船載型船体運動予測解析システムの研究－I．

大津 皓平*・井関 俊夫*

Study on the Onboard Predictive Ship Motion Analyser－I．

Kohei OHTSU and Toshio ISEKI

Abstract

An Onboard Predictive Ship Motion (OPSM) Analyser is proposed. The time series of ship's motions are assumed to be locally stationary processes. The fundamental model to represent them is an autoregressive model and the online Ozaki-Tong's fitting procedure is used for building the adaptive autoregressive model to such locally stationary process. Having fitted the autoregressive model, it is transformed to a state space model and on line smoothing, filtering and predicting of the observed time series data are carried out, using Kalman filter. In this paper, the ability as predictor of the system is checked, as the first step, by fitting to the actual rolling and pitching data of a middle and a small classes of ship.

1. まえがき

これまで、多くの船舶の運航支援システム、状態監視システムなどが提案され、実際に運用されてきた¹⁾。それらの多くはストリップ法などの理論をもとに、波浪中の応答関数を推定し、オフラインで操船者に情報を提供するシステムであった。しかし、波浪中の操船においては、システムはリアルタイムに対応する必要があり、しかも現在の船体の状態のみならず将来値をある程度予測しながら操船する必要がある。たとえば主機関が過負荷状態になることを避けるためには、ある程度早めに船体の運動等が予測できれば、ガバナ等の対応によって過負荷を避けることもできる。

本論文が取り扱う船載型船体運動予測解析システムの研究目的は、大洋航行中の船舶の船橋やエンジンコントロール室で船舶の現在の状態をリアルタイムに示すとともに、統計モデルによる予測機能を付加し、船舶の将来の状態を精度よく予測したり、作成した統計モデルを保存し船舶の保船管理、運航管理、長期傾向を船上で解析することを可能とする船載型統計予測解析器の概念設計およびその実船実験データの解析による可能性の検討である。

本報では、まず船載型予測解析システムの基本構想を示すとともに、特に本システムの重要なサブシステムである予測部で使われる統計モデルとそのモデルのオンライン推定法の基本アルゴリズムを示し、実船データの解析によって予測能力などの有効性を検証する。

2. 船載型船体運動予測解析システムの概念

2.1 取り扱う船舶データの種類

ここで取り扱う船舶データは、(1)横揺れ、縦揺れ等の船体運動関連の時系列データ、(2)船体の曲げモーメント、応力等の船体構造関連の時系列データ、(3)主機関の負荷、排気温度等の主機関連時系列デー

* 正会員 東京商船大学 (〒135 東京都江東区越中島 2-1-6)

タ、等の動的時系列データとし、線型時系列理論が適用できる定常もしくは局所定常過程とする。もちろんこのような時系列データの他、船内に起こる静的な統計的事象を表す変量もあり、これらデータに対する多項式回帰モデルや多変量解析モデルによる解析機能も本システムは持つ必要がある。後者については後の検討にゆずり、本報では動的データに限るとする。

2.2 必要要件と機能

船載型船体運動予測解析システムの必要要件としては、(1)リアルタイム性を有し、船舶の現在の状態の適切な表現機能を有すること、(2)選択する統計モデルが船舶の状態変化、船舶を取り巻く環境変化に適応した予測モデルであり、できる限り長時間の予測能力をもつこと、(3)船舶の過去の長期的データから、たとえばシーマージンのような船舶の大局的傾向 (trend) が推定できること、(4)表示、手続きがユーザーフレンドリーであり、ユーザーの知りたい情報が簡単な操作で得られること、(5)パソコンあるいはワークステーションで実現可能なこと、等が挙げられる。

これらを満たすため、本論文で目標とする船載型船体運動予測解析システムは次のような機能を有するものとする。

1. 船舶データの基本統計量の表示
2. 現下の海象、気象状態に最もよく適応した予測モデルによる船舶の状態の推定、予測値、異常値、欠測値の表示
3. 船舶データの統計モデルのデータベース化、長期傾向、季節調整モデル等の作成

