorama del tráfico marítimo y su incertidumbre, proporcionando información sobre la densidad del tráfico y la distribución de los puntos conflictivos con antelación.

De manera más específica, las soluciones basadas en datos AIS son cada vez más estudiadas. La extracción de patrones y el reconocimiento de eventos basados en datos AIS tienen como objetivo transformar las tramas en información comprensible, por ejemplo, patrones de rutas marítimas, identificación de clases de buques, etc. [15] presenta una metodología de extracción de rutas de tráfico para detectar comportamientos poco probables y predecir las posiciones futuras de los buques. En [16] se presenta un servicio cognitivo, cuyo elemento prin-

cipal es un modelo basado en el algoritmo *-Nearest Neighbor* (KNN), capaz de predecir la ETA de los buques en el puerto de Valencia (España). En [17] y [18] se desarrollaron dos soluciones al DEBS Grand Challenge 2018 [19] para predecir el destino y la hora de llegada de los buques a puerto. En ambos estudios se emplearon redes neuronales profundas. En [20] se propone una metodología para obtener la ETA de los buques utilizando datos históricos de tráfico marítimo AIS y *Long Range Identification and Tracking* (LRIT) que emplea un algoritmo optimizado de búsqueda de rutas basado en datos. En [21] se desarrolla una estrategia de decisión para la predicción del destino de los buques basada en trayectorias anteriores. Para ello se comparan trayectorias anteriores con la trayectoria actual y a través de un modelo basado en RF se mide la similitud entre trayectorias. Durante este trabajo se creó una base de datos con más de 141 millones de registros AIS.

En la Tabla I se incluye un resumen de los principales algoritmos de aprendizaje automático utilizados para estimar la llegada a puerto de buques portacontenedores encontrados en los artículos científicos revisados. Muchos de éstos son utilizados en diferentes trabajos por lo que el criterio de ordenación escogido para dotar de mayor claridad a la tabla resumen resultante ha sido la recurrencia, esto es, las posiciones superiores las copan aquellos algoritmos más empleados y a la inversa. De este modo, se proporciona un criterio de selección claro a la hora de escoger un algoritmo, en detrimento de otro.

III. MATERIALES Y MÉTODOS

A. Conjuntos de Datos

En este trabajo se han creado dos conjuntos de datos. En primer lugar, se utilizó un receptor AIS [22] para construir un histórico de las tramas transmitidas por todos los buques portacontenedores que estuvieron dentro del alcance del receptor en un período temporal de 6 meses. Los mensajes AIS contienen información estática del buque (p. ej. nombre, identificador único, tipo, dimensiones físicas, etc.) además de información dinámica (p. ej., latitud, longitud, velocidad, curso, etc.). Tras la obtención de los datos históricos, se eliminaron las tramas correspondientes a rutas erróneas o que contuviesen campos incompletos. La predicción de la ETA de los buques ha sido abordada como una tarea de regresión, donde la variable a predecir son los minutos restantes para que el buque llegue al puerto de destino. Así, en cada uno de los mensajes se ha calculado y agregado este valor. El conjunto de datos resultante incluye 3.761.994 mensajes AIS correspondientes a las rutas realizadas por 6.618 buques portacontenedores (i.e., DT-AIS).

El conjunto de datos anterior (i.e., DT-AIS) fue complementado con información meteorológica correspondiente a la geolocalización de los buques durante este periodo. El origen de los datos vino del proveedor World Weather Online [23]. En este caso, la información adicional adherida incluye la temperatura del agua, velocidad y dirección del viento, precipitaciones, visibilidad, presión atmosférica, altura, dirección y período del oleaje (i.e., DT-AISMET).

B. Algoritmos de Aprendizaje Automático

Esta sección describe los principales algoritmos de aprendizaje automático identificados en la sección anterior como los más relevantes de cara a estimar los minutos restantes desde una ubicación particular de un buque portacontenedores hasta su llegada al punto de recalada del puerto objetivo en trayectos cortos.

