

Опыт Прогнозирования Интенсивности Морского Трафика на Основе Компьютерного Анализа Online-морских Карт Панамского Канала

Ю.С. Тимошенкова, Е.А. Кужбанова, С.В. Поршнева

Аннотация—В статье обсуждаются результаты прогнозирования временных рядов, составленных из числа кораблей в Панамском канале на основе использования первичной информации о количестве судов, прошедших через выбранные морские проливы в течение одного часа в период с 1 марта по 31 марта 2021г. Информация, необходимая для составления обсуждаемых временных рядов была извлечена автоматически с помощью разработанного авторами программного инструмента из общедоступных онлайн морских карт, размещенных в сети Интернет. Приведены полученные временные ряды, составленные из числа морских судов.

Описана методика прогнозирования временного ряда, в которой интегрированы формальные методы прогнозирования и метода Data Assimilation. Проведен сравнительный анализ точности прогнозирования выбранных временных рядов, полученных с помощью формальных моделей временных рядов, (AR и др.) и методики интеграции. Продемонстрировано, что точность прогнозирования, основанная на интеграции формальных методов прогнозирования временного ряда и метода DA, оказывается выше аналогичной величины в случае прогнозирования на основе AR-модели временного ряда любого порядка.

Ключевые слова— морской трафик, Панамский канал, прогнозирование временных рядов, Data Assimilation.

I. ВВЕДЕНИЕ

В настоящее время основным способом доставки грузов от отправителей к их получателям являются морские перевозки, на которые приходится свыше 80% глобального грузооборота [4], большинство из которых осуществляется исключительно по известным судоходным маршрутам. Их исторический выбор обусловлен как целым рядом геофизических факторов

Статья получена 24 декабря 2024.

Тимошенкова Юлия Сергеевна, Альфа-Банк Центр разработки цифровых сервисов, Уральский Федеральный Университет, Институт радиоэлектроники и информационных технологий-РТФ, (e-mail: julia.timoshenkova@urfu.ru).

Кужбанова Елена Александровна, Федеральный Университет, Институт радиоэлектроники и информационных технологий-РТФ, (e-mail: kuzhbanova.elena@urfu.ru)

Поршнева Сергей Владимирович, Уральский Федеральный Университет, Институт радиоэлектроники и информационных технологий-РТФ, (e-mail: s.v.porshnev@urfu.ru).

(глубиной Мирового океана, направлением океанических течений, розой ветров, конфигурацией береговых линий, наличием морских проливов и каналов на пути следования морского судна), так и геополитических факторов.

Результаты многочисленных публикаций, посвященных анализу морского трафика (см., например, [23-25] и др.) позволяет сделать вывод о том, что большое число маршрутов морских судов, осуществляющих, в первую очередь, коммерческие перевозки грузов, сегодня проходят через морские проливы (Золотой рог, Ормузский пролив, Берингов пролив, Босфор, Дарданеллы, Керченский пролив и др.) и каналы (Суэцкий, Панамский), поэтому обсуждаемые районы Мирового океана являются областями интенсивного движения морского транспорта.

В этой связи анализ особенностей движения морских судов в выбранных областях Мирового океана, а также прогнозирование плотности морского трафика с целью оптимизации движения в районах морских проливов и каналов, является актуальной задачей.

В статье обсуждаются результаты прогнозирования значений временных рядов (ВР), составленных из числа морских судов, прошедших в прямом и обратном направлениях через Панамский канал в течение одной недели.

II. ТЕХНОЛОГИЯ ИЗВЛЕЧЕНИЯ ИНФОРМАЦИИ ОБ ИНТЕНСИВНОСТИ МОРСКОГО ТРАФИКА ИЗ ONLINE МОРСКИХ КАРТ

Первичная информация о координатах морских судов извлекалась из онлайн морских карт района Панамского канала. Напомним, что на этих картах отображаются названия морских судов и маркеры, соответствующие типу и размеру судна, размещаемые в соответствие с текущими географическими координатам судна, сообщаемые наземным службам контроля движения автоматической идентификационной системой (АИС), например, [1-3].

