

유도전동기 벡터제어를 위한 Support Vector Regression을 이용한 회전자자속 추정기

한동창*, 백운재*, 김성락*, 김한길**, 이석규#, 박정일**

Rotor flux Observer Using Robust Support Vector Regression for Field Oriented Induction Mmotor Drives

Dong Chang Han*, Woon Jae Back*, Sung Rag Kim*, Han Kil Kim**, Suk Gyu Lee# and Jung IL Park**

ABSTRACT

In this paper, a novel rotor flux estimation method of an induction motor using support vector regression(SVR) is presented. Two well-known different flux models with respect to voltage and current are necessary to estimate the rotor flux of an induction motor. Training of SVR which the theory of the SVR algorithm leads to a quadratic programming(QP) problem. The proposed SVR rotor flux estimator guarantees the improvement of performance in the transient and steady state in spite of parameter variation circumstance. The validity and the usefulness of proposed algorithm are throughly verified through numerical simulation.

Key Words : Support Vector Regression(SVR), Field Oriented Control(자속기준제어), Induction Motor(유도전동기), Rotor Resistance(회전자저항)

기호설명

R_s, R_r = stator and rotor resistances
 L_s, L_r = stator and rotor inductances
 L_m = mutual inductance
 λ_{dqs}^s = stator fluxes in the stationary reference frame
 λ_{dqr}^s = rotor fluxes in the stationary reference frame
 T_r = rotor time constant

ρL_s = stator transient inductance(= $L_s - (L_m^2/L_r)$)
 v_{dqs}^s, i_{dqs}^s = stator voltage and stator current
 w_r = rotor angle speed
 θ_e = angular position of rotor
 p = differential operator

1. 서론

유도전동기를 직접 또는 간접벡터 제어하기 위해서는 회전자의 자속정보가 필요하며, 자속정보를 알기위해서는 회전자의 위치 또는 속도 검출기가 필수적이다. 특히 회전자 자속 검출기로는 홀센서

접수일: 2004년 8월27일; 게재승인일: 2004년 12월 13일

* 영남대학교 전기공학과 대학원

** 영남대학교 전자정보공학부

영남대학교 전자정보공학부

E-mail sglee@yu.ac.kr Tel. (053) 810-2487

(Hall Sensor)에 의한 공극자속의 측정, 측정 코일 (Sensing Coil)에 의한 공극전압의 측정 등의 방법이 있으나, 하드웨어의 복잡성, 가격상승, 열악한 환경에서의 사용의 어려움, 낮은 신뢰성, 기계적 부착의 어려움 및 전기적 잡음 등의 경제적·기술적 측면의 문제점이 생길 수 있다. 이와 같은 문제점을 해결하기 위해 기준자속을 순시적으로 추정하는 자속추정기가 오랫동안 연구의 대상이 되어왔다. 대표적인 자속 추정기로는 전류모델 추정기와 전압 모델 추정기가 있으며, 전기적인 유도전동기 모델로부터 유도전동기 상태방정식을 유도하고, 적절한 추정기 이득 값을 선택함으로써 자속을 추정하는 전차원·최소차원 추정기 등이 있다.^{1,8} 그러나 앞에서 언급한 방법들은 전동기 상수들이 운전의 조건에 따라 변하고 잡음 등의 영향 때문에 과도 상태와 전 속도범위에서 만족할 만한 성능을 얻을 수 없는 문제점을 가지고 있다. 이와 같은 문제점을 해결하기 위해 전압모델의 옅섯 문제에 강인한 전류모델과 전동기 파라미터 오차에 강인한 전압모델을 적절히 혼용하는 방법이 제안되었다.^{1, 6-7} 그러나 이 방법 또한 고속영역에서 전류모델의 영향을 받아 전동기 파라미터변화에 따른 자속추정오차를 수반한다.⁴

본 논문에서는 전압, 전류모델과 Support Vector Regression(SVR)을 결합한 새로운 추정기법을 제안한다. 제안된 방식은 학습알고리즘의 일종인 SVR9-14을 이용하여 전압모델에서 추정된 자속을 목표 값으로 하고 전류모델에서 추정된 자속을 훈련데이터로 하며, 운전 중에 연속적으로 목표값을 추종하도록 구성하고, 저속 및 고속에서 자속을 보다 정확하게 그리고 전동기의 상수변화로부터 강인(Robust)하게 추정함을 컴퓨터를 이용한 시뮬레이션을 통해 확인하고자 한다.