- Linear Regression (LR) [24]: Ajusta un modelo lineal con coeficientes para minimizar la suma residual de cuadrados entre los objetivos observados en el conjunto de datos y los objetivos predichos por la aproximación lineal.
- Decision Trees (DT) [25]: Método no paramétrico cuyo objetivo es crear un modelo que prediga el valor de una variable objetivo mediante el aprendizaje de reglas de decisión simples inferidas a partir de las características de los datos.
- Random Forest (RF) [26]: Meta estimador que ajusta varios clasificadores de árboles de decisión en varias submuestras del conjunto de datos y utiliza el promedio para mejorar la precisión de la predicción y controlar el sobreajuste.
- K-Nearest Neighbor (KNN) [27]: Método no paramétrico que calcula la probabilidad de que un elemento pertenezca a un grupo u otro en función del grupo al que pertenezcan los elementos más cercanos.
- Gradient Boosting (GB) [28]: Produce un modelo predictivo a partir de un conjunto de modelos predictivos débiles, típicamente árboles de decisión. Para ello, construye los modelos de forma escalonada y los generaliza permitiendo la optimización arbitraria de una función de pérdida diferenciable.

Además, teniendo en cuenta que la utilización de atributos irrelevantes y redundantes pueden confundir a los algoritmos de aprendizaje automático [29] se han seleccionado los predictores empleando un método de selección y cribado. Estos métodos tienen como objetivo la obtención de un subconjunto pequeño de atributos suficientemente representativos del problema original, en aras de reducir la complejidad del mismo sin afectar a la calidad del resultado. En concreto, se ha empleado el algoritmo de clasificación *random forest* que es capaz de determinar la importancia de los atributos de forma automática.

C. Experimentos

En esta sección se presentan los experimentos realizados para la obtención de un modelo de regresión capaz de predecir con exactitud la ETA a puerto de los buques portacontenedores. Los experimentos ejecutados, de forma independiente, quedan resumidos en la Tabla II.

TABLA II
CONJUNTO DE EXPERIMENTOS.

	Algoritmos	Dataset
E-01	LR, DT, RF, KNN	DT-AIS
E-02	DT, RF, GB, KNN	DT-AISMET
E-03	LR, DT, RF, GB, KNN	DT-AISMET

El experimento E-01 considera únicamente los atributos del conjunto de datos DT-AIS. Se centra en determinar si es posible alcanzar un modelo fiable para predecir la ETA de los buques utilizando tanto aprendices débiles [30], modelos que se comportan ligeramente mejor que las conjeturas aleatorias, (p. ej. LR y DT) como aprendices fuertes, modelos que tienen una precisión arbitraria, (p. ej. RF y KNN), y compara la precisión aportada por cada uno en el problema de estudio. Seguidamente, el experimento E-02 consiste en determinar si existen diferencias significativas al entrenar los modelos usando, además, características meteorológicas (conjunto de datos DT-AISMET). En concreto, se añaden los atributos meteorológicos y se analiza su importancia junto al resto de variables del conjunto. Por último, el experimento E-03 busca utilizar los experimentos anteriores como base para continuar mejorando los modelos de predicción. Este experimento demuestra que es posible mejorar notablemente la predicción de la ETA mediante la generación de nuevos atributos utilizando métodos de agregación [31]. Se emplea el conjunto de datos DT-AISMET.

D. Validación de los Modelos

A través de una evaluación experimental se ha verificado cuáles de los modelos obtenidos durante los experimentos ofrecen una buena capacidad de generalización para el problema planteado. Las métricas seleccionadas para su validación son las siguientes: error absoluto medio (MAE, del inglés *Mean Absolute Error*) Ecuación (1), error cuadrático medio (RMSE, del inglés *Root Mean Squared Error*) Ecuación (2) y coeficiente de determinación (R^2) Ecuaciones (3) y (4).

$$MAE = \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{n} \quad (1)$$

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (2)$$

donde \hat{y}_i son los valores reales e y_i los predichos de las n observaciones consideradas.

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\hat{y}_i - \hat{y})^2} \quad (3)$$

donde \hat{y}_i representa el valor predicho de y_i e \hat{y} es la media de los datos observados que se calcula como

$$\hat{y} = \sum_{i=1}^n y_i \quad (4)$$

Respecto a las métricas anteriores, la MAE indica la diferencia absoluta media entre los valores previstos y los valores reales. La métrica RMSE proporciona la raíz cuadrada del promedio de diferencias cuadradas entre la predicción y la observación real. Es decir, RMSE otorga un peso mayor que MAE a los errores grandes. Es el criterio más importante para ajustar si el propósito principal del modelo es la predicción.

