

# 몬테카를로 기반 재귀최소자승법에 의한 시스템 인식 실험 연구

## Experimental Study on a Monte Carlo-based Recursive Least Square Method for System Identification

이 상 덕\* · 정 슬†  
(Sang-Deok Lee · Seul Jung)

**Abstract** - In this paper, a Monte Carlo-based Recursive Least Square(MC-RLS) method is presented to directly identify the inverse model of the dynamical system. Although a RLS method has been used for the identification based on the deterministic data in the closed loop controlled form, it would be better for RLS to identify the model with random data. In addition, the inverse model obtained by inverting the identified forward model may not work properly. Therefore, MC-RLS can be used for the inverse model identification without proceeding a numerical inversion of an identified forward model. The performance of the proposed method is verified through experimental studies on a control moment gyroscope.

**Key Words** : Recursive least square, Monte carlo simulation, inverse model identification, Control moment gyroscope

### 1. 서 론

시스템 인식의 목적은 그 시스템의 일반화된 모델을 찾아 제어의 성능을 높이는 데 있다. 이를 위해서 주파수 영역 [1]이나 시간 영역 [2]에서 시스템의 특성을 파악하여 모델을 구하는 과정이 필요하다. 주파수 영역에서의 시스템 인식은 스위핑 주파수(Sweeping Frequency)를 인가했을 때 시스템의 주파수 응답 특성을 확인하는 과정을 통해 이루어진다. 최근 FFT가 탑재된 알고리즘을 사용하여 실시간으로 주파수 영역에서의 시스템 모델링을 하는 연구가 이루어지고 있으나 [3], 주파수 영역에서의 시스템 인식 과정은 대부분 오프라인 방법으로 활용되어지고 있다.

이에 반해 시간 영역에서의 시스템 인식 방법은 실시간(Real-Time) 구현이 가능하다는 장점을 갖고 있다. 시간 영역에서의 시스템 인식은 입력과 출력 데이터의 관계를 이용하여 시스템 모델을 인식한다. 시간영역에서 입력과 출력 데이터의 관계를 이용하여 모델을 유추하는 방법 중의 하나가 재귀최소자승법(Recursive Least Square, RLS)이다. RLS는 빠른 수렴 특성과 간단하게 구현이 가능하다는 장점을 지니고 있어 변수 인식이나 모델 인식에 적합한 알고리즘으로 활용되어지고 있다[4-12].

재귀최소자승법의 대표적인 단점은 주기 신호와 같은 결정적 신호(Deterministic Signal)를 데이터로 사용하는 것이다. 단일 주파수를 갖고 있는 주기적 신호를 반복적으로 시스템에 인가했을

때 입력 데이터와 출력 데이터의 관계를 통해 선형화된 시스템 모델을 보다 잘 인식할 수 있게 된다. 제어분야에서도 개루프로 인식하기보다는 시스템이 제어된 폐루프에서 수행되는 경우가 많다. 하지만, 이 때 인식된 모델은 사용된 특정 주파수에 국한된 모델이 되므로 이를 일반화하기 위해서는 주파수 응답 방법과 유사하게 주기적 신호의 주파수를 스위핑시키면서 각각의 응답들을 모두 확인해야하는 번거로움이 발생하게 된다.

따라서 랜덤 데이터에 기반 한 인식 방법, 즉 몬테카를로방법은 일반화된 모델을 인식한다는 장점이 생긴다. RLS가 랜덤 데이터에 대해 어떤 인식의 정확성을 갖는지에 대해서 확실하게 알 수가 없으므로 랜덤 데이터에 기반 한 RLS 인식 방법이 시스템 모델 인식에 있어서 어느 정도 효과가 있는지를 확인하고 어떤 문제점이 발생하게 되는지를 알아볼 가치가 충분하다.

본 논문에서는 몬테카를로기반 RLS 방법이 시스템의 모델 인식 과정에서 어떠한 주요한 강점과 단점을 보이는 지에 대해 실험적으로 살펴보고자 한다. 실제 모멘텀 구동시스템(control moment gyroscope, CMG)을 대상으로 역모델을 인식하고 인식된 모델에 대한 평가를 하고자 한다.