2. 자속추정기

2.1 전압모델과 전류모델

유도전동기의 자속기준제어(Field Orientation Control) 혹은 벡터제어(Vector Control)를 위해서는 (1)의 회전자 자속각 θ_e 가 필요하다. 자속각 θ_e 를 계산하기 위해 필요한 회전자 자속 λ_{dr}^s 은 정지좌표계($w=0$)에서의 전압모델 및 전류모델은 식(2), 식(3)으로 나타낼 수 있다.

$$\theta_e = \tan^{-1}(\lambda_{qr}^s/\lambda_{dr}^s) \quad (1)$$

$$p \begin{bmatrix} \lambda_{dr}^s \\ \lambda_{qr}^s \end{bmatrix} = \frac{L_r}{L_m} \begin{bmatrix} v_{ds}^s \\ v_{qs}^s \end{bmatrix} - \begin{bmatrix} R_s + \sigma L_s p & 0 \\ 0 & R_s + \sigma L_s p \end{bmatrix} \begin{bmatrix} i_{ds}^s \\ i_{qs}^s \end{bmatrix} \quad (2)$$

$$p \begin{bmatrix} \lambda_{dr}^s \\ \lambda_{qr}^s \end{bmatrix} = \begin{bmatrix} -1/T_r & -w_r \\ w_r & -1/T_r \end{bmatrix} \begin{bmatrix} \lambda_{dr}^s \\ \lambda_{qr}^s \end{bmatrix} + \frac{L_m}{T_r} \begin{bmatrix} i_{ds}^s \\ i_{qs}^s \end{bmatrix} \quad (3)$$

2.2 Support Vector Regression

훈련 데이터 $\{(x_i, y_i), i = 1, \dots, l\}$, $x_i \in R^m, y_i \in R^n$ 이 주어진다고 가정한다. 여기서 l 은 훈련 데이터의 개수, x 는 입력벡터, y 는 목표 값을 나타낸다. SVR은 모든 훈련데이터에 대해서 실제 목표 값 y_i 로부터 최고 ϵ (Insensitive Parameter)만큼의 편차 내에 있으며 가능한 작은 크기의 가중치벡터 w (Weight Vector)를 갖는 다음과 같은 함수를 SVR의 출력으로 가진다.

$$f(x, w) = w^T x + b, b \in R \quad (4)$$

여기서 T 는 벡터의 전치, b 는 바이어스 이다. 식(4)에서 가중치 감소를 이용하여 함수근사 하는 한 가지 방법으로 유클리드 놈(Euclidean Norm) $\|w\|^2$ 을 최소화 하는 것으로 다음과 같은 볼록 최적화(Convex Optimization)문제로 간주될 수 있다.

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \zeta(\xi_i + \xi_i^*), \\ \text{subject to} \quad & \begin{cases} y_i - wx_i - b \leq \epsilon + \xi_i \\ wx_i + b - y_i \leq \epsilon + \xi_i^* \end{cases}, \\ & \xi_i, \xi_i^* \geq 0, C > 0 \end{aligned} \quad (5)$$

여기서 C 는 학습의 에러와 모델의 복잡성을 조절(Trade Off)하기 위한 값이며, 함수 $f(x)$ 의 평평함(Flatness)과 ϵ 의 허용한계 균형에 따라 결정된다. 또한 슬랙변수(Slack Variable) ξ_i, ξ_i^* 는 훈련데이터에 에러를 허용하기 위한 상·하한값이다. 그리고