En cuando al coeficiente de determinación R^2 , este mide la cantidad de variación que puede ser explicada por los modelos. Durante su entrenamiento y validación se ha utilizado el paquete de aprendizaje automático *Scikit-learn* [32].

IV. RESULTADOS Y DISCUSIÓN

Esta sección presenta los resultados obtenidos para el conjunto de experimentos descritos en la sección anterior cuyo objetivo es determinar la ETA de buques portacontenedores en travesías cortas. Como se ha indicado, las métricas de evaluación utilizadas para validar los modelos son MAE, RMSE y R^2 .

A. Experimento E-01

El experimento E-01 utiliza un número reducido de atributos del conjunto de datos DT-AIS. Para reducir la dimensionalidad, se ha realizado un análisis de la importancia de los atributos del conjunto de datos. La Tabla III incluye los atributos seleccionados junto con su importancia (ver sección III B). Los resultados indican que la latitud y longitud del buque son los atributos con mayor importancia seguidos de su velocidad, eslora y manga.

TABLA III
E-01 - IMPORTANCIA DE LOS ATRIBUTOS.

	Importancia
Latitud	0.375599
Longitud	0.311965
Velocidad	0.187223
Eslora	0.078391
Manga	0.046821

TABLA IV
RESULTADOS DE LAS MÉTRICAS DE EVALUACIÓN DEL EXPERIMENTO E01-1.

	MAE	RMSE	R^2
LR	32.98	50.59	0.35
DT	31.04	47.20	0.46
RF	27.23	46.24	0.53
KNN	23.69	40.99	0.63

TABLA V
RESULTADOS DE LAS MÉTRICAS DE EVALUACIÓN DEL EXPERIMENTO E01-2.

	MAE	RMSE	R^2
LR	32.98	50.59	0.44
DT	31.04	47.20	0.51
RF	28.21	47.50	0.50
KNN	23.61	40.84	0.63

La Tabla IV muestra los resultados de las métricas de evaluación del primer experimento (E-01-1). Se observa que los aprendices débiles (LR y DT) obtienen resultados ligeramente peores a la mayoría de los resultados obtenidos por los aprendices fuertes (RF, GB y KNN). Únicamente el algoritmo KNN ofrece resultados notablemente mejores que el resto de los algoritmos. Sin embargo, los errores de MAE y RMSE son elevados y la bondad del ajuste del modelo (R^2) es algo baja.

A fin de mejorar la precisión de los modelos, se ha incorporado un nuevo atributo construido a partir de los atributos disponibles: la distancia del buque al puerto. La Tabla V resume los resultados obtenidos en esta segunda fase (E-01-2). Se observa que el nuevo atributo contribuye levemente a la mejora de los modelos y por ese motivo se ha decidido incluirlo en los experimentos posteriores.

La Fig. 1 ofrece más detalle del modelo obtenido con el aprendiz KNN en E-01-2. El histograma muestra el error entre el valor predicho y el valor real. La campana es estrecha y está centrada en cero, indicando que la mayoría de las predicciones tienen un error cercano a cero minutos.

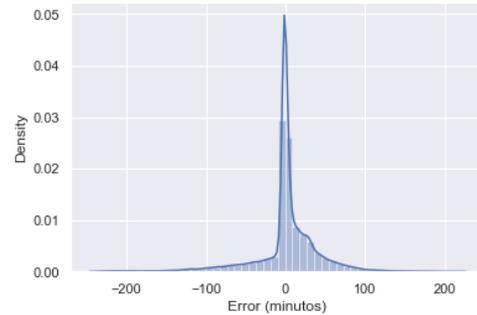


Fig. 1. Distribución de error con KNN en experimento E-01-2. El eje de abscisas indica el error (en minutos) y el eje de ordenadas su densidad.

B. Experimento E-02

En el experimento E-02 se utilizó el conjunto de datos DT-AISMET. Puesto que este conjunto de datos incorpora características meteorológicas, se realizó un nuevo análisis de la importancia de los atributos. Los resultados quedan resumidos en la Tabla VI.

