

СРАВНИТЕЛЬНЫЙ АНАЛИЗ АЛГОРИТМОВ ПРОГНОЗА КАЧКИ КОРАБЛЯ

Д.В. Антонов

АО «Концерн «ЦНИИ «Электроприбор»

danila.v.antonov@mail.ru**Введение**

Для увеличения безопасности работ на кораблях во время качки при проектировании различных систем нередко возникает необходимость решения задачи прогноза углов качки. Такая потребность появляется, например, при перегрузке крупногабаритных хрупких грузов в открытом море, работах на нефтегазодобывающих платформах, посадке летательного аппарата на палубу корабля, или платформу [1-3]. В связи с этим можно отметить значительный интерес разработчиков к исследованию задачи прогнозирования качки [4-8]. Предлагаемый доклад посвящен сравнительному анализу алгоритмов, применяемых в настоящее время для решения этой задачи. При этом рассматриваются три алгоритма: фильтр Калмана (ФК), алгоритм авторегрессии и искусственная нейронная сети с долговременной краткосрочной памятью (LSTM). Результаты работы алгоритмов апробированы на реальных данных.

Алгоритмы прогнозирования

При построении алгоритма, основанного на применении ФК [5], качка $u(t)$ рассматривается, как реализация стационарного случайного процесса. Будем полагать, что качка может быть описана с помощью узкополосного марковского процесса второго порядка с корреляционной функцией

$$k(\tau) = \sigma^2 e^{-\alpha|\tau|} \left(\cos \beta\tau + \frac{\alpha}{\beta} \sin \beta\tau \right), \quad (1)$$

где σ, α и β – параметры качки. Такой процесс может быть представлен с помощью формирующего фильтра для двумерного вектора $x(t)$, одна из компонент которого, например первая, и представляет собой качку $u(t)$, т.е. $u(t) = x_1(t)$ [9]. В этом случае при построении прогноза может быть использовано следующее соотношение:

$$\hat{x}(t+\tau) = \phi(\tau) \hat{x}(t), \quad (2)$$

где t - текущий момент времени, τ - время прогноза, $\hat{x}(t)$ - оптимальная оценка, полученная в ФК для двумерного вектора на момент t ; $\phi(\tau)$ - фундаментальная матрица формирующего фильтра, определяемая как [9]:

$$\phi(\tau) = \sigma^2 e^{-\alpha|\tau|} \begin{bmatrix} \cos \beta\tau + \frac{\alpha}{\beta} \sin \beta\tau & \frac{1}{\beta} \sin \beta\tau \\ -\frac{1}{\beta} \sin \beta\tau & \cos \beta\tau - \frac{\alpha}{\beta} \sin \beta\tau \end{bmatrix}, \quad (3)$$

Параметры качки получаются вследствие обработки сигнала, записанного на предыдущем отрезке времени. Оценка самой качки получается как $\hat{u}^{\text{ФК}}(t) = \hat{x}_1(t)$

При построении алгоритма авторегрессии предполагается, что качка может быть описана в виде [4]:

$$u(t) = \sum_{i=0}^{p-1} a_i u(t-i\Delta t) + \varepsilon(t), \quad (4)$$

где Δt – интервал дискретизации, a_i – коэффициенты авторегрессии, p – порядок модели, $\varepsilon(t)$ – белый шум.

Оценки коэффициентов a_i , $i = \overline{1..p}$ рассчитываются путем аппроксимации реализации качки $u(t)$ на интервале $n\Delta t$, где n – количество шагов, с использованием метода наименьших квадратов на линейной модели. Порядок модели определялся экспериментально, путем сравнения полученных результатов [7]. После того, как эти коэффициенты найдены, отыскивается прогноз на интервал Δt с использованием следующего соотношения

$$\hat{u}^{AP}(t + \Delta t) = \sum_{i=0}^{p-1} \hat{a}_i u(t - i\Delta t), \quad (5)$$

где \hat{a}_i , $i = \overline{0..(p-1)}$ – рассчитанные оценки коэффициентов; $u(t - i\Delta t)$, $i = \overline{0..(p-1)}$ – значения углов качки в предшествующие моменты времени на интервале времени $p\Delta t$. Для получения прогноза на интервал $2\Delta t$ согласно этой формуле необходимо вместо t подставить $t + \Delta t$, тогда можно записать

$$\hat{u}^{AP}(t + 2\Delta t) = \sum_{i=0}^{p-1} \hat{a}_i u(t + \Delta t - i\Delta t). \quad (6)$$