Так как, собственно, онлайн карты являются бесплатными, а информация о координатах судов, размещаемая в соответствующих хранилищах данных, доступна только для пользователей, оформивших

платную подписку, авторы разработали программный инструмент, обеспечивающий автоматическое извлечение данной информации из мгновенных онлайн карт, находящихся в свободном доступе [5].

Разработанный инструмент обеспечивает автоматическое сохранение последовательных мгновенных кадров online карты сайта (рис. 1) [2] с 20-минутным интервалом. Для примера рассмотрим участок Панамского канала с координатами долготы и широты соответственно 09.4545 / -079.9299 – верхний левый угол, 09.3873 / -079.8520 – нижний правый угол, площадью 62 км². Затем на каждом мгновенном кадре находят названия морских судов, вокруг которых строятся описанные прямоугольники минимального размера (на рис. 1б данные прямоугольники залиты белым цветом).

Далее значения координат вершин обсуждаемых прямоугольников, измеряемые в пикселях, через известные значения географических координат вершин мгновенной онлайн карты пересчитываются в фактически значения их долготы и широты. При этом оказывается, что наиболее близким к значениям географических координат судна, переданными АИС, оказывается координата верхнего левого угла прямоугольника, описанного вокруг названия судна.

В результате из отдельного мгновенного кадра онлайн карты извлекается информация, имеющая следующую структуру:

$$One = \langle t_i, The_Ship_Name_{i,j}, latitude_{i,j}, longitude_{i,j} \rangle,$$

где $i = \overline{1, I}$, I – количество последовательных мгновенных снимков онлайн карты; $k = \overline{1, The_Ship_Name_i}$ – порядковый номер морского судна на i -ом мгновенном снимке, $Number_of_The_Ship_i$ – количество морских судов, обнаруженных на i -ом мгновенном снимке; $latitude_{i,j}$ и $longitude_{i,j}$ – географические широта и долгота j -го морского судна на i -ом мгновенном кадре. Соответственно, информация, извлеченная из I последовательных кадров, имеет следующую структуру:

$$All = \bigcup_{i=\overline{1, I}} (One_i) = \bigcup_{i=\overline{1, I}} \langle t_i, The_Ship_Name_{i,j}, latitude_{i,j}, longitude_{i,j} \rangle.$$

(1)

Из (1) видно, что для хранения данной информации целесообразно использовать таблицу, состоящую из 4-х столбцов, число строк которой равно $\sum_{i=1}^I Number_of_The_Ship_i$.

Далее, на основе анализа таблицы All можно анализировать морской трафик в различных измерениях, например, подсчитать число кораблей, прошедших через исследуемую область в каждый из дней недели, месяц и т.д.; определить направление движения каждого морского судна и далее подсчитать число кораблей прошедших через пролив или канал в каждом из направлений в течение выбранного временного интервала (час, сутки, месяц).



а – Фрагмент мгновенного кадра онлайн карты района Панамского канала



б – Результат анализа электронной карты (распознанные названия морских судов и описанные вокруг них прямоугольники для наглядности увеличены в размерах и смещены относительно их истинного положения)

Рис. 1. К иллюстрации результата работы алгоритма анализа мгновенной онлайн-карты

В результате можно получить временные ряды x_k , составленные из числа морских судов, прошедших в каждом из направлений движения в течение k -го последовательного временного интервала выбранной длительности (см. рис. 2)

Из рисунка 2 видно, что данные ВР представляют собой некоторые реализации случайных процессов, которые, в предположении о их стационарности, можно пытаться прогнозировать и, тем самым, предсказывать, например, загруженность Панамского канала.




Рис. 2. ВР, составленные из числа морских судов, прошедших через Панамский канал, (красным – в Карибское море, синим – из Карибского моря) в период с 1 по 31 марта 2021 года.

III. МЕТОДИКА ПРОГНОЗИРОВАНИЯ

Существует множество методов решения задачи прогнозирования временных рядов. Наиболее популярными являются формальные методы прогнозирования. Данные методы используют данные известных отсчетах временного ряда и не учитывают математическое описание системы, породившей ВР. Примерами таких методов являются авторегрессия (AR), скользящее среднее (MA), авторегрессия проинтегрированного скользящего среднего (ARIMA).