TABLA VI
E-02 - IMPORTANCIA DE LOS ATRIBUTOS.

	Importancia
Distancia	0.223880
Latitud	0.205301
Longitud	0.189084
Velocidad	0.130565
Eslora	0.032919
Dirección del viento	0.031965
Periodo del oleaje	0.030344
Velocidad del viento	0.029790
Presión	0.025588
Altura del oleaje	0.024891
Manga	0.023529
Temperatura del agua	0.021131
Dirección del oleaje	0.017036
Precipitaciones	0.010906
Visibilidad	0.003070

De la Tabla VI se infiere que las variables oceanográficas aportan poca información a los modelos. Sin embargo, se desea cuantificar el comportamiento obtenido al incorporar esta información. Para ello, este experimento se divide en dos fases. En la primera fase (E-02-1) se estudia la bondad del ajuste de los aprendices al incorporar un atributo meteorológico, la dirección del viento (Tabla VII). Durante la segunda

TABLA VII
RESULTADOS DE LAS MÉTRICAS DE EVALUACIÓN DEL
EXPERIMENTO E02-1.

	MAE	RMSE	R ²
DT	31.04	47.19	0.51
RF	27.23	45.90	0.53
GB	32.98	44.27	0.57
KNN	23.69	44.13	0.57

TABLA VIII
RESULTADOS DE LAS MÉTRICAS DE EVALUACIÓN DEL
EXPERIMENTO E02-2.

	MAE	RMSE	R ²
DT	30.95	47.06	0.51
RF	26.80	45.48	0.54
GB	28.30	44.35	0.57
KNN	30.14	52.47	0.39

fase (E-02-2) se incorporaron dos atributos adicionales: el periodo del oleaje y la velocidad del viento (Tabla VIII). El algoritmo LR ha sido sustituido por GB. Esto ha sido motivado por los resultados obtenidos durante el experimento anterior, que demuestra que los aprendices fuertes presentan un mejor comportamiento para realizar las predicciones del problema de estudio.

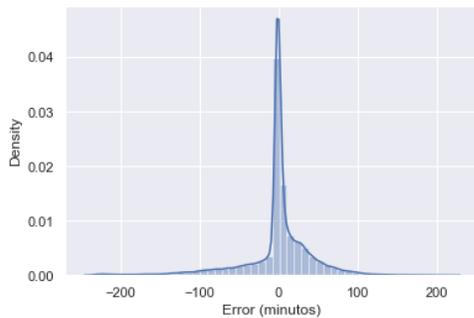


Fig. 2. Distribución de error con KNN en experimento E-02-1. El eje de abscisas indica el error (en minutos) y el eje de ordenadas su densidad.

Ambas tablas muestran resultados peores a los obtenidos durante el experimento E-01. El mejor resultado se obtiene al incorporar únicamente la dirección del viento utilizando el algoritmo KNN con una MAE de 25.11 minutos y RMSE 44.13 minutos. Esto se debe a que las variables oceanográficas están fuertemente interrelacionadas con la velocidad del buque. Cuando las condiciones de navegación empeoran, se reduce su velocidad. Los atributos oceanográficos no añaden nueva información, solo redundancia, empeorando su comportamiento.

La Fig. 2 muestra la distribución de error con el aprendiz KNN en E-02-1. Siguiendo la pauta de las métricas, el histograma apenas varía con respecto al experimento anterior.

C. Experimento E-03

El experimento E-02 no consiguió valores de las métricas de evaluación mejores que en el experimento E-01. Por ese

motivo durante el experimento E0-3 se ha descartó utilizar los atributos meteorológicos. Para lograr una mejora en los modelos predictivos, se ha utilizado el mismo enfoque al utilizado en el primer experimento. Se ha buscado mejorar la precisión de las predicciones añadiendo nuevos atributos en los modelos. Los nuevos atributos se generaron a partir de los ya disponibles y son: tiempo empleado para calcular la velocidad media, velocidad media y aceleración. La tabla VI incluye la importancia de los atributos utilizados en este experimento.

