

Support Vector Regression을 이용한 서보 시스템의 기계적 상수 추정

조경래*, 석줄기, 이동춘
영남대학교

Mechanical Parameter Identification of Servo Systems using Robust Support Vector Regression

Kyung-Rae Cho*, Jul-Ki Seok and Dong-Choon Lee
Yeungnam University

ABSTRACT

The overall performance of AC servo system is greatly affected by the uncertainties of unpredictable mechanical parameter variations and external load disturbances. Therefore, to compensate this problem, it is necessary to know different parameters and load disturbances subjected to position/speed control. This paper proposes an online identification method of mechanical parameters/load disturbances for AC servo system using Support Vector Regression (SVR). The proposed methodology advocates analytic parameter regression directly from the training data, rather than adaptive controller and observer approaches commonly used in motion control applications. The experimental results demonstrate that the proposed SVR algorithm is appropriate for control of unknown servo systems even with large measurement noise.

1. 서 론

최근의 산업용 서보 구동 응용 분야에서는 전 운전 영역에서 위치 추종에 대한 높은 정밀도와 빠른 응답 특성이 요구된다. 이와 같은 위치 추종에 대한 속응성과 정밀도의 문제는 속도 제어기의 특성과 연관지어 고려해야만 한다. 속도 제어기의 응답 특성은 속도 제어기의 이득(gain) 설정과 속도 제어기의 형태에 절대적으로 의존한다. 이때 속도 제어기의 이득의 설정을 위해서는 부하를 포함한 시스템의 전체 관성을 정확히 알 필요가 있다. 특히 물체를 운반하는 다관절 로봇의 경우 부하 관성이 실시간으로 변동되므로 이러한 시스템에 대한 고성능 속도 제어기의 설계를 위해서는 속도 제어기의 이득 또한 실시간으로 조정해 주어야만 한다. 부하 토크는 시스템의 속도 응답 특성을 나쁘게 하여 위치 추종에 대한

빠른 응답 특성과 높은 정밀도를 기대하기 어렵게 만든다. 이런 경우 정확한 부하 토크를 알 수 있다면 토크 전향 제어(feed forward control)을 통하여 보상할 수 있다. 마찰은 기계적인 시스템에서는 피할 수 없는 가장 대표적인 비선형적인 요소이다. 고 정밀도 위치 추종을 요구하는 서보 시스템에서 저속 영역의 마찰은 제어 성능을 심각하게 악화시킬 수 있으며 이를 보상하기 위해서는 정확한 마찰 계수를 알 필요가 있다. 특히 마찰 계수가 큰 시스템에서 정확히 마찰 계수를 추정하면 제어 성능을 향상시킬 수 있다 [1].

지금까지는 넓은 속도 영역에서 고성능 속도 제어를 위해서 관성, 마찰력 및 부하 토크의 변화를 외란으로 간주하고 외란 관측기를 이용하여 기계적 상수와 부하 토크를 추정하고 제어기 이득을 조정해 주었다 [2]. 그러나 이러한 기계적 상수와 부하 토크 변화를 제어기에 이용하기 위해서는 외란 관측기의 시정수가 작아야만 한다. 그러나 관측기의 시정수를 너무 작게 설정하면 외란 관측기가 불안정해질 수 있고, 속도 정보가 정확치 않은 저속영역이나 잡음 환경 하에서 속도 미분 값 등을 사용하여 기계적 상수와 부하 토크를 추정하게 되면 부정확한 추정 결과를 초래할 수 있다. 또한 외란 관측기들 중의 일부는 추정하고자 하는 기계적 상수 이외의 상수 값은 정확히 알고 있다거나 거의 변하지 않는다고 가정하여 모델을 간략화하는 문제점이 있다 [3].

본 논문에서는 최근 학습 알고리즘으로 널리 쓰이고 있는 SVM (Support Vector Machines)을 이용하여 산업용 서보 시스템의 기계적 상수와 부하 토크를 추정하고자 한다. SVM은 Vapnik에 의해 고안된 VC이론을 기반으로 명확한 수학적 이론에 근거하며 [4-5], SVM의 성능은 다른 학습 알고리즘에 비해 뛰어난 것으로 알려져 있다. 최근 SVM은 Classification [6-7], Time Series Prediction [8], Regression [9-10]의 다양한 분야에 성공적으로 사용되어지고 있는데, 특히 SVM이 추정 (Regression Estimation) 알고리즘으로 사용될 때 SVR(Support Vector Regression)이라 한다 [8-10].

제안된 SVR 알고리즘은 서버 시스템에 구현되어져 온라인 데이터로부터 기계적 상수를 추정한다. 제안된 추정 방법의 타당성을 검증하기 위하여 400[W]급 서버 모터를 대상으로 다양한 실험을 수행하였다.