ζ 는 손실함수(Loss Function)로서 다양한 형태의 손실 함수가 있으며 손실 함수에 따라서 볼록 최적화 문제의 해가 달라질 수 있다. 그 중 ϵ -insensitive loss function $|\zeta|_\epsilon$ 는 다음과 같이 나타 낼 수 있다.

$$|\zeta|_\epsilon = \begin{cases} 0 & \text{if } |\xi| \leq \epsilon \\ |\xi| - \epsilon & \text{if } |\xi| > \epsilon \end{cases} \quad (6)$$

ϵ 은 ϵ 마진(Margin)내에 있는 데이터에 있는 데이터에 대해 코스트(Cost)없이 에러를 허용한다. ϵ 값은 훈련데이터의 잡음(Noise)이나 형태에 따라 조정되어 질 수 있으며, 이 값에 따라 SVR의 출력함수를 구성하는 서포터벡터(Support Vector)의 개수에 영향을 준다. ϵ 값이 커지면 커질수록 서포터벡터 개수는 작아지며, 이 값은 C 값과 다른 형태로 모델의 복잡성에 영향을 준다. 식(5)의 최적화 문제를 해결하기 위하여 라그랑지안(Lagrangian)계수법을 도입하면 식(7)의 라그랑지안 함수가 되며, 목적함수(Object Function)와 제약조건으로 구성되는 이원문제(Dual Problem)인 식(8)로 나타낼 수 있다.⁹⁻¹⁴

$$L = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) - \sum_{i=1}^l \alpha_i (\epsilon_i + \xi - y_i + wx_i + b) - \sum_{i=1}^l \alpha_i^* (y_i + \epsilon_i + \xi_i^* - wx_i - b) - \sum_{i=1}^l (\zeta \xi_i + \zeta_i^* \xi_i^*),$$

$$\alpha_i, \alpha_i^*, \eta_i, \eta_i^* \geq 0 \quad (7)$$

$$\max - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) x_i x_j - \epsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*), \quad (8)$$

$$\text{subject to } \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0$$

$$\alpha_i, \alpha_i^* \in [0, C]$$

여기서 α_i, α_i^* 는 상·하한 라그랑지안 승수(Lagrangian Multipliers), ζ, ζ_i^* 상·하한 손실함수.

식(7)의 최적해를 구하고, 가중치 벡터 \bar{w} 을 구하면 식(9)가 되고, 최적의 값 \bar{b} 는 Karush-Kuhn-Tucker 조건에 의해 구하면 식(10)이 된다. 그리고 식(9)와 식(10)을 식(4)에 대입하여 다시 정리하면 식(11)같이 SVR의 출력을 구할 수 있다.

$$\bar{w} = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i \quad (9)$$

$$\bar{b} = y_i - \bar{w} x_i - \epsilon \quad \text{for } \alpha_i \in (0, C) \quad (10)$$

$$\bar{b} = y_i - \bar{w} x_i + \epsilon \quad \text{for } \alpha_i \in (0, C)$$

$$f(x, w) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i^T x) + \bar{b} \quad (11)$$

여기서 $(\bar{\quad})$ 는 계산된 최종 값들을 의미한다.

식(11)에서 $K(x_i^T x)$ 는 커널함수(Kernel Function)로써 입력데이터를 입력 공간보다 더 높은 차원의 자질공간(Feature Space)으로 사상하는 것이며, 차원이 높은 자질공간에서의 선형 근사화 후 차원이 낮은 공간으로 다시 사상하면 비선형 근사화를 할 수 있다. 그 관계를 Fig. 1에 보였다. 커널 함수에는 식(12)와 같은 것들이 있다.⁹⁻¹⁴