В формальных методах предполагается, что прогнозируемые значения ВР связаны с известными значениями ВР согласно некоторой функции [9]:

$$x_{k+1} = F(x_k, x_{k-1}, \dots, x_{k-p}, \alpha_1, \dots, \alpha_p), \quad (2)$$

где x_{k+1} — прогнозируемый отсчет ВР, $x_k, x_{k-1}, \dots, x_{k-p}$, $\alpha_1, \dots, \alpha_p$ — известные отсчеты ВР, $\alpha_1, \dots, \alpha_p$ — параметры формальной модели, идентифицируемые на основе исходных наблюдений ВР, F — некоторая известная функция, описывающая связь между известными значениями ВР $x_k, x_{k-1}, \dots, x_{k-p}$.

На практике для сложных ВР формальные методы прогнозирования не дают требуемой точности. Например, процессы, в основе которых лежат сложные механизмы. В таких задачах требуется учитывать не только известные отсчеты ВР, но и математическую модель.

Для прогнозирования таких процессов исследователями был разработан метод Data Assimilation (DA) [13, 18]. Метод основан на использовании не только известных наблюдаемых данных x_{k+1}, x_{k+2}, \dots , но и использовании спрогнозированных значений $\bar{x}_{k+1}, \bar{x}_{k+2}, \dots$. Вновь полученные наблюдаемые данные позволяют выполнить коррекцию прогноза на основе сравнения прогноза и наблюдений. Данный метод показал хорошие практические результаты, что подтверждается который показывает достаточную точность [12, 15, 21].

Метод DA описывается системой дискретных уравнений [8, 14]:

$$\begin{cases} \bar{x}_{k+1} = M(\bar{x}_k, t_k) + \bar{w}_k \\ \bar{y}_k = H(\bar{x}_k, t_k) + \bar{v}_k \end{cases}, \quad (3)$$

где \bar{x}_k — вектор состояния динамической системы, M — оператор или функция перехода, определяющая эволюцию системы во времени в виде математической модели, \bar{x}_k — вектор состояния системы в момент t_k , \bar{x}_{k+1} — вектор состояния системы в момент времени t_{k+1} , \bar{y}_k — вектор наблюдений, H — оператор наблюдения, связывающий многомерное состояние системы с одномерным вектором наблюдений, \bar{w}_k и \bar{v}_k — векторы ошибок модели и наблюдения с ковариационными матрицами Q_k и R_k соответственно.

DA основывается на применении оптимальной фильтрации или вариационного метода. На практике достаточную точность прогноза показывает использование фильтра Калмана. Сегодня известно множество различных модификаций фильтра Калмана, используемых и в методе DA, в том числе: EKF (Extended Kalman filter), EnKF (Ensemble Kalman Filter), UKF (Unscented Kalman Filter) и др. [13] В работе мы используем ансамблевый фильтр Калмана (EnKF) потому что он обеспечивает приемлемую точность прогнозирования и оптимальную сложность [11, 12, 20].

В (3) первое уравнение называется уравнением прогноза, второе уравнение — уравнением коррекции. Уравнение прогноза использует математическую модель ДС, порождающей ВР, при этом математическая модель должна быть представлена в виде СДУ. Это условие на практике выполняется не всегда.

Для возможности применения методики DA для прогнозирования систем, описание которых в виде СДУ не известно, была разработана методика интеграции формальных методов прогнозирования и метода Data Assimilation, которая впервые описана в [11]. Методика показала хорошие результаты применения для систем разной природы [7, 19].

В методике предполагается, что в уравнении (3) для прогноза состояния системы в будущий момент времени в первом уравнении вместо математической модели M , можно использовать формальную модель $F(x_k, x_{k-1}, \dots, x_{k-p}, \alpha_1, \dots, \alpha_p)$ из (2). Таким образом система уравнений (3), можно представить, как:

$$\begin{cases} x_{k+1} = F(x_k, x_{k-1}, \dots, x_{k-p}, \alpha_1, \dots, \alpha_p) + w_k \\ y_k = H(x_k, t_k) + v_k \end{cases}. \quad (4)$$

Из (4) видно, что метод интеграции состоит из следующей последовательности шагов:

1. Выбрать формальный метод прогнозирования (функцию F).
2. Задать параметры метода DA, основанного на использовании EnKF и формального метода прогнозирования.
3. Выполнить шаг анализа DA в соответствии с первым уравнением в (4).
4. Скорректировать в соответствии со вторым уравнением в (4) спрогнозированное значение x_{k+1} и вектор ошибки \bar{w}_k .