2. Support Vector Regression

훈련데이터 $\{(x_i, y_i), i = 1, \dots, N\}, x \in R^m, y \in R$ 이 주어졌다고 가정 한다. 여기서 N 은 훈련데이터의 개수, x 는 입력 벡터, y 는 출력데이터를 나타낸다. 모든 훈련데이터에 대해서 실제 목표 값 y_i 들로부터 최고 ϵ (무감각 모수, Insensitive Parameter) 만큼의 편차 내에 있으며 가능한 작은 크기의 θ 값을 갖는 다음과 같은 함수가 SVR의 출력이다.

$$f(x, \theta) = \theta^T \Phi(x) + b \quad (1)$$

여기서 $\Phi(\cdot)$ 은 입력데이터의 차원 R^m 에서 더 높은 차원의 자질 공간(Feature Space)으로 사상시키는 비선형 함수이고, θ 는 가중치 벡터(Weight Vector), b 는 바이어스이다. 가장 작은 크기의 θ 를 구하기 위해 입력 데이터로부터 다음과 같은 볼록 최적화(Convex Optimization) 문제를 구성 할 수 있다.

$$\text{minimize } \frac{1}{2} \|\theta\|^2, \quad (2)$$

$$\text{subject to } |y_i - \theta^T x_i - b| \leq \epsilon$$

여기서 기본 가정은 볼록 최적화 문제의 해결이 가능하다는 것이다. 그러나 가끔 훈련데이터의 에러 때문에 이 가정이 성립되지 않는 경우가 있다. 따라서 이를 해결하기 위해 새로운 slack 변수 ξ, ξ^* 를 도입하여 Vapnik이 제안한 최적화 문제에 적용시키면 다음과 같은 최적화 문제로 확장시킬 수 있다 [4].

$$Q(\theta, \xi, \xi^*) = \frac{1}{2} \|\theta\|^2 + C \left(\sum_{i=1}^N \zeta(\xi_i) + \sum_{i=1}^N \zeta(\xi_i^*) \right)$$

subject to

$$y_i - (\theta^T \Phi(x) + b) \leq \xi_i^* + \epsilon \quad (3)$$

$$(\theta^T \Phi(x) + b) - y_i \leq \xi_i + \epsilon$$

$$\xi_i, \xi_i^* \geq 0 \quad i = 1, \dots, N$$

여기서 C 는 학습 에러와 모델의 복잡성을 조절 (trade-off)하기 위한 값이며, slack 변수 ξ, ξ^* 는 훈련 데이터에 에러를 허용하기 위한 값이다. ζ 는 손실 함수(Loss Function)으로서 다양한 형태의 손실 함수가 있으며, 손실 함수에 따라 볼록 최적화 문제의 해가 달라질 수 있다. ϵ 은 ϵ 마진 내에 있는 데이터에 대해 Cost없이 에러를 허용한다. ϵ 값은 훈련데이터의 잡음(Noise)이나 형태에 따라 조정되어 질수 있으며, 이 값에 따라

SVR의 출력함수를 구성하는 Support Vector의 개수에 영향을 준다. 식 (3)처럼 볼록 최적화 문제가 2차식으로 표현되는 문제를 Quadratic Programming이라고 하며 이 Quadratic Programming 계산하기 위해 본 논문에서는 LOQO [Vanderbei 97]을 사용했다.

이 최적화 문제는 쌍대 문제(Dual Problem)로 바꿀 수 있으며[3-4], 쌍대 문제의 해를 이용하면 SVR의 출력 함수는 다음과 같이 주어진다.

$$f(x, \theta) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) (\Phi(x_i) \cdot \Phi(x)) + b \quad (4)$$

subject to

$$0 \leq \alpha_i^* \leq C, 0 \leq \alpha_i \leq C$$

식 (4)에서 자질 공간에서 내적 $(\Phi(x_i) \cdot \Phi(x))$ 은 커널 함수(Kernel Function) $K(x_i, x)$ 로 생각할 수 있다. 함수 근사에 사용되는 커널 함수에는 다음과 같은 것들이 있다.

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

$$\text{Polynomial kernel of degree } d : \quad (5)$$

$$K(x_i, x) = (x^T x_i + 1)^d$$

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

이 커널 함수의 역할은 입력데이터를 입력 공간보다 더 높은 차원의 자질 공간으로 사상하는 것이며, 차원이 높은 자질 공간에서의 선형 근사한 후 차원이 낮은 입력 공간으로 다시 사상하면 비선형 근사를 할 수 있다. 그 관계를 그림 1에 보였다.