$$\text{Linear Kernel: } K(x_i, x) = x_i^T x,$$

$$\text{RBF Kernel: } K(x_i, x) = \exp(-\|x - x_i\|^2 / \sigma^2) \quad (12)$$

3. SVR을 이용한 자속 추정기

SVR을 이용한 자속 추정기는 두개의 자속 모델 즉, 전압모델, 전류모델을 기본으로 한다. SVR의 훈련데이터 x_i 는 전동기 운전상황에 따라 심하게 전동기 파라미터 $L_m, L_r/R_r$ 이 가변하여 고속영역에서 정확한 자속추정이 어려운 식(3)의 전류모델 자속 λ_{dq}^s 로 정하였고, 목표값 y_i 는 비교적 전동기 파라미터가 실제 제어특성에 많은 영향을 주지 않는 식(2)의 전압모델 자속 λ_{dq}^{*s} 로 하여, $\{(\hat{\lambda}_{dqri}^s, \lambda_{dqri}^{*s}), i = 1, \dots, l\} \subset X \times R$ 같이 구성하였

다. 추정된 $\hat{\lambda}_{dqr}^s$ 자속은 w_r 정보가 포함된 λ_{dqr}^s 과 w_r 정보가 포함되지 않은 λ_{dqr}^{*s} 로부터 최고 ϵ 편차 내에 있으며 가능한 작은 크기의 가중치 벡터 w 값을 갖는 식(13)과 같은 자속을 추정하는 것이다. Fig. 2 는 SVR 자속추정기의 구조를 설명한 그림이다.

$$\hat{\lambda}_{dqr}^s = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(\lambda_{dqr}^s, \lambda_{dqr}^s) + \bar{b} \quad (13)$$




Fig. 1 A feature map from input space to higher dimensional feature space




Fig. 2 Structure of flux observer using SVR

3.1 파라미터 C, ϵ 설정

식(7)에서 해를 구하기 위해서는 C 와 ϵ 값의 설정이 필요하다. C 와 ϵ 값은 시스템이나 훈련데이터의 노이즈와 같은 사전 지식에 따라 사용자가 설정하여야 한다. 파라미터 C 는 학습의 예러와 모델의 복잡성을 조절(Trade Off)하기 위한 값이며,

함수 $f(x)$ 의 평평함(Flatness)과 ϵ 의 허용한계 균형에 따라 결정된다. C 의 값을 적게 설정하면 Fig. 3에서 보는바와 같이 노이즈 데이터에 덜 민감함을 알 수 있다. 이와는 반대로 C 의 값을 크게 설정할 경우 Fig. 4와 같이 보다 많은 노이즈 데이터가 포함되어 학습 예러는 줄어들지만 모델의 복잡성을 증가 시킨다. 따라서 C 와 ϵ 를 적절하게 선택하는 방법이 필요할 것이다.¹⁴

앞에서 언급한 파라미터 중 C 를 적절하게 선택하는 상당히 어려운 문제이다. SVR에 관련된 상당히 많은 연구가 진행되었고 또 진행 중에 있으나 명확한 선정방법은 아직까지 보이지 않고 있다. 따라서 본 논문에서는 파라미터 C 선정을 위한 새로운 방법을 제안 한다. 본 연구에서는 손실함수 식(6)을 사용하였는데, 이 경우 추정된 결과의 대부분은 식(13)의 바이어스 항 \bar{b} 에 나타난다. 따라서 좌변의 추정된 값 $\hat{\lambda}_{dqr}^s$ 과 \bar{b} 가 예러를 최소화 하는 조건은 식(13)의 첫 번째 항 $\sum_{i=1}^l (\alpha_i - \alpha_i^*) K(\lambda_{dqr}^s, \lambda_{dqr}^s)$ 을 최소로 되게 하면 될 것이다. 따라서 본 논문에서는 식(13)의 가중치 벡터 부분 중 $\alpha - \alpha^*$ 를 C 라 가정하고, 바이어스 항을 제거하면 식(13)은 식(14), 식(15)와 같이 나타낼 수 있다.

$$\hat{\lambda}_{dqr}^s = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(\lambda_{dqr}^s, \lambda_{dqr}^s) \quad (14)$$

$$\hat{\lambda}_{dqr}^s = \sum_{i=1}^l C \lambda_{dqr}^s \quad (15)$$

여기서 $\hat{\lambda}_{dqr}^s$:SVR 출력, λ_{dqr}^s :SVR 입력이다. 따라서 파라미터 C 는 식(15)를 식(16)과 같이 다시 나타내고 이 식을 통해서 구할 수 있다.