En primer lugar, se evaluó el comportamiento de los modelos generados al utilizar todos los atributos (E-03-1) incluidos en la Tabla X. Los valores de las métricas de evaluación aumentaron considerablemente respecto a los experimentos anteriores. Se observa que los resultados de las métricas de evaluación para los algoritmos RF y KNN mucho mejores que los resultados proporcionados por el resto de los algoritmos y los ajustes de todos los modelos son buenos (cerca de la unidad). Por otro lado, los buenos resultados han motivado volver a utilizar el algoritmo LR. Con él se consigue una MAE de 16.13 minutos con un RMSE bajo, 25.81 minutos y un R² alto (0.85). Se trata de un resultado bueno que demuestra que el uso de los atributos seleccionados permite la resolución de problemas complejos con modelos simples. Este modelo es un buen candidato para ser utilizado en entornos con capacidad computacional ajustada. Si se desea obtener la mayor precisión posible y el coste computacional no es problema, el mejor modelo es el proporcionado por el algoritmo KNN (cuya configuración se resume en la Tabla XII), que ofrece una MAE de 11.31 minutos, RMSE de 19.56 minutos y R² de 0.91.

TABLA IX
E-03 - IMPORTANCIA DE LOS ATRIBUTOS.

	Importancia
Time AvSpeed	0.198273
Distancia	0.156509
Velocidad media	0.134935
Latitud	0.130961
Longitud	0.120629
Velocidad	0.107028
Aceleración	0.073097
Eslora	0.044712
Manga	0.033856

TABLA X
RESULTADOS DE LAS MÉTRICAS DE EVALUACIÓN DEL
EXPERIMENTO E03-1.

	MAE	RMSE	R ²
LR	16.13	25.81	0.85
DT	13.07	47.20	0.88
RF	11.79	19.61	0.91
GB	13.39	21.75	0.89
KNN	11.31	19.56	0.91

Para reducir la dimensionalidad se ha evaluado el comportamiento de modelos entrenados con los mismos atributos a excepción de los menos significativos, manga y eslora (E-03-2). La tabla XI incluye los resultados de la evaluación de esta segunda fase del experimento. Los resultados muestran que su no inclusión mantiene o empeora levemente el comporta-

TABLA XI
RESULTADOS DE LAS MÉTRICAS DE EVALUACIÓN DEL
EXPERIMENTO E03-2.

	MAE	RMSE	R ²
LR	15.03	26.13	0.85
DT	13.76	23.68	0.88
RF	11.79	19.61	0.91
GB	13.77	22.36	0.89
KNN	12.06	20.99	0.90

TABLA XII
CONFIGURACIÓN UTILIZADA DURANTE EL
ENTRENAMIENTO DEL ALGORITMO KNN EN EL
EXPERIMENTO E-03-1.

	Valor
algorithmo	auto
tamaño_hoja	30
metrica	minkowski
parámetros_métrica	ninguno
n_trabajos	0.046821
n_vecinos	70
p	2
pesos	uniforme

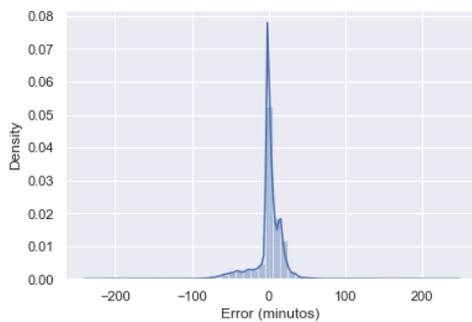


Fig. 3. Distribución de error con KNN en experimento E-03-1. El eje de abscisas indica el error (en minutos) y el eje de ordenadas su densidad.

miento de la mayoría de modelos respecto al subexperimento anterior. El único modelo que mejora levemente es linear regression pero los errores grandes empeoran (RMSE). Por tanto, estos modelos son descartados.

La Fig. 3 muestra la distribución de error con el aprendizaje KNN. Como se observa en la figura, los errores continúan estando centrados en cero y la función de distribución del error es más estrecha que en los experimentos anteriores, lo cual indica que se producen menor cantidad de errores grandes. Con esto se concluye que el modelo obtenido presenta un mejor comportamiento que los modelos anteriores. Por ese motivo el modelo seleccionado es el obtenido con el aprendizaje KNN en el experimento E-03-1.