그림 1 입력 공간에서 고차원 자질 공간으로의 사상

3. SVR을 이용한 기계적 상수 추정

일반적으로 서버 시스템의 기계 방정식은 다음과 같이 주어진다.

$$T_e(t) = J_m \frac{dw_m(t)}{dt} + B_m(t)w_m(t) + T_L \quad (6)$$

여기서 $T_e(t)$ 는 전동기 토크, $w_m(t)$ 는 전동기 회전자의 기계적 각속도이며, $J_m(t)$ 는 전체 시스템의 관성, $B_m(t)$ 는 마찰 계수 그리고 T_L 은 부하 토크이다. 실제 시스템에 있어 부하 토크는 시스템의 시정수 내에서는 변하지 않는다고 볼 수 있다. 따라서 이 기계 방정식을

식(1)의 형태로 새로 구성하면 다음과 같다.

$$y = T_e(t) \quad (7)$$

$$x = \left[\frac{dw_m}{w_m} w_m \right] \quad (8)$$

$$\theta^T = [J_m(t) B_m(t)] \quad (9)$$

$$b = T_L \quad (10)$$

Quadratic Loss Function을 사용하면 볼록 최적화 문제는 다음과 같은 함수를 최소화 하는 문제로 바뀐다.

$$W(\alpha_i, \alpha_i^*) = \frac{1}{2} \sum_{i,j=1}^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j) - \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) + \frac{1}{2C} \sum_{i=1}^N (\alpha_i^2 - \alpha_i^{*2}) \quad (11)$$

식 (11)의 함수를 최소화하는 라그랑지안 계수 $\alpha_i, \alpha_i^*, i = 1, \dots, N$ 를 찾으면 θ 와 b 는 다음과 같이 쓸 수 있다.

$$\theta^T x = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x_i, x) \quad (12)$$

$$b = \text{mean} \left\{ y_i - \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x_i, x) \right\} \quad (13)$$

3. C값과 Loss Function의 선정

SVR에서 C와 ϵ 값은 시스템이나 훈련데이터의 노이즈와 같은 사전 지식에 따라 사용자가 설정해야 한다. 그러나 전문가가 아닌 사용자가 C와 ϵ 값을 설정하는 것은 쉽지 않다. 따라서 본 논문에서는 비전문가도 쉽게 사용할 수 있도록 ϵ 값을 설정해야 하는 ϵ -Insensitive Loss Function 대신에 ϵ 값을 설정할 필요가 없는 Quadratic Loss Function을 사용한다.

C값은 모델의 복잡성을 결정하는 요소이다. C값이 크면 학습 에러를 줄여주고 모델은 복잡하게 결정된다. 반대로 C값이 작으면 학습 에러는 커지고 모델은 단순하게 결정된다. 따라서 입력데이터에 outlier가 크게 들어온다면, C값이 클 때 일반화의 어려움이 커지게 되고, 반대로 outlier가 거의 들어오지 않는데도 불구하고 C값을 작게 설정한다면 일반화의 어려움이 커지게 된다. 그러므로 C값의 결정은 모델의 사전 정보에 의해 결정해야만 일반화의 성능을 높일 수 있다. 본 논문에서는 최대 마찰 정보를 이용하여 C값을 입력데이터에서 유일하게 결정할 수 있는 방법을 제시한다.

주어진 식 (8), (9), (12)에 의해 마찰은 다음과 같이 계산된다.

$$\hat{B}_m = \sum_{i=1}^N w_{mi} \cdot \beta_i \quad (14)$$

실제 서보 시스템에서 마찰은 정격토크의 50%를 넘지 않는다. C값은 $|\beta|$ 의 최대 값이므로 SVR에 의해 계산되어지는 마찰이 최대 마찰 토크를 넘을 수 없도록 C값을 선정함으로써 outlier의 영향을 줄일 수 있다.

$$B_{\max} = \sum_{i=1}^N w_{mi} \cdot \beta_{\max i} = \sum_{i=1}^N w_{mi} \cdot C_i \quad (15)$$

이 때 C값은 상수이어야 함으로 평균값을 사용함으로써 입력데이터로부터 자동적으로 결정되어진다.

$$C = \frac{B_{\max}}{\left(\sum_{i=1}^N w_{mi} \right) / N} \quad (16)$$

4. 실험 결과

제안된 방법의 타당성을 검증하기 위하여 서보 구동 장치에 SVR 알고리즘을 구현하고 220[V], 400[W]급 서보 전동기에 대하여 실험을 수행 하였다. 전동기 자체 관성 계수는 $3.6e-5 \text{ kgm}^2$, 마찰 계수는 매우 작으며, 부하 토크는 인가하지 않았다. 자체관성의 5배에서 20배까지 다양한 부하 관성을 모터에 연결하여 실험을 수행하였다.