본 논문의 구성은 다음과 같다. 먼저 RLS 알고리즘에 대해 소개한다. 다음으로 인식 대상 시스템인 감벌시스템에 대해 소개하고 RLS 인식 과정에서의 문제점을 지적하고 해결방안을 제시한다. 끝으로 실험을 통해 제안한 방법의 유효함을 검증한다.

### 2. 본 론

#### 2.1 재귀최소자승법

임의의 모터 시스템은 선형화 과정을 거쳐 이차 선형 시스템

† Corresponding Author : Dept. of Mechatronics Engineering, Chungnam National University, Korea.

E-mail : jungsl@cnu.ac.kr

\* Dept. of Mechatronics Engineering, Chungnam National University, Korea.

Received : June 19, 2017; Accepted : January 23, 2018

으로 다음과 같이 표현할 수 있다.

$$I\ddot{\theta}(t) + B\dot{\theta}(t) + K\theta(t) = \tau(t) \quad (1)$$

여기서  $\tau(t)$ 는 토크이고  $I$ 는 관성 변수이고  $B$ 는 댐핑 변수이고  $K$ 는 스프링 변수이고  $\theta(t)$ 는 각도이다.

식 (1)을 라플라스 변환을 하면 다음과 같다.

$$\frac{\Theta(s)}{T(s)} = \frac{1}{Is^2 + Bs + K} \quad (2)$$

식 (2)의 이차 모델의 역모델을 사용하기 위해서는 분모 분자의 차수가 같은 proper 전달함수를 사용한다.

$$\frac{\theta(s)}{T(s)} = \frac{a_1s^2 + a_2s + a_3}{s^2 + a_4s + a_5} \quad (3)$$

여기서 변수들  $a_1, a_2, a_3, a_4, a_5$ 은 시스템 모델을 나타내며 궁극적으로 재귀최소자승법을 사용하여 찾아내는 것이 목적이다.

재귀최소자승법은 많이 알려진 선형 매핑 방법으로 입출력 데이터 간의 상관관계를 통해 시스템의 모델을 인식하는 방법이다. 식 (3)을 이산영역에서 표현하는 경우 RLS 알고리즘은 3개의 업데이트 식의 구현을 통해 작동하게 된다.

$$G(n) = \frac{\frac{1}{\lambda}P(n-1)\mathbf{x}(n)}{1 + \frac{1}{\lambda}\mathbf{x}^T(n)P(n-1)\mathbf{x}(n)} \quad (4)$$

$$P(n) = \frac{1}{\lambda}(P(n-1) - G(n)\mathbf{x}^T(n)P(n-1)) \quad (5)$$

$$\hat{\phi}(n) = \hat{\phi}(n-1) + G(n)(y(n) - \mathbf{x}^T(n)\hat{\phi}(n-1)) \quad (6)$$

여기서  $G(n)$ 은 게인 행렬이고  $\lambda$ 는 망각인자 이고  $P(n)$ 은 공분산 행렬이고  $\mathbf{x}(n)$ 은 입력 데이터 행렬이고  $y(n)$ 은 출력이고  $\hat{\phi}(n)$ 은 추정된 변수 행렬이다.

이차시스템(Second-order system)으로 모델링할 경우에 변수들은 다음 표 1과 같이 정의 된다.

재귀최소자승법은 표 1에서 5개의 입력 데이터가 하나의 출력

표 1 RLS 변수 정의

Table 1 Definition of variables of the RLS

$$G(n) = [G_1(n) G_2(n) G_3(n) G_4(n) G_5(n)]^T$$

$$P(n) = \begin{bmatrix} P_{11}(n) & P_{12}(n) & P_{13}(n) & P_{14}(n) & P_{15}(n) \\ P_{21}(n) & P_{22}(n) & P_{23}(n) & P_{24}(n) & P_{25}(n) \\ P_{31}(n) & P_{32}(n) & P_{33}(n) & P_{34}(n) & P_{35}(n) \\ P_{41}(n) & P_{42}(n) & P_{43}(n) & P_{44}(n) & P_{45}(n) \\ P_{51}(n) & P_{52}(n) & P_{53}(n) & P_{54}(n) & P_{55}(n) \end{bmatrix}$$