第1の基本統計量の表示機能としては、船舶時系列データの表示、分布図、散布図 (Scattering Diagram)、モーメント、相関関数、レーリ分布等の極値統計量の算出が行われる。

第2の予測機能では、船舶の状態の変化、外乱環境の変化に適応して、オンラインで状態の予測モデルが作成され、この予測モデルを使って将来値を予測し、異常値の予測、運航状態の予測等がリアルタイムで行われる。予測モデルとしては、推定手続きが最も容易で状態の予測能力に優れた自己回帰モデル (Auto Regressive Model) を基本とする。ただし実際の予測時は、自己回帰モデルを基本にするカルマンフィルター (Kalman Filter) を使う²⁾。

第3の機能では、現在まで得られたデータを生のまま保存するのではなく、モデルとして将来の検索等の役立つ形式で保存したり、また基本統計量としてデータベース化し保船資料等に役立てるため船舶の長期的な傾向、シーマージンの傾向、季節調整等を行う。

第1の基本統計量の推定については、この種のようなシステムも備えているので本論文では触れない。本報では、まず第2の機能、すなわち予測機能について、その基本的構造、周囲環境変化への適応性を考慮したモデルの構築法などについて提案する。

2.3 基本構成

本システムは、図1のような構成となっている。すなわち、収録された時系列データは Onboard Predictive Ship Motion Analyser (PSMA) に入力される。PSMA は図2のような優先順位をもつ2つのタスクから成っている。優先順位が高いタスク1は Real Time Signal Processor で、船内データの定時間間隔の観測と予測モデルによるフィルター値、一定期間先までの予測値、異常値の検出、予測などのリアルタイム性の高いタスクをカルマンフィルターを使って実行し操船者に表示する。優先順位

Structure

図1 船載型船体運動予測解析システム

図2 リアルタイム処理タスクと
モニタリングタスク

の低いタスク 2 は、Optimal Model Builder と呼ばれ、タスク 1 で得られるデータの状態を監視するため、一定区間観測されたバッチデータをもとに現在の船体の状態にもっとも適応した統計予測モデルを求め、タスク 1 にわたすとともに、得られた最新のスペクトラムを表示したり得られた統計モデルおよび基本統計などから、1 航海終了後の船体の長期的状態の推定（トレンド推定、季節調整）などを計算するためにデータベースにモデルとして格納する。

3. 予測モデルの Batch Sequential 生成法

3.1 基本モデルと局所定常性の仮定

本節は、タスク 2 で使われる気象、海象に最も適応した予測モデルのオンライン構築法を提案する。

本システムの基本モデルである自己回帰モデルは、

$$y(n) = \sum_{m=1}^M A(m)y(n-m) + v(n) \quad (1)$$

で表される。ここで、 $y(n)$ は船体の状態を示す k 次元の時系列観測値、 $v(n)$ は同じ次元のガウス性白色雑音である。また $A(m)$ は $k \times k$ の自己回帰係数行列である。 M はこのモデルの次数である。そして M 次自己回帰モデルの良さは赤池情報量規準

$$AIC_M = N(k \log 2\pi + \log |\hat{V}_M| + k) + k(k+1) + 2k^2 M \quad (2)$$

によって測るものとする^{(2),(3)}。ここで、 N は観測データの個数、 $\hat{V}_M$ は残差の分散共分散行列の推定値である。

3.2 自己回帰モデルのバッチシーケンシャル推定

オンラインで現在の状態に適合するモデルを構築するための基本的な仮定は、船舶を取り巻く気象、海象は局所的には定常とみなせる程度にゆっくりと変化するという局所定常性 (Locally Stationarity) の仮定である。