Далее рассмотрим применение методике к набору исследуемых данных.

IV. ОПИСАНИЕ ЭКСПЕРИМЕНТА

В качестве прогнозируемого ВР взяты данные, отражающие среднее количество кораблей в день, на основе данных, описанных выше. Прогноз выполнялся для 7 точек, что соответствует одной неделе.

В качестве формальных методов (функция F), был выбран метод на основе авторегрессионной модели (АР);

Для модели АР прогноз отсчета ВР $k + 1$ с использованием авторегрессии описывается уравнением [9, 22]:

$$x_{k+1} = F(x_k, \dots, x_{k-p}, \alpha_0, \dots, \alpha_p) + w_k = \alpha_0 + \alpha_1 x_k + \alpha_2 x_{k-1} + \dots + \alpha_p x_{k-p} + \varepsilon_i, \quad (5)$$

где p — порядок регрессии, $\alpha_0, \alpha_1, \dots, \alpha_p$ — коэффициенты регрессии, ε_i — случайное число, принадлежащее генеральной совокупности с распределением $N(0, \sigma)$.

Таким образом, прогноз и коррекция ВР будет выполнен согласно:

$$\begin{cases} x_{k+1} = \alpha_0 + \alpha_1 x_k + \alpha_2 x_{k-1} + \dots + \alpha_p x_{k-p} + w_k \\ y_k = H(x_k, t_k) + v_k \end{cases} \quad (6)$$

Алгоритм исследования состоит из следующих этапов:

1. Сбор данных и подготовка к выполнению ретроспективного прогноза.
2. Разделение данных на базу прогноза и точки, которые будут спрогнозированы для возможности оценки точности прогноза.
3. Ввод параметров прогнозирования:
 - база прогноза $B = 12$
 - окно прогноза $M = 7$
 - порядок АР $p = 15$;
 - в качестве фильтра Калмана в (6) использовался ЕпKF, в котором число ансамблей $N_a = 75$, корректировалось каждое второе прогнозируемое значение;
 - число запусков эксперимента $j = 100$.
4. Вычисление прогнозируемых значений TS с использованием описанных методов: в соответствии с формулой (5) — Метод № 1, с использованием формулы (6) — Метод № 2.
5. Повторение пункта 4 j -раз для получения статистически значимого результата.
6. Вычисление зависимости дисперсии разностей между точными и спрогнозированными для каждой точки прогноза.

V. РЕЗУЛЬТАТЫ

Рассмотрим полученные средние по 100 прогнозам результаты прогнозирования обоих ВР, которые представлены на Рисунке 3 и 4.

Из полученных рисунков 3 и 4 видно, что разработанная методика дает лучше результат, чем если бы выполнялось прогнозирование только с использованием формального метода АР.

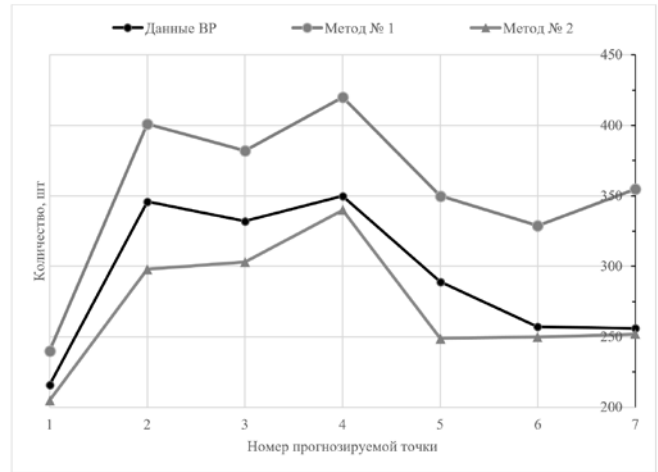


Рис. 3 Пример результата среднего прогноза первого ВР по 100 экспериментам с помощью всех методов