서보 구동 장치의 CPU는 120MHz 클럭으로 동작하는 TMS320VC33 DSP를 사용하였으며 온라인 SVR 알고리즘은 속도 지령이 변할 때 1.4msec 마다 샘플링하여 10개의 샘플로 Linear Kernel을 사용하여 관성 계수, 마찰 계수, 부하 토크를 추정한다. 속도 정보를 위해 전동기 측에 1024p/r의 분해능을 가지는 엔코더를 연결하였다,




그림 2 5배 부하 관성에 대한 실험 결과 (초기J=1/5Jm)




그림 3 20배 부하 관성에 대한 실험 결과 (초기 $J=1/5J_m$)




그림 4 볼 스크류에 대한 기계적 상수 추정 실험 결과

속도의 미분은 오일러 방정식을 이용해 간단히 구하였다. 잘 알려져 있듯이 속도의 미분은 작은 잡음에 의해서도 쉽게 왜곡될 수 있으며 그림 2와 3의 속도 미분 파형에서 확인할 수 있다. 그러나 SVR 알고리즘은 이런 잡음에 의해 속도와 속도 미분의 정보가 왜곡됨에도 불구하고 훌륭한 성능을 발휘한다.

그림 2와 3은 초기에 부하 관성의 20%로 관성 값을 잘못 알고 있다고 가정하여 속도 제어기 이득을 계산하였다. 0rpm~1000rpm 스텝 지령에 대한 속도 응답과 표시된 시점에서 SVR 알고리즘에 의하여 전체 관성을 추정하여 속도 제어기의 이득을 보상한 후의 속도 응답, 추정된 기계적 상수 및 부하 토크를 보이고 있다. 속도 응답을 보면, 보상 전 약 100rpm의 오버 슈트가 보상 후

에는 오버 슈트가 거의 없으며, 이 때 추정된 관성 계수가 나타나 있고, 마찰과 부하 토크는 매우 작으므로 0 근처에서 수렴하고 있다.

또 마찰이 큰 시스템인 볼 스크류에 대하여 추정 실험을 수행하였다. 그림 4에서 보는 바와 같이 SVR 알고리즘이 동작함에 따라 관성 계수, 마찰 계수가 빠르게 수렴해 감을 볼 수 있다. 여기서 부하 토크는 인가하지 않았으므로 추정된 부하 토크는 0Nm 근처에서 수렴하고 있다.

5. 결론

본 논문에서는 SVR 알고리즘을 사용하여 서보 시스템의 기계적인 상수 및 부하 토크를 온라인으로 추정하는 방법을 제안하였다. 제안된 방법은 속도 지령이 변할 때 마다 SVR 알고리즘을 수행하여 전동기의 기계적 상수와 부하 토크를 성공적으로 추정하였다. 제안된 추정 방법의 타당성을 검증하기 위하여 400[W]급 서보 전동기를 대상으로 다양한 실험을 수행하였다.

이 논문은 2003년도 한국학술진흥재단의 지원에 의하여 연구되었음.(KRF-2003-041-D0024)

참고 문헌

- [1] Honglu Du, Satish S. Nair, "Low Velocity Friction Compensation", *IEEE Trans. Contr. Syst. Mag.*, vol.18, pp.61-69, 1998.
- [2] Ichiro Awaya, Yoshiki Kato, Iwao Miyake, and Masami Ito, "New Motion control with Inertia Identification Function using Disturbance Observer", *Proc. of IECON'92*, vol. 1, pp.77-81, 1992.
- [3] K. B. Lee, J. H. Song, I. Choy, and J. Y. Yoo, "An Inertia Identification using ROELO for Low Speed Control of Electric Machine", in *Proc. IEEE APEC*, vol.2, pp.1052-1055, 2003.
- [4] V. Vapnik, *The Nature of Statistical Learning Theory 2nded.*, Springer, 1999.
- [5] V. Vapnik, *Statistical Learning Theory*. New York:Wiley, 1998.
- [6] B. Schölkopf *et al.*, "Comparing support vector machines with Gaussian kernels to radial basis function classifier," *IEEE Trans. Signal Processing*, vol.45, pp.2758-2765, 1997.
- [7] B. Boser, I. Guyon, and V. Vapnik, "A training algorithm for optimal margin classifiers," presented at the 5th Annual Workshop Comput. Learning Theory, 1992.
- [8] S. Mukherjee, E. Osuna, and F. Girosi, "Nonlinear prediction of chaotic time series using a support vector machine," in *Proc. NNSP*, pp.24-26, 1997.
- [9] H. Druker *et al.*, "Support vector regression machines," *Int. Neural Information Processing Systems*. Cambridge, MA:MIT Press, vol.9, 1997.
- [10] A. J. Smola and B. Schölkopf, "A tutorial on support vector regression," Royal Holloway College, London, U.K., Neuro COLT Tech. Rep. TR-1998-030, 1998.