$$\lambda = \text{constant}, (0 < \lambda \leq 1)$$

$$\mathbf{x}(n) = [x_1 \ x_2 \ x_3 \ x_4 \ x_5]^T$$

$$\hat{\phi}(n) = [\phi_1 \ \phi_2 \ \phi_3 \ \phi_4 \ \phi_5]^T$$

데이터를 만들 때 비용 함수를 최소화하는 변수 5개가 추정되는 원리이다. 변수 추정 성능은 추정된 출력의 정확성과 수렴 속도에 의해 정의된다. 초기 공분산 값의 설정과 망각 인자  $\lambda$  값이 시스템 인식 성능에 미치는 영향도 중요하다 [14].

RLS 알고리즘에 의한 모델과 역 모델 인식 과정은 그림 1과 같이 도식화할 수 있다.

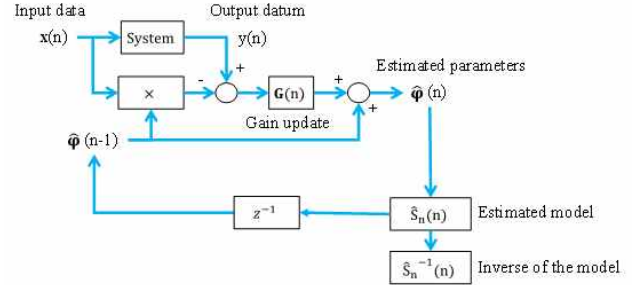


그림 1 재귀최소자승법에 의한 모델 인식 과정

Fig. 1 Model identification by RLS

그림 1에서 추정 모델은 FIR-필터 또는 IIR-필터 형태를 갖는다. FIR의 경우 안정성이 보장되는 반면, 이차시스템을 IIR-필터 형태의 모델로 인식할 경우 RLS는 그 안정성을 보장할 수 없게 된다. 특히 인식된 선형모델로부터 역모델을 사용하는 경우에 안정성에 문제가 발생할 수 있게 된다.

예컨대, 제안된 알고리즘은 NMP (Non-minimum Phase) 모델로 인식된 RLS 모델을 MP 모델로 변환할 수가 있다. 이 때 그림 2와 같이 주파수 영역에서의 크기는 변화가 없고 위상 조건만이 변하게 된다.

$$H_1(z) = \frac{1 + 2z^{-1} + 4z^{-2}}{1 + \frac{5}{6}z^{-1} + \frac{1}{6}z^{-2}}, \quad H_2(z) = \frac{4 + 2z^{-1} + 1z^{-2}}{1 + \frac{5}{6}z^{-1} + \frac{1}{6}z^{-2}} \quad (7)$$




그림 2  $H_1(z)$  and  $H_2(z)$ 의 보디선도

Fig. 2 Bode diagram for  $H_1(z)$  and  $H_2(z)$

이러한 문제점에 대해서는 선형연구에서 All-Pass-Filter(APF)를 사용하여 분모 분자를 모두 안정화 하는 방법을 제안하였다 [12]. 제안된 안정화 방법을 통해 인식된 모델과 그 역 모델은

항상 안정하게 된다. 인식된 시스템 모델은 이산영역에서 다음과 같다.

$$\hat{S}(z) = \frac{\phi_1 + \phi_2 z^{-1} + \phi_3 z^{-2}}{1 + \phi_4 z^{-1} + \phi_5 z^{-2}}, \hat{S}^{-1}(z) = \frac{1 + \phi_4 z^{-1} + \phi_5 z^{-2}}{\phi_1 + \phi_2 z^{-1} + \phi_3 z^{-2}} \quad (8)$$

### 2.2 시스템 순모델로 부터 역모델 추정방식

그림 1의 방법은 먼저 입력력 데이터를 통해 순방향 모델,  $\hat{S}(z)$ 을 RLS 방법으로 구하고, 구한 순방향 모델의 역으로 부터 역모델,  $\hat{S}^{-1}(z)$ 을 구하는 알고리즘을 나타낸다. 하지만 순행 모델로부터 역으로 사용하는 역모델의 경우에는 정확도가 떨어져 시스템 제어 성능이 저하되는 문제가 발생한다. 본 논문에서는 이러한 역모델 인식방법의 문제점을 실험적으로 검증하고 대안을 제시하고자 한다.