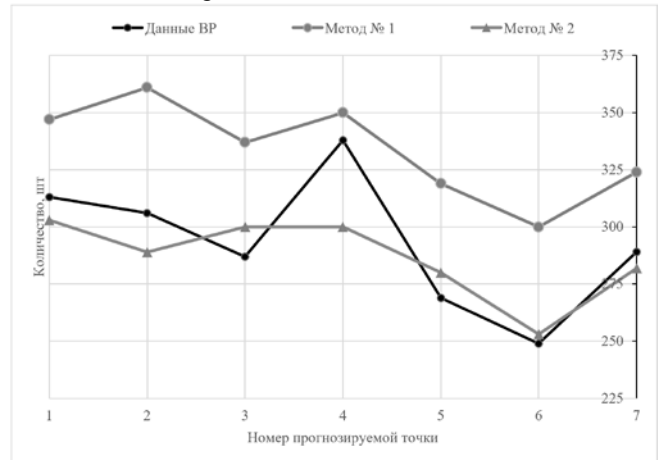


Рис. 4 Пример результата среднего прогноза второго ВР по 100 экспериментам с помощью всех методов

На рисунках 3 и 4 так же можно заметить, что с дальностью прогноза точность прогноза может изменяться. Согласно пункту 6 для оценки дальности прогнозирования необходимо вычислить дисперсии разностей между точными и спрогнозированными для каждой точки прогноза.

На рисунках 5 и 6 представлены полученные зависимости дисперсии для средних прогнозов ВР по 100 экспериментам с помощью формального метода на основе АР и методики интеграции, в которой формальный метод представлен с помощью АР от номера точки прогноза для двух наборов данных.

Из полученных результатов видно, что АР-модель высокого порядка пытается отследить наличие периодической и сезонной составляющих анализируемого ВР, однако, точность ее прогнозирования оказывается недостаточно высокой.

Для повышения точности прогнозирования ВР с помощью (4) рекомендовано использовать АР-модели высокого порядка. Однако увеличение порядка АР-модели приводит к увеличению размерности системы уравнений Юла-Уокера и, соответственно, к пропорциональному увеличению числа необходимых известных пред-прогнозных точек, что не всегда возможно на практике.




Рис. 5 Модуль разности данных первого ВР и прогноза по 100 экспериментам, полученного с помощью методов

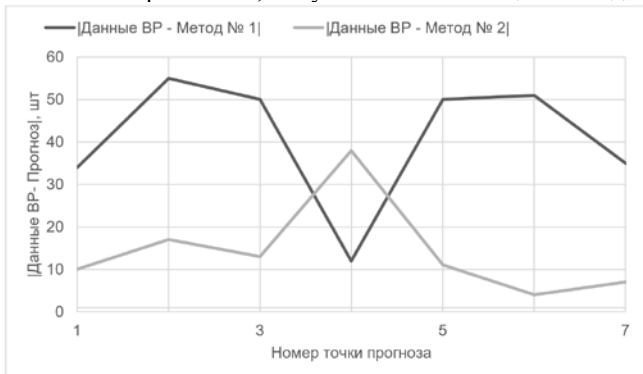


Рис. 6 Модуль разности данных второго ВР и прогноза по 100 экспериментам, полученного с помощью методов

Полученные результаты показывают, что использование методики «Интеграции формальных методов прогнозирования и метода Data Assimilation» [6, 7, 15], дает меньшую погрешность прогнозирования и наилучшую дальность прогноза. Данные результаты говорят о том, что в методике можно использовать AR более меньшего порядка, что улучшит вычислительную скорость выполнения прогноза.