局所定常的に変化する外乱に適応する自己回帰モデルをオンライン的に生成するため、次のような Ozaki-Tong の方法⁽⁴⁾を用いることにする。

図 3 において、まず局所的には定常とみなせる長さ L_1 個の時系列データが入力され、このデータに M 次自己回帰モデルを当てはめると自己回帰モデル AR_1 が得られ、そのときの AIC は AIC_1 であったとする。またその後、 L_2 個のデータが得られ、この区間のデータに対して同じく M 次のモデル AR_2 が得られ、その時の AIC は AIC_2 であったとする。これら 2 つの結合区間の $L_1 + L_2$ 個のデータ全体に対しても M 次 AR モデルを当てはめると、 AR_c モデルが得られその時の AIC は、 AIC_c であるとする。これを結合モデルと呼ぶことにする。一方、この区間の前半と後半におけるデータが異質であるとみなす場合（分割モデルと呼ぶ）の AIC は、

$$AIC_D = AIC_1 + AIC_2 \quad (3)$$

である。この 2 つの AIC を使って Ozaki-Tong の局所定常過程のあてはめアルゴリズムは、

1. $AIC_D < AIC_c$ ならば分割モデルを採用し、新しく AR_2 モデルを採用する。

2. $AIC_D \geq AIC_c$ ならば併合モデル AR_c を採用する。

とまとめられる。この手続きによって、適当な長さのバッチデータに対するオンライン推定が可能となる。

3.3 Householder 変換によるバッチデータへの自己回帰モデルのあてはめ

本システムでは、上で述べたような手続きによって自己回帰モデルのあてはめを実行する場合、モデルの推定を極めて高速に行うことのできる、Householder 変換法を用いた最小 2 乗法のあてはめ法を使う^{(2),(4)}。この方法を採用した理由は、(1) 係数 $A(m)$ の最小 2 乗解が、順次簡単な演算で計算可能である、(2) 残差 V_m

図 3 Ozaki-Tong⁽⁴⁾ によるモデル更新の手続き

の推定も簡単である、(3) Ozaki-Tong の手続きに必要な時系列の追加や分割によるモデルのあてはめが極めて容易である、等である。ここでは簡単のため $k=1$ とするが、多次元への拡張は容易である。いま、最初の L_1 個のデータに対して M 次 AR モデルを当てはめることにして、

$$\begin{aligned} y &= (y(M+1), y(M+2), \dots, y(L_1))', \\ a &= (A(1), A(2), \dots, A(M))' \end{aligned} \quad (4)$$

$$Z = \begin{pmatrix} y(M) & y(M-1) & \cdots & y(1) \\ y(M+1) & y(M) & \cdots & y(2) \\ \vdots & \vdots & \ddots & \vdots \\ y(L_1-1) & y(L_1-2) & \cdots & y(L_1-M) \end{pmatrix} \quad (5)$$

と置く。また v を、残差ベクトルとする。この時、 L_1 個のデータに対して当てはめられた結果は、

$$y = Za + v \quad (6)$$

と書ける。このとき最小 2 乗法の目的は、

$$L = \|y - Za\|^2 = \|v\|^2 \quad (7)$$

を最小にすることである。ここで、 $\|X\|$ はベクトル X のユークリッドノルムである。このノルムを保持しながら直交行列 U を用い Z を上三角行列にした後、 a を順次計算する方法のひとつが Householder 変換法である（詳細は他の文献²⁾にゆずる）。いま Z を拡張し、

$$X = [Z : y] \quad (8)$$

とし、この Householder 変換を X に $M+1$ 回施し、

$$\begin{pmatrix} S_{11} & \cdots & S_{1M+1} \\ & \ddots & \vdots \\ 0 & & S_{M+1M+1} \end{pmatrix} \quad (9)$$