인식된 모델 (8)에 의해서 추정된 출력 값은 다음과 같이 쓸 수 있다.

$$\hat{y}(n) = \mathbf{x}^T(n) \hat{\phi}(n-1) \quad (9)$$

그러므로 모델 인식의 정확성은 (10)에 의해 알 수가 있다.

$$Accuracy = y(n) - \hat{y}(n) \quad (10)$$

실험을 통해 간접적으로 역모델을 구해 보자. 랜덤 데이터가 입력으로 가해졌을 때의 모델 인식 성능을 파악하기 위한 실험을 진행하였다. 실험에 사용된 시스템은 1축 제어모멘트자이로 프로토타입 시스템이고 실험 환경은 그림 3과 같다.





그림 3 실험 환경  
Fig. 3 Experimental setup

컴퓨터에서 연산되는 RLS-APF 알고리즘은 RLS로부터 안정한 모델을 얻기 위해 제안된 알고리즘이고 그림 3의 우측에 있는 시스템은 1축 제어모멘트자이로 프로토타입 시스템이다.


시스템 인식 실험은 프로토타입의 킴벌 축에 대한 토크 제어 모델 획득을 목적으로 수행되었고 입력된 전류와 출력된 킴벌의 각도의 관계를 이차시스템 모델을 이용하여 IIR-필터 형태로 인식하도록 진행하였다.

실험에 사용된 입력데이터는 그림 4(a)와 같은 랜덤 데이터이고 랜덤 입력 전류 데이터에 의한 출력 데이터는 그림 4(b)와 같

은 랜덤 킴벌 각도 데이터가 수집되었다.



(a) 랜덤 입력 데이터




(b) 랜덤 출력 데이터


그림 4 실험 데이터

Fig. 4 Experiment data

실험을 통해 모델 인식의 정확성을 확인하였다. 모델 인식 정확성은 (10)에서와 같이 측정된 출력값과 추정된 출력값의 비교를 통해 확인한다. 모델에 대한 추정 성능은 그림 5(a)와 같았고 그 역 모델에 대한 추정 성능은 그림 5(b)와 같았다.



(a) 모델 추정 성능



(b) 역 모델 추정 성능

그림 5 RLS 성능 평가

Fig. 5 RLS performance evaluation

그림 5(a)의 모델 추정 오차는 그림 6과 같다. 평균 오차는 0.000157 rad 이고 분산 오차는 0.0000097 rad 으로 분석되었다. 매우 정확한 추정 성능을 갖고 있음을 알 수가 있다.





그림 6 모델 추정 오차

Fig. 6 Model estimation error

하지만 역모델의 경우 그림 5(a)에서 미리 인식된 모델  $\hat{S}(z)$ 의 역, 즉  $\hat{S}^{-1}(z)$ 로부터 구할 경우에 그림 5 (b)에서 볼 수 있듯이 그 역모델에 대한 추정 성능은 보장하지 못하는 문제를 발견하였다. 따라서 선행 모델로부터 역모델을 구하지 않고 직접 역모델을 구하고자 한다.

### 2.3 MC-RLS 역모델 추정 방식

본 논문에서는 앞서 제시된 문제를 해결하기 위해 몬테카를로 재귀최소자승법(Monte Carlo Recursive Least Square, MC-RLS) 방법을 사용하였다. 순방향 모델 인식은 그림 7 (a)이고 역모델 인식 구조는 그림 7 (b)와 같다. 인식된 순방향 그리고 역방향의 전달함수는 수식적으로 정확하게 역관계가 성립되는 것은 아니다.



(a)Model identification (b)Inverse model identification

그림 7 MC-RLS 구조

Fig. 7 MC-RLS framework

첫 번째 APF-RLS는 모델을 추정하는 역할을 하고 두 번째 APF-RLS는 역 모델을 추정하는 역할을 한다. 이러한 구조에서 모델과 역 모델은 동시에 추정이 될 수가 있다. 이 때 추정된 두 모델은 항상 안정하다.