Из соотношения (6) следует, что при $i=0$ необходимо значение качки в момент $u(t + \Delta t)$. Поскольку при решении задачи прогноза, этого значения нет, вместо $u(t + \Delta t)$ подставляется прогноз (5). Аналогично поступают и при вычислении прогноза на интервал $2\Delta t$ и в более общем случае на интервал $\tau = l\Delta t$. Таким образом, для определения значений прогноза угла качки на время τ , используются реализация значений угла качки $u(t - (p-1)\Delta t), u(t - (p-2)\Delta t), \dots, u(t)$ и вычисленные согласно описанной процедуре спрогнозированные значения углов качки в моменты времени, превышающие значение t .

При использовании нейронной сети применялась модель LSTM, отличающаяся способностью к обучению долгосрочным зависимостям за счет ключевой особенности этой сети, содержащей так называемые ячейки сети и состояние ячейки – канал связи, в котором информация может храниться неизменной на протяжении преобразований, осуществляемых в сети [10]. Модель этой нейронной сети включает один входной слой, один выходной и 200 скрытых слоев. При ее обучении использовался метод градиентного спуска. После обучения формируются параметры функций активации.

Для вычисления прогноза, фиксировался интервал времени t_{tr} , на котором проводилось обучение сети, и на вход сети подавалась реализация сигнала угла качки $u(t_{tr})$, записанная на этом интервале, тем самым в сети частично обновлялись состояние ячеек и рассчитывался прогноз $\hat{u}^{HC}(t + \Delta t)$ на первый интервал прогнозирования Δt . Для прогноза угла качки на интервал $2\Delta t$, к сигналу $u(t_{tr})$, поданному на вход сети на предыдущем такте, добавлялось полученное значение прогноза. В более общем случае, для прогноза на интервал $\tau = l\Delta t$ в качестве входного сигнала подавалась реализация $u(t_{tr})$ со значениями спрогнозированных углов, предшествующих τ . При этом на каждом интервале в сети частично обновлялись состояния ячеек и таким образом формировался прогноз $\hat{u}^{HC}(t + \tau)$.

Результаты моделирования

Приведем результаты моделирования, направленные на сопоставление рассмотренных выше алгоритмов прогнозирования. Как правило, прогноз качки рассматривается на промежутках времени 5 - 10 сек. Интервал дискретизации Δt был выбран одинаковым для всех методов и равнялся 0,5 с.

Секция №2

Для расчета параметров процесса σ, α и β , необходимых в алгоритме ФК, привлекалось 500 значений угла качки, как и для обучения НС. Число значений угла качки, используемое для определения коэффициентов авторегрессионной модели, было принято равным 200, а порядок модели $p=10$.

Рассматриваемый интервал прогноза составлял 10 сек, что соответствует 20 интервалам прогноза Δt .

При проведении исследований для сравнения алгоритмов рассчитывались среднеквадратические значения приведенной погрешности Δd , %, определяемой как:

$$\Delta d = \frac{|\hat{u}^j(t+\tau) - u(t+\tau)|}{u_{\max}} \cdot 100, \quad (7)$$

где $\hat{u}^j(t+\tau)$, $j=ФК, АР, НС$ – спрогнозированное значение угла качки в момент времени t на период τ , полученное с использованием различных методов, $u(t+\tau)$ – реальное значение угла качки в момент времени $t+\tau$, u_{\max} – максимальное значение угла качки на изучаемом промежутке времени. Среднеквадратические значения вычислялось для различных интервалов прогноза методом статистических испытаний для числа реализаций, равного 30.

Приведенные среднеквадратические значения погрешности прогноза угла качки для трех анализируемых алгоритмов представлены в таблице 1.