と $(M+1) \times (M+1)$ 上三角行列に変換されたとする。この時、

$$\begin{aligned} \|Uy - UZa\|^2 &= \left\| \begin{pmatrix} S_{1M+1} \\ \vdots \\ S_{MM+1} \\ 0 \end{pmatrix} - \begin{pmatrix} S_{11} & \cdots & S_{1M} \\ & \ddots & \vdots \\ & & S_{MM} \\ 0 & & & \end{pmatrix} \begin{pmatrix} A(1) \\ \vdots \\ A(M) \end{pmatrix} \right\|^2 \\ &= \left\| \begin{pmatrix} S_{1M+1} \\ \vdots \\ S_{MM+1} \end{pmatrix} - \begin{pmatrix} S_{11} & \cdots & S_{1M} \\ & \ddots & \vdots \\ & & S_{MM} \end{pmatrix} \begin{pmatrix} A(1) \\ \vdots \\ A(M) \end{pmatrix} \right\|^2 + S_{M+1M+1}^2 \end{aligned} \quad (10)$$

となる。最後の式の右辺第 2 項は a と無関係な定数であるから、 $\|Uy - UZa\|^2$ を最小とするためには右辺第 1 項を 0、すなわち

$$\begin{pmatrix} S_{11} & \cdots & S_{1M} \\ & \ddots & \vdots \\ & & S_{MM} \end{pmatrix} \begin{pmatrix} A(1) \\ \vdots \\ A(M) \end{pmatrix} = \begin{pmatrix} S_{1M+1} \\ \vdots \\ S_{MM+1} \end{pmatrix} \quad (11)$$

とすれば良いことになる。すなわち、(11) を解くことによって、 a の最小 2 乗解が求められるが、この方程式の係数行列は上三角であるので $A(m)$ を求めることは容易である。また残差の分散は S_{M+1M+1}^2 / L_1 で与えられる。

その後、 L_2 時系列が得られた段階で X を

$$\begin{pmatrix} S_{11} & S_{12} & \cdots & S_{1M} & S_{1M+1} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & 0 & S_{M+1M+1} \\ x(L_1-M+1) & x(L_1-M) & \cdots & x(L_1) & x(L_1+1) \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x(L_1+L_2-M) & x(L_1+L_2-M-1) & \cdots & x(L_1+L_2-1) & x(L_1+L_2) \end{pmatrix} \quad (12)$$

と $(M+1) \times (M+1)$ 行列の下に L_2 個のモデルを追加する形で構成する。次にこの追加された下半分を L_2

回の変換によって上三角とし、この部分から AR_2 モデルを作成する。最後に上の AR_1 モデルの部分と出来たばかりの下の三角行列の部分を含めた行列に対する変換によって、 AR_c モデルの分の三角行列を作成する。この方法は、一部著者の一人によって外乱適応オートパイロット装置の開発においてその有効性が確かめられており^{(5),(6)}、海象変化のような局所的には定常とみなせる、ゆっくりとした変化には極めて有効であることが分かっている。

4. 状態空間モデルによる時系列の解析

4.1 時系列の状態空間表現

次にタスク 2 で確定したモデルを使って、タスク 1 において予測、ろ波、平滑等を時々刻々実行するため、本システムでは次に述べるカルマンフィルターを使っている。このためまず、 k 次元 AR モデル

$$y(n) = \sum_{m=1}^M A(m)y(n-m) + v(n) \quad (13)$$

をカルマンによって導入された状態空間表現

$$x(n) = F(n)x(n-1) + G(n)v(n) \quad (14)$$

$$y(n) = H(n)x(n) + w(n) \quad (15)$$

に変換する。ここで、 $x(n)$ はシステムの内部を表現する状態変数 (State variable)、 $F(n)$ は、遷移マトリクスである。 $v(n)$ 、 $w(n)$ は、それぞれ平均値 0、分散・共分散行列が $Q(n)$ 、 $R(n)$ のガウス性白色システム雑音、観測雑音である。このとき、 AR モデルのような線型モデルは全て状態空間表現に変換できることが知られている。ただし、よく知られているように、 AR モデルから状態空間モデルへの変換法は一意ではない。ここでは、予測信号が極めて速く得られる変換法として、

$$F = \begin{pmatrix} A(1) & I & 0 & \cdots & 0 \\ A(2) & 0 & I & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ A(M-1) & 0 & 0 & \cdots & I \\ A(M) & 0 & 0 & \cdots & 0 \end{pmatrix}, G = \begin{pmatrix} I \\ 0 \\ \vdots \\ 0 \\ 0 \end{pmatrix}, H = (I \ 0 \ \cdots \ 0) \quad (16)$$