첫 번째 APF-RLS에서 입력 데이터는 다음과 같다.

$$\mathbf{x}(n) = [Ki(n) Ki(n-1) Ki(n-2) \theta(n-1) \theta(n-2)]^T \quad (11)$$

식 (11)에서  $K(N/A)$ 는 토크 상수 이고  $i(n)$ 은 현재 상태 입력 전류이고  $i(n-1)$ 는 바로 직전 제어 주기에서의 입력 전류 이고  $i(n-2)$ 는 두 제어 주기 이전의 입력 전류이고  $\theta(n-1)$ 는 바로 직전 제어 주기에서의 측정된 김벌의 출력 각도 이고  $\theta(n-2)$ 는 두 제어 주기 이전에 측정된 김벌의 출력 각도이다.

추정된 출력 데이터와 모델 변수는 다음과 같다.

$$\begin{aligned} \hat{y}(n) &= \hat{\phi}_{f1}(n-1)K i(n) + \hat{\phi}_{f2}(n-1)K i(n-1) \\ &+ \hat{\phi}_{f3}(n-1)K i(n-2) - \hat{\phi}_{f4}(n-1)\theta(n-1) \\ &- \hat{\phi}_{f5}(n-1)\theta(n-2) \end{aligned} \quad (12)$$

여기서  $\hat{\phi}_{f1}, \hat{\phi}_{f2}, \hat{\phi}_{f3}, \hat{\phi}_{f4}, \hat{\phi}_{f5}$ 는 순방향 모델 변수이다. 변수 업데이트 식은 다음과 같다.

$$\begin{aligned} \tilde{\phi}_f(n-1) &= APF\{\phi_f(n-1)\} \\ &= [\tilde{\phi}_{f1}(n-1) \tilde{\phi}_{f2}(n-1) \tilde{\phi}_{f3}(n-1) \tilde{\phi}_{f4}(n-1) \tilde{\phi}_{f5}(n-1)]^T \end{aligned} \quad (13)$$

두 번째 APF-RLS에서 입력 데이터, 출력 데이터는 다음과 같다.

$$\begin{aligned} \mathbf{y}(n) &= [\theta(n) \theta(n-1) \theta(n-2) Ki(n-1) Ki(n-2)]^T \quad (14) \\ \hat{\mathbf{x}}(n) &= \hat{\phi}_{i1}(n-1)\theta(n) + \hat{\phi}_{i2}(n-1)\theta(n-1) \\ &+ \hat{\phi}_{i3}(n-2)\theta(n-3) - \hat{\phi}_{i4}(n-1)K\hat{i}(n-1) \\ &- \hat{\phi}_{i5}(n-1)K\hat{i}(n-2) \end{aligned} \quad (15)$$

여기서  $\hat{\phi}_{i1}, \hat{\phi}_{i2}, \hat{\phi}_{i3}, \hat{\phi}_{i4}, \hat{\phi}_{i5}$ 는 역방향 모델 변수이다. 변수 업데이트 식은 다음과 같다.

$$\begin{aligned} \tilde{\phi}_i(n-1) &= APF\{\phi_i(n-1)\} \\ &= [\tilde{\phi}_{i1}(n-1) \tilde{\phi}_{i2}(n-1) \tilde{\phi}_{i3}(n-1) \tilde{\phi}_{i4}(n-1) \tilde{\phi}_{i5}(n-1)]^T \end{aligned} \quad (16)$$

### 2.4 실험환경

역모델 인식 실험은 신규 제작한 제어모멘트자이로의 김벌축에 대한 토크-각도 모델링을 위해 진행되었고 실험 과정에 관한 몇 장의 사진은 다음 그림 8과 같다. 랜덤 입력에 대한 출력 데이터를 통해 모델링을 수행하였다.

MC-RLS 방식을 사용하여 역모델을 구하여 인식 성능을 확인한다. RLS 변수 초기값들은 앞 실험과 동일하게 설정한 표 2의 조건으로 수행되었다.