$$\max C = \frac{\hat{\lambda}_{dqr}^s}{\lambda_{dqr}^s} \quad (16)$$

본 연구에서는 기준자속을 $\lambda_{\omega}^s = 0.4 [Wb]$ 로 설정하였다. SVR 추정기를 통해서 입출력되는 자

속 또한 $0.4[Wb]$ 의 범위를 크게 벗어나지 않을 것이므로 C 를 최대 1로 설정하였다. 그리고 ϵ 값은 손실을 최소화 하도록 $\epsilon = 0.001$ 로 두고 실험을 하였다.




Fig. 3 Insensitive band for a one dimensional regression with small parameter C




Fig. 4 Insensitive band for a one dimensional regression with large parameter C

3.2 Optimization problem

SVR의 Linear Quadratic Programming(LQP)문제를 해결하기 위해 Interior Point Method를 C 코드로화해서 적용하였다. Fig. 5는 처리과정을 설명한 흐름도이다.¹¹⁻¹²

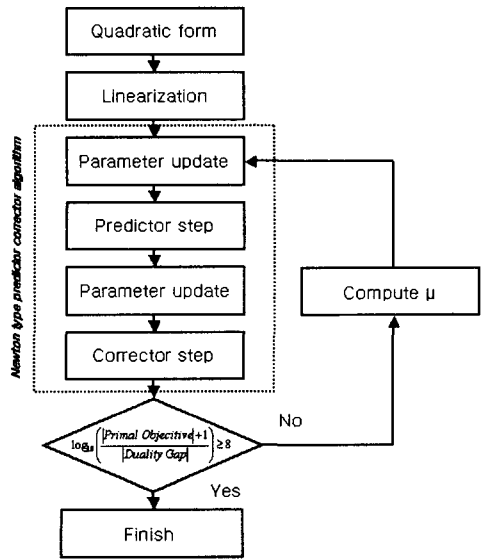


Fig. 5 Flowchart of interior point method for optimization

4. 모의실험

4.1 실험조건

자속의 변화를 관찰하고 성능을 비교하기 위해서는 기준이 되는 자속 추정기가 필요하다. 비교적 실제자속과 일치하다고 알려져 있으며, 운전 조건에 따라 전동기 파라미터의 변화, 오차 그리고 전압오프셋 등에 강인하다고 알려져 있는 Gopinath⁶⁻⁷ 모델을 통해 구해낸 자속값을 비교의 기준으로 삼았다. 모의실험을 위한 전체 제어시스템의 블록도는 Fig. 6과 같다. 전체시스템의 구성에서 w_r^* , w_r 은 기준속도 및 측정된 속도, λ_{dr}^* , λ_{dr}^e 는 동기좌표계 d 축 기준자속 및 추정자속, i_{dqsr}^* , i_{dqsr}^e 는 동기좌표계 d, q 축 기준전류 및 측정된 전류, v_{dqsr}^* , v_{dqsr}^e 는 동기좌표계 d, q 축 기준전압, v_{abcs}^* , v_{abcs}^e 는 기준상전압 및 상전압 그리고 i_{abcs}^* 는 측정된 상전류를 각각 의미하며, 속도제어기, 전류제어기, 자속제어기 그리고 제한된 SVR자속 추정기와 PWM발생부 등으로 구성된다. 자속추정은 Fig. 2에서 보는바와 같이 전동기 고정자 전압, 전류를 기본으로 하여 식(2), (3)을 이용하여 기준자속 λ_{dqr}^{*s} 과 혼련자속 λ_{dqr}^s 을 구한다. SVR자속추

정기는 λ_{dqr}^{*s} 과 λ_{dqr}^s 로부터 최고 ϵ 편차 내에 있으며 가능한 작은 크기의 가중치 벡터 w 값을 갖는 자속 $\hat{\lambda}_{dqr}^s$ 를 추정한다. 벡터제어(Vector Control)를 위해 필요한 회전자 자속각 $\hat{\theta}_e$ 은 식(1)을 다시 정리한 식(17)로부터 구할 수 있다.

$$\hat{\theta}_e = \tan^{-1}(\hat{\lambda}_{qr}^s / \hat{\lambda}_{dr}^s) \quad (17)$$

모의실험에 사용된 벡터제어시스템 및 유도전동기의 상세사양은 Table 1과 같다.