と置く方法を採用する。

4.2 カルマンフィルターによる状態推定

次に k 次元観測値 $Y_j \{y(1), y(2), \dots, y(j)\}$ が与えられた条件下において、 n 時刻での内部状態 $x(n)$ の条件付き平均 $x(n|j)$ と分散共分散行列 $V(n|j)$ を推定する問題を考える。この時、(1) $j < n$ の場合を予測 (Prediction)、(2) $j = n$ の場合をろ波 (Filtering)、(3) $j > n$ の場合を平滑 (Smoothing) と呼ぶ。

ところで、 $v(n)$ 、 $w(n)$ は正規分布に従い、かつモデルは線型であるから、これらの条件付き分布も正規分布となる。したがって、分布の平均値ベクトル、分散共分散ベクトルが求まれば正規分布は確定する。モデルが状態空間モデルで表されるとき、カルマンフィルタ (Kalman Filter) を使う逐次計算アルゴリズムによれば、状態量の推定値 $x(n)$ の平均値、分散共分散すなわち

$$\begin{aligned} x(n|j) &\equiv E(x(n) | Y_j) \\ V(n|j) &\equiv E(x(n) - x(n|j))(x(n) - x(n|j))^t \end{aligned} \quad (17)$$

を求めることができる (以後、 $x(a|b)$ なる表記では b の条件下で a が起きることを示す)。カルマンフィルターは 1 期先予測 (Time Update) とフィルターの部分 (Measurement Update) に分けて次のように表される⁽³⁾。

[1 期先予測 (Time Update)]

$$\begin{aligned} x(n|n-1) &= F(n)x(n-1|n-1) \\ V(n|n-1) &= F(n)V(n-1|n-1)F(n)^t + G(n)Q(n)G(n)^t \end{aligned} \quad (18)$$

[フィルター (Measurement Update)]

$$\begin{aligned} K(n) &= V(n|n-1)H(n)^t \{H(n)V(n|n-1)H(n)^t + R(n)\}^{-1} \\ x(n|n) &= x(n|n-1) + K(n) \{y(n) - H(n)x(n|n-1)\} \\ V(n|n) &= \{I - K(n)H(n)\} V(n|n-1) \end{aligned} \quad (19)$$

4.3 カルマンフィルタによる長期予測

カルマンフィルタでの予測は、1期先の予測を与えている。さらに先の長期予測を行うには、カルマンフィルタの予測部分を繰り返せばよい。現在の時刻が n とすると、 $Y_n = \{y(1), y(2), \dots, y(n)\}$ が予測に使える。この観測データを基本に、 $j > 1$ 期先の予測を行う。新しいデータは入らないから、カルマンフィルタから得られる $n+1$ 時刻への予測の部分を $n+1$ 時刻のフィルタ部分と等置して、 $x(n+1 | n+1) = x(n+1 | n)$ 、 $V(n+1 | n+1) = V(n+1 | n)$ とする。すなわち、フィルタの部分を省略して、予測の部分のみで j 回繰り返せば、状態 $x(n)$ の j 期先の予測と分散共分散が推定される。すなわち