VI. ЗАКЛЮЧЕНИЕ

В работе показана методика получения временных рядов, составленных из числа морских судов, прошедших в каждом из направлений движения. Представлен сравнительный анализ прогнозирования двух временных рядов, с помощью AR-модели и методики [6, 7, 15], в которой используется AR-модель и EnKF-фильтр. На примере двух одномерных ВР продемонстрирована возможность достоверного прогнозирования его значений с помощью метода DA, в котором вместо математической модели, описывающей закон изменения во времени состояния ДС, породившей изучаемые ВР, используется AR-модель. Дальность прогнозирования двух одномерных ВР оказалась больше в случае применения разработанной методики [6, 7, 15], с использованием AR-модели вместо математической модели ВР.

БИБЛИОГРАФИЯ

[1] Ship & Container Tracking – Vessel Finder [Online]. Available: <https://www.vesselfinder.com>

- [2] AIS Marine Traffic: Global Ship Tracking Intelligence [Online]. Available: <https://www.marinetraffic.com>
- [3] Отслеживание судов по всему миру в реальном времени. Мониторинг. Поиск. Данные АИС [Online]. Available: <https://www.shippingexplorer.net/ru>
- [4] Грамматчиков А. Пандемия, китайский фактор и суэцкий кризис // Эксперт 2021 №15 (1202). С 5-10
- [5] Кужбанова Е. А., Поршнев С. В. Опыт анализа информации о движении морских судов, извлеченной из электронных online морских карт // International Journal of Open Information Technologies. 2021. №4
- [6] Тимошенкова Ю. С., Поршнев С. В., Сафиуллин Н. Т. Методика Интеграции Формальных Методов Прогнозирования Временных Рядов в Data Assimilation // International Journal of Open Information Technologies. 2022. № 4 (10). С. 15–23.
- [7] Тимошенкова Ю. С., Поршнев С. В., Сафиуллин Н. Т. Алгоритмическое и программное обеспечение методики интеграции формальных методов прогнозирования временных рядов и метода ассимиляции данных / Ю. С. Тимошенкова, С. В. Поршнев, Н. Т. Сафиуллин, Научно-техническое издательство «Горячая линия-Телеком».
- [8] Vocquet M. Introduction to the principles and methods of data assimilation in geosciences // Notes de cours, École des Ponts ParisTech. 2014.
- [9] Box G. E. [и др.]. Time series analysis: forecasting and control / G. E. Box, G. M. Jenkins, G. C. Reinsel, G. M. Ljung, John Wiley & Sons, 2015.
- [10] Demuth H. B. [и др.]. Neural network design / H. B. Demuth, M. H. Beale, O. De Jess, M. T. Hagan, Martin Hagan, 2014.
- [11] Evensen G. Data assimilation: the ensemble Kalman filter / G. Evensen, Springer Science & Business Media, 2009.
- [12] Houtekamer P. L., Mitchell H. L. Data assimilation using an ensemble Kalman filter technique // Monthly Weather Review. 1998. № 3 (126). С. 796–811.
- [13] Kalnay E. Atmospheric modeling, data assimilation and predictability / E. Kalnay, Cambridge university press, 2003.
- [14] Kamruzzaman J., Begg R., Sarker R. Artificial neural networks in finance and manufacturing / J. Kamruzzaman, R. Begg, R. Sarker, IGI Global, 2006.
- [15] Moradkhani H. [и др.]. Uncertainty assessment of hydrologic model states and parameters: Sequential data assimilation using the particle filter // Water resources research. 2005. № 5 (41).
- [16] Morariu N., Iancu E., Vlad S. A neural network model for time series forecasting // Romanian journal of economic forecasting. 2009. № 4 (12). С. 213–223.
- [17] Muzaffar S., Afshari A. Short-term load forecasts using LSTM networks // Energy Procedia. 2019. (158). С. 2922–2927.
- [18] Nerger L. [и др.]. SANGOMA: Stochastic Assimilation for the Next Generation Ocean Model Applications EU FP7 SPACE-2011-1 project 283580.
- [19] Timoshenkova Y., Porshnev S., Safiullin N. Method of Integration of Formal Forecasting Methods into Data Assimilation on the Example of Autoregressive Time Series Yekaterinburg, Russian Federation: IEEE, 2022. С. 224–227.
- [20] Timoshenkova Y. S., Safiullin N. T., Porshnev S. V. Application of Data Assimilation Algorithms Based on Kalman Ensemble Filters for the Lorenz Attractor CEUR-WS, 2018. С. 82–87.
- [21] Yulia T., Sergey P., Nikolai S. On the possibility of correction of the forecasting of the Lorenz attractor dynamic characteristics using experimental data and data assimilation IOP Publishing, 2018. С. 012004.
- [22] Zhang G. P. Time series forecasting using a hybrid ARIMA and neural network model // Neurocomputing. 2003. (50). С. 159–175.
- [23] Yang Zhou, Winnie Daamen, Tiedo Vellinga, Serge Hoogendoorn, Review of maritime traffic models from vessel behavior modeling perspective, Transportation Research Part C: Emerging Technologies, Volume 105, 2019, Pages 323-345, ISSN 0968-090X, <https://doi.org/10.1016/j.trc.2019.06.004>
- [24] Y. Nie, K. Liu, X. Xin & Q. Yu A Novel Through Capacity Model for One-way Channel Based on Characteristics of the Vessel Traffic Flow // TransNav the International Journal on Marine Navigation and Safety of Sea Transportation - 2017 - 11(3) C:495-502 DOI:10.12716/1001.11.03.16
- [25] Muirhead, J.R., Minton, M.S., Miller, W.A. and Ruiz, G.M. (2015), Projected effects of the Panama Canal expansion on shipping traffic and biological invasions. Diversity Distrib., 21: 75-87. <https://doi.org/10.1111/ddi.12260>