La precisión obtenida en trabajos anteriores es sensiblemente menor. En ellos se obtienen errores del orden de horas, en lugar de minutos. Las travesías que son objeto de estudio tienen una duración mayor y por lo tanto la incertidumbre asociada a la hora de llegada de los buques también es mayor. Consecuentemente, los modelos obtenidos en trabajos previos presentan menor precisión.

A pesar de los buenos resultados obtenidos por el algoritmo

KNN, en algunos casos el error puede ser demasiado grande. Este hecho se acentúa en travesías de corto alcance como las que son objeto de investigación en este trabajo puesto que un error medio de 11 minutos es demasiado crítico y no permitiría a los diferentes agentes involucrados en la operativa del buque anticiparse a la llegada de este. No obstante, futuros trabajos podrían emplear este modelo como elemento principal de un sistema que permita predecir, de forma automática, la hora de llegada de los buques a puerto. El sistema debería integrar y procesar información AIS y meteorológica en tiempo real y mostrar los resultados a través de una interfaz de usuario, sin necesidad de recurrir a medios de comunicación tradicionales.

V. CONCLUSIONES

En la actualidad, el transporte de buques portacontenedores es una de las actividades de mayor impacto ambiental dentro de las comunidades portuarias. Tradicionalmente son los agentes portuarios los encargados de estimar la hora de llegada de los buques y frecuentemente estas discrepan ampliamente de la hora real. Esto ocurre principalmente por dos motivos. En primer lugar, el intercambio de información entre agentes portuarios, realizado a través de medios tradicionales, frecuentemente es poco fluido. Por otro lado, la casuística de imprevistos durante la travesía es grande y puede desviar ampliamente las estimaciones realizadas. Como resultado, y para evitar ser sancionados por incumplir los contratos de transporte, los buques aumentan significativamente su velocidad con el objetivo de llegar las proximidades del puerto destino mucho antes de lo necesario donde esperan fondeados a su entrada en el puerto. Con ello se aseguran cumplir el horario de llegada, pero lamentablemente el aumento de la velocidad implica un aumento del combustible empleado y, por lo tanto, un incremento innecesario de emisiones de CO₂ a la atmósfera. En este contexto, disponer de un modelo automático de predicción de ETA reduciría la fricción actual a la hora de compartir información además de contribuir a la reducción de emisiones de CO₂. Así, utilizando técnicas de aprendizaje automático el presente trabajo presenta un enfoque pragmático para estimar los tiempos de llegada de los buques a las zonas portuarias para travesías de corto alcance. Al leer y entender de los autores, este es el primer estudio centrado en el cálculo de ETA de buques portacontenedores en trayectos cortos.

Para obtener un modelo capaz de realizar estas predicciones, se han utilizado datos históricos de mensajes AIS extraídos de un escenario real y se han combinado con información oceanográfica sobre una zona de interés deseada y un conjunto de modelos de aprendizaje automático (LR, DT, RF, GB y KNN). La evaluación detallada de estos modelos muestra que los algoritmos KNN proporcionan un comportamiento muy bueno para el conjunto de datos de prueba recogidos en condiciones reales. Pese a que los resultados obtenidos en el presente trabajo son prometedores, en el caso de rutas comerciales con una duración especialmente corta (30-40 minutos), la precisión lograda puede llegar a ser insuficiente. Futuros trabajos podrían estudiar la reducción del error obtenido. Además, el modelo obtenido puede emplearse para construir

un sistema que calcule automáticamente la hora de llegada de los buques a un determinado puerto.

AGRADECIMIENTOS

This work has been developed under the framework of the COSIBAS project (funded by CDTI research and innovation programme under grant agreement No.EXP 00110912/INNO-20181033).