$$x(n+j | n) = F(n+j)x(n+j-1 | n) \quad (20)$$

$$V(n+j | n) = F(n+j)V(n+j-1 | n)F(n+j)' + G(n+j)Q(n+j)G(n+j)' \quad (21)$$

こうして、状態 $x(n)$ を知ることができたから、観測時系列 $y(n)$ の j 期先の推定値、分散共分散、すなわち $y(n+j | n) \equiv E[y(n+j | Y_n)]$ 、 $d(n+j | n) \equiv \text{Cov}[y(n+j | Y_n)]$ は、

$$\begin{aligned} y(n+j | n) &= E[H(n+j)x(n+j) + w(n+j) | Y_n] \\ &= H(n+j)x(n+j | n) \end{aligned} \quad (22)$$

$$\begin{aligned} d(n+j | n) &= \text{Cov}[H(n+j)x(n+j) + w(n+j) | Y_n] \\ &= H(n+j)V(n+j | n)H(n+j)' + R(n+j) \end{aligned} \quad (23)$$

で推定される。

5. 局所定常性の検証

次に、本システムの基本的な局所定常性判定アルゴリズムの検証を行う。ここで用いたデータは、東京商船大学汐路丸を用いて30度毎の変針試験の結果である。図4は、この時の横揺れデータ（サンプリング間隔1秒）を用いて、自己回帰モデルの次数を $M=20$ に固定し前節で述べた方式を使って、1スパン=200秒間隔（ $L_1=L_2=200$ ）で定常性をチェックした例である。ただし、非定常性の確認を明白にするため、観測されたデータを、600秒のところで波を斜め30度に受けている状態のデータから、正横から受けるデータに人工的に連結したデータである。4スパン目（621秒）から後のスパンでは時系列が変化したと判断し、モデルが変更され、従ってスペクトラムが変化していることがわかる。

また、第3スパンでも時系列の構造にわずかな変化があり、同質な第1、第2スパンのスペクトラムと若干の変化があることがわかる。また、スパンの節目におけるモデルの切り換えは、オンラインでの実験の結果、計算と定常性の判定を含めこの程度のスパンではほぼリアルタイムで切り替わることが確かめら

((下) スペクトラム：対数スケール、横軸は周波数 Hz)

図4 針路変更による横揺れ時系列に対する局所定常過程のあてはめの検証

れている⁵⁾。

6. 時系列の予測能力の検証

次に、確定した自己回帰モデルを基礎としたカルマンフィルターを使った、船体運動データの予測能力について検証する。そのうち本報告ではまず $k=1$ 、すなわちひとつの運動モードの予測をそれ自身の過去のデータから予測する場合を取り扱う。

6.1 中型コンテナ船の横揺れ、縦揺れの予測

風力 9 の荒波中を航行する中型コンテナ船において、1 秒間隔でサンプリングされた横揺れ、縦揺れのデータを使って、予測をした例を図 5（横揺れ）、図 6（縦揺れ）に示す。ただし、これらの図はオンライン実験で得られたものではなく、予め観測されたデータに前節で述べた局所定常モデルのあてはめをスパン 200 秒で行った結果を用いている。次数は 20 次に固定した。各図の最後の 20 秒間が予測結果で、3 本の実線のうちの中央は、カルマンフィルタの予測値 $x(n+j|n)$, $j=1, \dots, 20$, 上下の実線は予測値の標準偏差の上限, 下限すなわち $\pm V(n+j|n)$, $j=1, \dots, 20$ である。これに対して、丸印付きの実線は実測値である。ただし、予測が始まる時刻、すなわち図 5 では 610 秒以前、図 6 では 360 秒以前においては、実線は平滑 (Filtering) の結果およびそれらの標準偏差の上、下限を与えている。

図 5 の横揺れの結果では、ほぼ 20 秒間満足のいく予測値を与えている。これに対して、図 6 の縦揺れの結果では後半の 10 秒間の予測値は若干はずれるが前半の 10 秒間 (約 1 周期) は良い結果を与えている。減衰力の弱い横揺れ、それも単峰性スペクトラムをもつ場合の方が予測成績がよいことは当然の結果である。この傾向はデータの全域にわたって見られた。