모의실험은 정상상태 가정을 위해 일정속도를 유지한 상태에서 Fig. 14(b)와 같은 부하(5N-m)와 회전자 저항변동($\hat{R}_r = 1.4R_r$)을 고려하고 실험하였다. 각 속도 영역에서의 자속 추정성능을 확인하기 위해 저속, 중속, 고속 영역을 각각 일정속도 70r/min, 170r/min 그리고 1500r/min으로 설정하였다. 저속영역은 자속추정기의 차단주파수보다 낮은 영역으로 100r/min 미만으로 하였고, 중속영역은 전류모델과 전압모델이 혼합되는 차단주파수 부근에서 부하상황에 따른 슬립주파수를 고려하여 170r/min 중속영역으로 정하였다.⁴ 그리고 전압모델이 지배적인 고속영역은 1200r/min 이상으로 실험 하였다. 과도상태 시 자속추정기 특성을 확인하기 위해 속도를 1500-170-1500r/min 순서로 가감속하면서 과도상태 추정오차를 살펴보았다.




Fig. 6 Block Diagram of Field Oriented Control system using SVR Flux Observer

Table 1 Main specifications used in simulation

구분	사양
전류제어기	<ul style="list-style-type: none"> 제어주기: 10kHz(100μsec) 주파수대역: 942[rad/sec]
속도제어기	<ul style="list-style-type: none"> 제어주기: 250Hz(4msec) 주파수대역: 63[rad/sec]
자속제어기	<ul style="list-style-type: none"> 제어주기: 250Hz(4msec) 주파수대역: 31.4[rad/sec] 기준자속: $\lambda_{dr}^e = 0.4$ [Wb]
PWM	<ul style="list-style-type: none"> 스위칭주기: 5kHz(200μsec) VDC: 300V
전동기	<ul style="list-style-type: none"> 정격출력: 5Hp 정격주파수, 전압: 60Hz, 220V 극수: 4극 정격전류: 12A $R_s = 0.55 \Omega, R_r = 0.36 \Omega,$ $L_{ls} = 1.8mH, L_{lr} = 1.8mH,$ $L_m = 59mH,$ $J_{M+L} = 0.04kg - m^2$
SVR 자속추정기	<ul style="list-style-type: none"> $C = 1, \epsilon = 0.001$

4.2 모의 실험결과

모의 실험시 파라미터 변화에 따른 추정오차의 변화를 알아 보기위해 전류모델의 오차에 직접영향을 끼치는 회전자저항 값의 변화 및 부하의 인가를 통해 확인한 결과 전반적으로 제안된 추정기의 성능이 양호한 결과를 보인다. Fig. 7, 8 에서 보는바와 같이 저속에서 두 추정기 추정오차는 거의 없었다. 그러나 Gopinath모델은 중속에서 고속영역까지 부하 관계없이 자속추정오차가 나타나며 부하를 인가하면 추정오차가 더욱 크게 나타남을 Fig. 9-12 을 통해서 알 수 있었으며, Gopinath 모델은 부하와 회전자저항이 증가되면 자속추정오차 더욱 커진다는 것을 모의실험과 Gopinath 모델을 분석한 앞선 연구결과^{4, 6-7}를 확인할 수 있었다. 제안한 SVR 자속 추정기의 정상 상태 성능은 전 속도 영역에서 기준자속을 잘 추종함을 확인하였다.