Таблица 1 – Среднеквадратическое значение приведенной погрешности прогноза угла качки в зависимости от времени прогноза

Модель прогноза\интервал прогноза	0,5 сек	5 сек	10 сек
Фильтр Калмана	7%	16%	30%
Авторегрессионная модель	2%	13%	26%
Сеть LSTM	7%	10%	17%

Анализ результатов моделирования алгоритмов показал, что использование методов фильтрации Калмана возможно при времени прогноза, большем, чем 0,5 секунд. Алгоритм, основанный на использовании искусственной нейронной сети, показывает наилучшие результаты по точности прогноза, однако наиболее затратный по времени и ресурсам. Выигрыш по точности обусловлен нелинейным и адаптивным характером алгоритма, который, по сути, реализуется на этапе ее обучения.

Заключение

Проведено сопоставление трех алгоритмов прогноза качки: фильтра Калмана, алгоритма авторегрессии и искусственной нейронной сети с долговременной краткосрочной памятью – LSTM. Проиллюстрированы преимущества алгоритма, основанного на использовании нейронной сети, в части достижения более высокой точности прогноза. Отмечено, что выигрыш по точности обусловлен нелинейным и адаптивным характером этого алгоритма, который, по сути, реализуется на этапе обучения нейронной сети. В дальнейшем предполагается проанализировать эффективность применения методов идентификации и адаптации при реализации ФК, описанных в работах [11, 12] с учетом работы [8]. Следует подчеркнуть, что, в сущности, при решении задачи прогноза качки можно говорить о двух вариантах построения адаптивных алгоритмов, которые обсуждаются на настоящем семинаре в докладе [13]. При использовании нейронной сети – речь идет непосредственно о построении адаптивного алгоритма, не предполагающего промежуточного этапа, направленного на идентификацию свойств качки. При синтезе адаптивного ФК потребуется одновременное решение синтеза ФК и идентификации, используемых при его построении параметров.

Работа проводилась при поддержке гранта РФФИ 18-08-01101-а.

Список литературы

1. Bo, Zhou. (2016). Continuous forecasting of ship's way based on lssvm. 10.2991/icmmse-16.2016.16.
2. Yin, Jianchuan&Perakis, Anastassios& Wang, Ning. (2018). A real-time ship roll motion prediction using wavelet transform and variable RBF network. Ocean Engineering. 160. 10-19. 10.1016/j.oceaneng.2018.04.058.
3. Lin, Zhuang& Yang, Qiang&Guo, Zhiquan& Li, Jun. (2011). An Improved Autoregressive Method with Kalman Filtering Theory for Vessel Motion Prediction. International Journal of Intelligent Engineering and Systems.
4. X. Zhao, R. Xu, C. Kwan, Ship-motion prediction: algorithms and simulation results, Acoustics, Speech, and Signal Processing, 1988. ICASSP-88., 1988 International Conference on June 2004.
5. Menahem M. Sidar, Brian F. Doolin On the Feasibility of Real-Time Prediction of Aircraft Carrier Motion at Sea, IEEE Transactions on automatic control, vol. AC-28, NO. 3, march 1983.
6. Жуйян Чжоу, К.А. Неусыпин, М.С. Селезнева, А.В. Пролетарский Алгоритм прогнозирования качки при посадке самолета на палубу авианосца, 2020, XXVII Санкт-Петербургская международная конференция по интегрированным навигационным системам.
7. Wang Wei-chao, Qin Shi-qiao, Wu Wei, ZhengJia-xing, Prediction of ship pitch motion by dual autoregressive model, 2015, 27th Chinese Control and Decision Conference (CCDC).
8. А.Е. Пелевин 2016, Прогноз угла наклона палубы корабля, Гироскопия и навигация. Том 24, № 4 (95), стр. 122-132, 2016.
9. Степанов О.А. Основы теории оценивания с приложениями к задачам обработки навигационной информации. Часть 2 Введение в теорию фильтрации. Санкт-Петербург, 2017, 428с
10. Alex Sherstinsky, Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network, Physica D: Nonlinear Phenomena. Elsevier, march 2020.
11. Motorin, A.V., Stepanov, O.A. Designing an error model for navigation sensors using the Bayesian approach. IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems. 2015-October, с. 54-58.
12. Stepanov O., Motorin A. Performance criteria for the identification of inertial sensor error models/ Sensors. 2019. Т. 19. № 9
13. Степанов О.А., Моторин А.В. Адаптивные задачи оценивания и методы их решения при обработке навигационной информации. Труды семинара «Навигация и управление движением». Самара, 2020 г.