REFERENCIAS

- [1] UNCTAD, "Review of Maritime Transport 2021," tech. rep., United Nations, 2010.
- [2] BBC, "Container ship facts: Egypt's Suez Canal blocked by massive boat." [shorturl.at/lqsH5](https://www.bbc.com/news/technology-57144444), 2021. [Accessed on: Feb. 17, 2022].
- [3] CEPAL, "Grandes desafíos para los puertos en la postpandemia," 2021.
- [4] MARPOL, "Marine environment protection committee (mepc)," 2011.
- [5] I. MEPC72, "Resolution mepc. 304 (72)," *Initial IMO Strategy on Reduction of GHG Emissions from Ships*, 2018.
- [6] K. Tsolaki, T. Vafeiadis, A. Nizamis, D. Ioannidis, and D. Tzovaras, "Utilizing machine learning on freight transportation and logistics applications: A review," *ICT Express*, 2022.
- [7] "COSIBAS cognitive services for iot-based scenarios." <https://itea4.org/project/cosibas.html>, 2022. Accessed on: May 2, 2022.
- [8] T. Gies, "The sciencedirect accessibility journey: A case study.," *Learned publishing*, vol. 31, no. 1, 2018.
- [9] Y. Chen and E. A. Fox, "Using acm dl paper metadata as an auxiliary source for building educational collections.," in *IEEE/ACM Joint Conference on Digital Libraries*, pp. 137–140, IEEE, 2014.
- [10] C. Pani, P. Fadda, G. Fancello, L. Frigau, and F. Mola, "A data mining approach to forecast late arrivals in a transhipment container terminal," *Transport*, vol. 29, no. 2, pp. 175–184, 2014.
- [11] J. Yu, G. Tang, X. Song, X. Yu, Y. Qi, D. Li, and Y. Zhang, "Ship arrival prediction and its value on daily container terminal operation," *Ocean Engineering*, vol. 157, pp. 73–86, 2018.
- [12] N. H. M. Salleh, R. Riahi, Z. Yang, and J. Wang, "Predicting a containership's arrival punctuality in liner operations by using a fuzzy rule-based bayesian network (frbnn)," *The Asian Journal of Shipping and Logistics*, vol. 33, no. 2, pp. 95–104, 2017.
- [13] A. M. Bassam, A. B. Phillips, S. R. Turnock, and P. A. Wilson, "Ship speed prediction based on machine learning for efficient shipping operation," *Ocean Engineering*, vol. 245, p. 110449, 2022.
- [14] H. Rong, A. Teixeira, and C. Guedes Soares, "Maritime traffic probabilistic prediction based on ship motion pattern extraction," *Reliability Engineering & System Safety*, vol. 217, p. 108061, 2022.
- [15] G. Pallotta, M. Vespe, and K. Bryan, "Vessel pattern knowledge discovery from ais data: A framework for anomaly detection and route prediction," *Entropy*, vol. 15, no. 6, pp. 2218–2245, 2013.
- [16] C. I. Valero, E. Ivancos Pla, R. Vaño, E. Garro, F. Boronat, and C. E. Palau, "Design and development of an aiot architecture for introducing a vessel eta cognitive service in a legacy port management solution," *Sensors*, vol. 21, no. 23, p. 8133, 2021.
- [17] C.-X. Lin, T.-W. Huang, G. Guo, and M. D. Wong, "Mtdetector: A high-performance marine traffic detector at stream scale," in *Proceedings of the 12th ACM International Conference on Distributed and Event-Based Systems*, pp. 205–208, 2018.
- [18] O. Bodunov, F. Schmidt, A. Martin, A. Brito, and C. Fetzer, "Real-time destination and eta prediction for maritime traffic," in *Proceedings of the 12th ACM international conference on distributed and event-based systems*, pp. 198–201, 2018.
- [19] V. Gulisano, Z. Jerzak, P. Smirnov, M. Strohbach, H. Ziekow, and D. Zissis, "The debs 2018 grand challenge," in *Proceedings of the 12th ACM International Conference on Distributed and Event-Based Systems, DEBS '18*, (New York, NY, USA), p. 191–194, Association for Computing Machinery, 2018.
- [20] A. Alessandrini, F. Mazzarella, and M. Vespe, "Estimated time of arrival using historical vessel tracking data," *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 1, pp. 7–15, 2018.
- [21] C. Zhang, J. Bin, W. Wang, X. Peng, R. Wang, R. Haldearn, and Z. Liu, "Ais data driven general vessel destination prediction: A random forest based approach," *Transportation Research Part C: Emerging Technologies*, vol. 118, p. 102729, 2020.
- [22] T. Eriksen, G. Høye, B. Narheim, and B. J. Meland, "Maritime traffic monitoring using a space-based ais receiver," *Acta Astronautica*, vol. 58, no. 10, pp. 537–549, 2006.
- [23] WWO, "World weather online." <https://worldweatheronline.com>, [Online], 2022. Accessed on: Feb. 17, 2022.
- [24] G. A. Seber and A. J. Lee, *Linear regression analysis*. John Wiley & Sons, 2012.
- [25] L. Rokach and O. Maimon, "Decision trees," in *Data mining and knowledge discovery handbook*, pp. 165–192, Springer, 2005.
- [26] M. R. Segal, "Machine learning benchmarks and random forest regression," *UCSF: Center for Bioinformatics and Molecular Biostatistics*, 2004.
- [27] L. E. Peterson, "K-nearest neighbor," *Scholarpedia*, vol. 4, no. 2, p. 1883, 2009.
- [28] J. H. Friedman, "Stochastic gradient boosting," *Computational statistics & data analysis*, vol. 38, no. 4, pp. 367–378, 2002.
- [29] H. Liu and R. Setiono, "Incremental feature selection," *Applied Intelligence*, vol. 9, no. 3, pp. 217–230, 1998.
- [30] Z.-H. Zhou, *Ensemble methods: foundations and algorithms*. CRC press, 2012.
- [31] J. Bleiholder and F. Naumann, "Data fusion," *ACM computing surveys (CSUR)*, vol. 41, no. 1, pp. 1–41, 2009.
- [32] J. Hao and T. K. Ho, "Machine learning made easy: a review of scikit-learn package in python programming language," *Journal of Educational and Behavioral Statistics*, vol. 44, no. 3, pp. 348–361, 2019.