図 5 中型コンテナ船の横揺れの 20 ステップ
(20 秒) 先までの予測

図 6 中型コンテナ船の縦揺れの 20 ステップ
(20 秒) 先までの予測

6.2 小型船の横揺れ、縦揺れの予測

運動周期の速い小型船の場合の予測能力を調べるため、汐路丸の 0.5 秒間隔のサンプリングデータを用い 50 秒スパン (100 データ) の定常性確認を行いながらそれぞれの運動予測能力を調べた。次数 M は 20 に固定した。図 7 は、横揺れの 2 例、図 8 は縦揺れの 2 例でいずれも最後の 10 秒間 (20 ステップ) を予測している。ここでも横揺れの予測はほぼ安定しているが、縦揺れの予測は横揺れよりも安定していないことが分かる。

図 7 汐路丸の横揺れの 20 ステップ
(10 秒) 先までの予測 (2 例)

図 8 汐路丸の縦揺れの 20 ステップ
(10 秒) 先までの予測 (2 例)

なお、1つのスパンの間に突變的に時系列の構造が全く異なると予測能力は次の節目のスパンにくるまで落ちることが予想される。図9は、同じ原理を制御の場合に応用して開発した外乱適応オートパイロットにおいて、島影から出た直後の海象変化により制御成績が悪化した例⁶⁾であるが新しいモデルの導入により制御成績が向上していることがわかる。一般に大洋航行中は、気象、海象の基本的な変化は、適当な長さのスパンの間では局所定常性が成り立つ程度に一定であると考えられるから、本システムでも追従可能であると考えられる。

図9 外乱適応型オートパイロットの突風に対する応答⁶⁾

7. まとめ

本報告では、船載型船体運動予測解析システムの基本構成、外乱変化に適応するモデルの構成法を提案した。そして、まずある1つの船体運動モードの予測をそれ自身の過去のデータだけから、どの程度先まで予測可能かを中型コンテナ船と小型船の実船データを用いて、横揺れと縦揺れに関して検証した。

その結果、

1. Ozaki-Tong の方法を用いた局所定常船体運動データのモデル作成が有効であることを確かめた。
2. 横揺れの方が縦揺れよりも予測精度が高いことがわかった。
3. 中型コンテナ船の横揺れは1.5周期（20秒程度先）程度、縦揺れでも1周期程度先（15秒程度先）の予測が可能である。
4. 小型船においても横揺れは安定して10秒程度先まで、縦揺れは予測精度の安定性がそれよりやや落ちる。

等のが分かった。今後の検討事項としては、減衰力の強い縦揺れなどについて精度を上げるために、他の運動モード、波浪データなどの導入を検討することが重要である。

本研究の遂行にあたり統計数理研究所、北川源四郎博士にお世話になったことを感謝します。また原稿整理にあたり織田美千子さんにお世話になりました事を感謝します。

参 考 文 献

- (1) 菅井和夫他：船体強度モニタリングシステムについて，日本造船学会誌，705号，pp.21-44，1988
- (2) 北川源四郎：時系列解析プログラミング，岩波書店，1993
- (3) H.Akaike：Information theory and an extension of the maximum likelihood principle, *2nd International Symposium on Information Theory* (eds.B.N.Petrov and F.Csaki), pp.267-281, Akademiai Kiado, Budapest, 1973
- (4) T.Ozaki and H.Tong：On the fitting of non-stationary autoregressive models in the time series analysis, *Proceeding of the 8-th Hawaii International Conference on System Science*, Western Periodical Hawaii, 1975
- (5) K.Ohtsu, M.Horigome and G.Kitagawa：A Robust autopilot system against the various sea conditions, *Proceeding ISSOA Symposium*, Tokyo, 1979
- (6) 大津皓平：船体運動と主機関の統計的最適制御，時系列解析の基礎，朝倉書店，1993