과도상태 자속추정 성능은 벡터제어의 순시적 토크제어를 수행하는데 매우 중요하다. 모의실험에서는 170r/min에서 1500r/min까지 가감속하는 속도제어를 통해서 부하가 인가되어 있는 상태에서

회전자 저항이 변화할 때의 속도, 자속 그리고 토크전류의 상태를 확인 하였다. 그 결과 Fig. 13, 14에서와 같이 제안된 자속 추정기는 과도 상태의 파라미터 변동에도 강인하게 동작하는 것을 확인하였다.




Fig. 7 Rotor flux estimation errors with No-load, 70 rpm (a) λ_{dr}^s (b) λ_{dr}^e

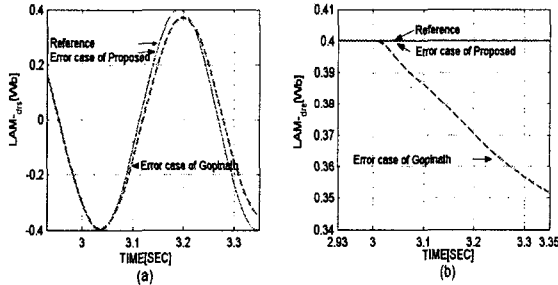


Fig. 8 Rotor flux estimation errors with 5N-m load, 70 rpm (a) λ_{dr}^s (b) λ_{dr}^e




Fig. 9 Rotor flux estimation errors with No-load, 170 rpm (a) λ_{dr}^s (b) λ_{dr}^e




Fig. 10 Rotor flux estimation errors with 5N-m load, 170 rpm (a) λ_{dr}^s (b) λ_{dr}^e




Fig. 11 Rotor flux estimation errors with No-load, 1500 rpm (a) λ_{dr}^s (b) λ_{dr}^e

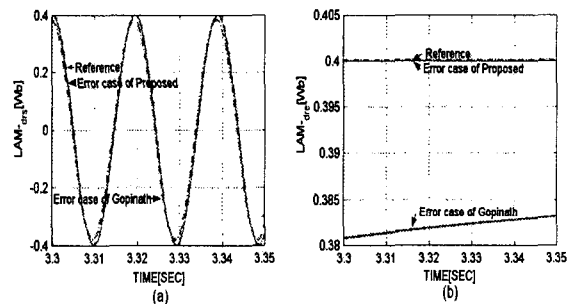


Fig. 12 Rotor flux estimation errors with 5N-m load, 1500 rpm (a) λ_{dr}^s (b) λ_{dr}^e




Fig. 13 Velocity and Rotor flux estimation errors with 5N-m load, 1500-170-1500 rpm (a) $WRPM$ (b) λ_{dr}^s (c) λ_{dr}^c

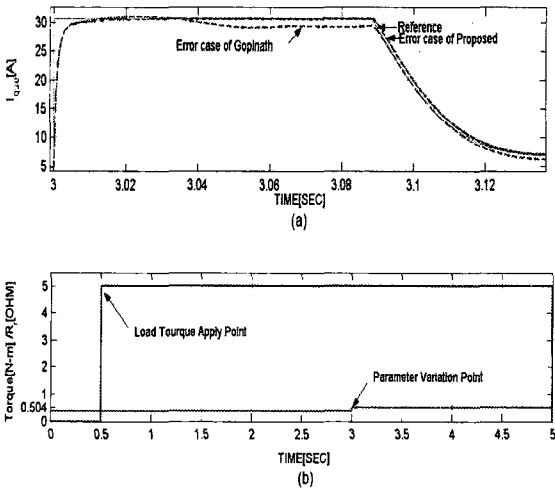


Fig. 14 Torque current with load and parameter variation, 1500-170-1500 rpm (a) i_{qs}^c (b) Torque and R_r