Clara I. Valero M.Sc. degree in Telecommunication Engineering from the Universitat Politècnica de València (UPV). She is currently working as a researcher in the Distributed Real Time Systems and Applications Research Group, UPV, where she is currently pursuing the PhD. degree in telecommunications engineering. Her research interests include Internet of Things, machine learning and cloud computing.



Ángel Martínez-Cavero M.Sc. degree in Telecommunication Engineering from the Universitat Politècnica de València (UPV) and PhD student at the Business, Administration and Management School also in the UPV. He is currently the head of the Maritime Operations and Terminales at Prodevelop (SME) where he has to the opportunity to validate new business models as well as to build solid and innovative technological ICT solutions in order to improve performance, user experience and RoI of industrial partners.



Raúl Oltra-Badenes M.Sc. degree in Industrial Engineering and PhD in Integration of Information Technologies in Organizations from the Universitat Politècnica de València (UPV). He is currently professor in the Department of Business Organization at the UPV. He has participated in 14 research projects, 8 of them funded by the European Union. He is author of more than 40 papers, most of them indexed as Q1 and Q2. He is also an Expert and TEP (Technical Specialist in Projects) by AENOR for the evaluation of R+D+i projects.



Hermenegildo Gil-Gómez PhD in Telecommunication Engineering from the Universitat Politècnica de València (UPV). He is currently full professor in the Department of Business Organization and researcher at the University Institute for Research in Automation and Industrial Computing (ai2) at UPV. He has been collaborating in more than 40 projects related to Information Systems, e-businesses and, more recently, to Digital Transformation. He is author of more than 60 papers, most of them indexed as Q1 and Q2. The researcher's publications include more

than 30 publications in JCR journals (most of them indexed in Q1 or Q2) and more than 100 contributions to national and international research conferences.



Fernando Boronat M.E. and Ph.D. degrees in telecommunication engineering from the Universitat Politècnica de València (UPV). He is the head of the Immersive Interactive Media R&D Group at the Gandia Campus of the UPV. After working for several Spanish telecommunication companies, he moved back to the UPV in 1996. He has extensive experience in research and both undergraduate and postgraduate teaching in communication networks, multimedia systems and protocols, and media synchronization.



Carlos E. Palau M.Sc. and PhD degree in Telecommunication Engineering from the Universitat Politècnica de València (UPV). He is currently a Full Professor with the Escuela Técnica Superior de Ingenieros de Telecomunicación, UPV. He has over 20 years of experience in the ICT research area in the field of networking. He has collaborated extensively in the research and development of multimedia streaming, security, networking, and wireless communications for government agencies, defense, and European Commission as a Main Researcher of EU-

FP6, EU-FP7, and EU-H2020 Programs.