### 2.5 실험결과

MC-RLS에 의한 역 모델 인식 결과는 다음 그림 9와 같다. 그림 9(a)는 20초간 추정데이터와 측정 데이터를 비교한 것이다. 그림 9(b)는 데이터 간의 차이를 보기 위해 그림 9 (a)에서 1초 동안의 데이터만 따로 표현한 것으로 매우 유사하게 나타나는 것을 볼 수 있다.

종래 방법을 사용했을 경우 그림 5 (b)에서와 같이 역 모델 추정 성능이 좋지 못했던 결과가 그림 9와 같이 그 성능이 매우




그림 8 시스템 인식 실험 영상  
 Fig. 8 Images of experiment for system identification

표 2 RLS 변수 초기화

Table 2 Initialization of RLS variables

$$G(n) = [0 \ 0 \ 0 \ 0]^T$$

$$P(n) = \begin{bmatrix} 50 & 0 & 0 & 0 \\ 0 & 50 & 0 & 0 \\ 0 & 0 & 50 & 0 \\ 0 & 0 & 0 & 50 \end{bmatrix}$$


$$\lambda = 0.999$$

향상됨을 볼 수 있다. 그림 9(b)는 1초 동안의 모델 추정과 특정 데이터를 나타내고 그림 9(c)는 모델 추정 오차이다. 오차가 매우 작음을 알 수 있다.


MC-RLS의 인식 성능은 주파수 분석을 통해 조사할 수가 있다. 그림 10은 MC-RLS에 의한 역 모델 추정에 관한 주파수 영역 분석 결과이다.

그림 10에서와 같이 랜덤 데이터는 주파수 영역의 전 범위에 랜덤하게 흩어져 있는 특성을 갖게 되며 인식된 모델이 각각의 랜덤 주파수에 잘 매칭되었음을 알 수가 있다. 랜덤 신호에 포함된 신호들의 랜덤 주파수 성분들이 MC-RLS에 의해서 추정이 가능함을 나타낸다.


또 다른 랜덤 입력 신호에 대한 추가적인 실험을 통해 이와 같은 실험 결과가 반복적으로 가능한지를 검증하였다. 같은 환경에서 추가 실험을 진행하였고 실험 결과에 대한 주파수 영역 분석 결과는 그림 11과 같고 표 3과 같이 요약 정리하였다. 그림 11(b)에서 보면 마찬가지로 추종 오차가 매우 적게 나타남을 알 수 있다. 이는 역모델의 인식이 잘 이루어졌음을 의미한다.



(a) 역 모델 추정 성능 (20초)



(b) 역 모델 추정 성능 (1초)



(c) 역 모델 추정 오차

그림 9 MC-RLS 성능 평가

Fig. 9 MC-RLS performance evaluation




그림 10 주파수 영역 분석

Fig. 10 Frequency-domain analysis

표 3 추가 검증 결과

Table 3 Extra verification results

	Mean	Variance
Task	-3.6E-06	4.1E-06




그림 11 추가 검증  
Fig. 11 Extra verification

### 3. 결 론

일반적으로 시스템의 역모델 인식 과정에서는 안정적인 입출력 데이터, 즉 결정적 데이터(deterministic data)를 기반으로 재귀최소자승법을 통해 모델을 구한 다음, 그 모델의 역을 취해 역 모델을 구했다. 하지만 이렇게 구한 역모델은 인식 모델의 대역폭이 한정되어 있어 제대로 인식되지 않는 문제가 있다. 본 논문에서는 랜덤 데이터를 사용하여 역 모델을 인식하고 그 정확도를 실험을 통해서 확인하였다. 몬테카를로 재귀최소자승법(Monte Carlo Recursive Least Square, MC-RLS) 방법을 사용하여 역 모델을 추정하고 인식된 모델의 안정성은 APF 방법에 의해 항상 보장이 되도록 하였다. 제안된 MC-RLS 방법은 제어모멘트자이로(Control Moment Gyro, CMG) 프로토타입에 실제 적용해서 그 성능을 검증하였다. 역 모델 인식의 문제점이 해결될 수 있음을 주파수 영역에서 분석한 결과를 통해 제시하였다.