Experience of Forecasting Maritime Traffic Intensity Based on Computer Analysis of Online Marine Charts of the Panama Canal

Y.S. Timoshenkova, E.A. Kuzhbanova, S.V. Porshnev

Annotation— The article discusses the results of forecasting time series compiled from the number of ships in the Panama Canal based on the use of primary information on the number of ships that passed through the selected sea straits during one hour in the period from March 1 to March 31, 2021. The information necessary for compiling the discussed time series was extracted automatically using a software tool developed by the authors from publicly available online nautical charts posted on the Internet. The obtained time series compiled from the number of sea vessels are presented. A time series forecasting technique is described that integrates formal forecasting methods and the Data Assimilation method. A comparative analysis of the forecasting accuracy of selected time series obtained using formal time series models (AR, etc.) and the integration technique is performed. It is demonstrated that the forecasting accuracy based on the integration of formal time series forecasting methods and the DA method is higher than the similar value in the case of forecasting based on an AR model of a time series of any order.

Key Words—sea traffic, Panama Canal, time series forecasting, Data Assimilation.

REFERENCES

- [1] Ship & Container Tracking – Vessel Finder [Online]. Available: <https://www.vesselfinder.com>
- [2] AIS Marine Traffic: Global Ship Tracking Intelligence [Online]. Available: <https://www.marinetraffic.com>
- [3] Otslezhivanie sudov po vsemu miru v real'nom vremeni. Monitoring. Poisk. Dannye AIS [Online]. Available: <https://www.shippingexplorer.net/ru>
- [4] Grammatchikov A. Pandemija, kitajskij faktor i sujekij krizis // Jekspert 2021 #15 (1202). S 5-10
- [5] Kuzhbanova E. A., Porshnev S. V. Opyt analiza informacii o dvizhenii morskikh sudov, izvlechennoj iz jelektronnyh online morskikh kart // International Journal of Open Information Technologies. 2021. #4
- [6] Timoshenkova Ju. S., Porshnev S. V., Safiullin N. T. Metodika Integracii Formal'nyh Metodov Prognozirovanija Vremennyh Rjadov v Data Assimilation // International Journal of Open Information Technologies. 2022. # 4 (10). C. 15–23.
- [7] Timoshenkova Ju. S., Porshnev S. V., Safiullin N. T. Algoritmicheskoe i programnoe obespechenie metodiki integracii formal'nyh metodov prognozirovanija vremennyh rjadov i metoda assiljacii dannyh / Ju. S. Timoshenkova, S. V. Porshnev, N. T. Safiullin, Nauchno-tehnicheskoe izdatel'stvo «Gorjachaja linija-Telekom».
- [8] Bocquet M. Introduction to the principles and methods of data assimilation in geosciences // Notes de cours, École des Ponts ParisTech. 2014.
- [9] Box G. E. [et al.]. Time series analysis: forecasting and control / G. E. Box, G. M. Jenkins, G. C. Reinsel, G. M. Ljung, John Wiley & Sons, 2015.
- [10] Demuth H. B. [и др.]. Neural network design / H. B. Demuth, M. H. Beale, O. De Jess, M. T. Hagan, Martin Hagan, 2014.