5. 결론

본 논문에서는 회전자 자속추정기로 잘 알려진 전압 및 전류모델과 SVR을 결합한 새로운 추정기법을 이용해서 전동기의 상수변화에 강인한 회전자 자속 추정 기법을 제안하였다. 제안된 기법의 자속의 변화를 관찰하고 성능을 비교하기 위해서 파라미터의 변화, 오차 그리고 전압 읍셋 등에 강인하다고 알려져 있는 Gopinath 모델을 통해 구해낸 자속값을 비교의 기준으로 삼고 정상상태의 저속, 중속 그리고 고속영역에서 파라미터 변화시의 추정 성능을 Gopinath 모델과 비교하였다. 그리고 벡터제어의 순시적 토크제어를 위한 과도상태시의 동적특성과 정상상태 특성을 고려한 자속추정을 하였다. 그 결과 제안된 SVR자속 추정기의 정상 상태 성능은 전 속도 영역에서 기준자속을 잘 추종함을 확인하였다. 그리고 과도상태 자속추정 성능 또한 양호하게 벡터제어를 수행하였다.

후기

이 논문은 2003학년도 영남대학교 학술연구조성비 지원에 의한 것임.

참고문헌

1. Takhasi, Isao and Noguchi, Toshihiko, "A New Quick-Response and High-Efficiency Control Strategy of an Induction Motor," IEEE Trans, Ind. Appl., Vol. IA22, No. 5, pp. 820-827, Sep./Oct., 1986.
2. Hori, Yoichi and UmeNo, Takaji, "Implementation of Robust Flux Observer based Field Orientation(FOFO) Controller for Induction Machines," Conf. Rec. of IEEE Industry Applications Society Annual Meeting, pp. 523-528, 1989.
3. Kubota, Hisao, Matsuse, Kouki and NakaNo, Takayoshi, "New Adaptive Flux Observer of Induction Motor for Wide Speed Range Motor Drives," IEEE, IECON90, pp. 921-926, 1990.
4. Kim, J. H., "Novel Rotor Flux Observer Using Observer Characteristic Function in Complex

- Vector Space for Field Oriented Induction Motor Drives," Seoul National University M.S Thesis, 2001.
5. Ohtani, Tsugtoshi, Takada, Noriyuki and Tanaka, Koji, "Vector Control of Induction Motor without Shaft Encoder," IEEE Trans, Ind. Appl., Vol. 28, No. 1, pp. 157-164, Jan./Feb., 1992.
 6. Jansen, Patrick L. and Lorenz, Robert D., "A Physically Insightful Approach to the Design and Accuracy Assessment of Flux Observer for field Oriented Induction Machine Drives," IEEE Trans, Ind. Appl., Vol. 30, No. 1, pp. 101-110, Jan./Feb., 1994.
 7. Jansen, Patrick L., Lorenz, Robert D. and Novotny, Donald W., "Observer-Based Direct Field Orientation: Analysis and Compensation of Alternative Methods," IEEE Trans, Ind. Appl., Vol. 30, No. 4, pp. 945-953, Jul./Aug., 1994.
 8. Kim, Y. R., Sul, S. K. and Park, M. H., "Speed Sensorless Vector Control of Induction Motor Using Extend Kalman Filter," IEEE Trans. Ind. Appl., Vol.30, pp.1225-1233, 1994.
 9. Vapnik, V., "The Nature of Statistical Learning Theory 2nd," Springer, 1999.
 10. Cherkassky, V. and Mulier, F., "Learning from Data: Concepts, Theory, and Methods," John Wiley & Sons, 1998.
 11. Gunn, S., "Support Vector Machines for Classification and Regression," ISIS Technical Report, U. of Southampton, 1998.
 12. NELLO CRISTIANINI AND JOHN SHAWE-TAYLOR, "An Introduction to Vector Machines and other kernel-based learning methods," CAMBRIDGE university press, 2000.
 13. Smola, A. and Schölkopf, B., "A Tutorial on Support Vector Regression," Technical Report NC2-TR-1998-030, NeuroCOLT2, 1998.
 14. Cho, Kyung_Rae, Seok, Jul-Ki and Lee, Dong Choon, "Mechanical Parameter Identification of Servo Systems using Support Vector Regression," PESC, pp.588-593, 2004.