### 감사의 글

본 연구는 2017년 한국연구재단 기초연구(NRF-2016 R1A2A1A0102031)의 지원을 받아 이루어진 연구로 지원에 감사드립니다.

### References

- [1] R. Pintelon and J. Schoukens, "System identification: a frequency domain approach," John Wiley & Sons, 2012.
- [2] L. Ljung, "System identification," John Wiley & Sons, 1999.
- [3] T. Hiyama, N. Suzuki, and T. Funakoshi, "On-line identification of power system oscillation modes by using real time FFT," IEEE Power Engineering Society Winter Meeting, vol. 2, pp. 1521-1526, 2000.
- [4] M. Beza and M. Bongiorno, "A modified RLS algorithm for online estimation of low-frequency oscillations in power systems," IEEE Transactions on Power Systems, vol. 31, no. 3, pp. 1703-1714, 2016.
- [5] Y. H. Eng, K. M. Teo, M. Chitre, and K. M. Ng, "Online system identification of an autonomous underwater vehicle via in-field experiments," IEEE Journal of Oceanic Engineering, vol. 41, no. 1, pp. 5-17, 2016.
- [6] N. Reichbach and A. Kuperman, "Recursive-squares-based real-time estimation of supercapacitor parameters," IEEE Transactions on Energy Conversion, vol. 31, no. 2, pp. 810-812, 2016.
- [7] M. Tanelli, L. Piroddi, S. M. Savaresi, "Real-time identification of tire-road friction conditions," IET Control Theory & Applications, vol. 3, no. 7, pp. 891-906, 2009.
- [8] A. Ashrafian and J. Mirsalim, "On-line recursive method of phasor and frequency estimation for power system monitoring and relaying," IET Generation, Transmission & Distribution, vol. 10, no. 8, pp. 2002-2011, 2016.
- [8] M. Ruderman, M. Iwasaki, "Observer of Nonlinear Friction Dynamics for Motion Control," Industrial Electronics, IEEE Transactions on, vol. 62, no. 9, pp. 5941-5949, 2015.
- [9] S. A. Fattah, W. -p. Zhu, and M. O. Ahmad, "Identification of autoregressive moving average systems based on noise compensation in the correlation domain," IET Signal Processing, vol. 5, no. 3, pp. 292-304, 2011.
- [10] M. Z. A. Bhotto and A. Antoniou, "New improved recursive least-squares adaptive-filtering algorithm," IEEE Transactions on Circuits and Systems, vol. 60, no. 6, pp. 1548-1558, 2012.
- [11] M. Badoni, A. Singh, and B. Singh, "Variable forgetting factor recursive least square control algorithm for DSTATCOM," IEEE Transactions on Power Delivery, vol. 30, no. 5, pp. 2353-2361, 2015.
- [12] S. D. Lee and S. Jung, "An identification technique for non-minimum phase systems by a recursive least square method," Proceedings of the SICE Annual Conference 2016, pp. 624-626, 2016.
- [13] S. D. Lee and S. Jung, "Monte Carlo Based CMG System Identification Method: Dual Recursive Least Squares," CICS, 2017
- [14] S. D. Lee and S. Jung, "Analysis of Parameter Effect in Inverse Model Identification by Recursive Least Square Method," ICROS, 2017

---

저 자 소 개



**이 상 덕 (Sang-Deok Lee)**

1998년 전북대학교 전자공학과 졸업. 1998년~2000년 LG정밀 근무. 2003년 전북대학교 전자공학과 석사. 2003년~2014년 삼성중공업연구원. 현재 충남대학교 메카트로닉스공학과 박사과정.



**정 슬 (Seul Jung)**

1988년 미국 웨인 주립대 전기 및 컴퓨터공학과 졸업. 1991년 미국 캘리포니아대 데이비스 전기 및 컴퓨터 공학과 석사. 1996년 동 대학 박사 졸업. 1997년~현재 충남대학교 메카트로닉스공학과 교수. 관심분야는 지능제어 및 지능로봇 시스템, 밸런싱 시스템, 서비스 로봇, 자이로 구동기, 드론, 로봇교육.