- [11] Evensen G. Data assimilation: the ensemble Kalman filter / G. Evensen, Springer Science & Business Media, 2009.
- [12] Houdekamer P. L., Mitchell H. L. Data assimilation using an ensemble Kalman filter technique // Monthly Weather Review. 1998. № 3 (126). C. 796–811.
- [13] Kalnay E. Atmospheric modeling, data assimilation and predictability / E. Kalnay, Cambridge university press, 2003.
- [14] Kamruzzaman J., Begg R., Sarker R. Artificial neural networks in finance and manufacturing / J. Kamruzzaman, R. Begg, R. Sarker, IGI Global, 2006.
- [15] Moradkhani H. [и др.]. Uncertainty assessment of hydrologic model states and parameters: Sequential data assimilation using the particle filter // Water resources research. 2005. № 5 (41).
- [16] Morariu N., Iancu E., Vlad S. A neural network model for time series forecasting // Romanian journal of economic forecasting. 2009. № 4 (12). C. 213–223.
- [17] Muzaffar S., Afshari A. Short-term load forecasts using LSTM networks // Energy Procedia. 2019. (158). C. 2922–2927.
- [18] Nerger L. [и др.]. SANGOMA: Stochastic Assimilation for the Next Generation Ocean Model Applications EU FP7 SPACE-2011-1 project 283580.
- [19] Timoshenkova Y., Porshnev S., Safiullin N. Method of Integration of Formal Forecasting Methods into Data Assimilation on the Example of Autoregressive Time Series Yekaterinburg, Russian Federation: IEEE, 2022.C. 224–227.
- [20] Timoshenkova Y. S., Safiullin N. T., Porshnev S. V. Application of Data Assimilation Algorithms Based on Kalman Ensemble Filters for the Lorenz Attractor CEUR-WS, 2018.C. 82–87.
- [21] Yulia T., Sergey P., Nikolai S. On the possibility of correction of the forecasting of the Lorenz attractor dynamic characteristics using experimental data and data assimilation IOP Publishing, 2018.C. 012004.
- [22] Zhang G. P. Time series forecasting using a hybrid ARIMA and neural network model // Neurocomputing. 2003. (50). C. 159–175.
- [23] Yang Zhou, Winnie Daamen, Tiedo Vellinga, Serge Hoogendoorn, Review of maritime traffic models from vessel behavior modeling perspective, Transportation Research Part C: Emerging Technologies, Volume 105, 2019, Pages 323-345, ISSN 0968-090X, <https://doi.org/10.1016/j.trc.2019.06.004>
- [24] Y. Nie, K. Liu, X. Xin & Q. Yu A Novel Through Capacity Model for One-way Channel Based on Characteristics of the Vessel Traffic Flow // TransNav the International Journal on Marine Navigation and Safety of Sea Transportation - 2017 - 11(3) C:495-502 DOI:10.12716/1001.11.03.16
- [25] Muirhead, J.R., Minton, M.S., Miller, W.A. and Ruiz, G.M. (2015), Projected effects of the Panama Canal expansion on shipping traffic and biological invasions. Diversity Distrib., 21: 75-87. <https://doi.org/10.1111/ddi.12260>

Yulia Timoshenkova, Alfa-Bank and Ural Federal University, Yekaterinburg, Russia, (e-mail: julia.timoshenkova@urfu.ru) <https://orcid.org/0000-0002-4137-0484>.
Elena Kuzhbanova, Ural Federal University, Yekaterinburg, Russia, (e-mail: kuzhbanova.elena@urfu.ru)
Sergey Porshnev, Ural Federal University, Yekaterinburg, Russia, (e-mail: s.v.porshnev@urfu.ru) <https://orcid.org/0000-0001-6884-9033>