

Support Vector Regression을 이용한 서보 시스템의 기계적 상수 추정

조 경 래, 석 줄 기, 이 동 춘
 영남대학교 전자정보공학부

Mechanical Parameter Identification of Servo Systems using Robust Support Vector Regression

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

Abstract - 서보 시스템의 전체 제어 성능은 기계적 상수의 변화와 부하 토크의 영향을 크게 받는다. 그러므로 서보 시스템의 성능을 향상시키기 위해서는 기계적 상수와 부하 토크를 정확히 알 필요가 있다. 본 논문에서는 Support Vector Regression (SVR)을 이용한 기계적 상수와 부하 토크의 추정 알고리즘을 제안한다. 여기서 제안된 추정 알고리즘인 SVR은 통계적인 학습 이론을 기반으로 한 새로운 추정 알고리즘으로 적은 샘플, 비선형, 국부해의 문제를 극복하고 강력한 성능을 발휘한다. 실험 결과는 제안된 SVR 알고리즘이 기계적 상수와 부하 토크를 비교적 정확하게 추정하고 있음을 보여준다.

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 연관되어 고려해야 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 보상 할 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 사용하기 위해서는 외란 관측기의 시정수가 작아야만 한다. 그러나 관측기의 시정수를 너무 작게 설정하면 외란 관측기가 불안정해질 수 있고, 속도 정보가 정확히 않은 저속영역이나 잠음 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 값

은 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 서보 시스템에 구현되어져 온 라인 데이터로부터 기계적 상수를 추정한다. 제안된 추정 방법의 타당성을 검증하기 위하여 400[W]급 서보 모터를 대상으로 다양한 실험을 수행하였다.

2. Support Vector Regression

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

$$f(x, \theta) = \theta^T \Phi(x) + b \tag{1}$$

여기서 $\Phi(\cdot)$ 은 입력 데이터의 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.

$$\text{minimize } \frac{1}{2} \|\theta\|^2, \tag{2}$$

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

여기서 기본 가정은 볼록 최적화 문제의 해결이 가능하다는 것이다. 그러나 가끔 훈련 데이터의 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

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

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

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

여기서 C는 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 블록 최적화 문제의 해가 달라질 수 있다. ϵ 은 ϵ 마진 내에 있는 데이터에 대해 Cost없이 에러를 허용한다. ϵ 값은 훈련 데이터의 잡음(Noise)이나 형태에 따라 조정되어 질수 있으며, 이 값에 따라 SVR의 출력함수를 구성하는 Support Vector의 개수에 영향을 준다. ϵ 값이 커지면 커질수록 Support Vector의 개수는 작아지며, 이 ϵ 값은 C값과 다른 형태로 모델의 복잡성에 영향을 준다. 식 (3)처럼 블록 최적화 문제가 2차식으로 표현되는 문제를 Quadratic Programming이라고 하며 Quadratic Programming은 매우 복잡하기 때문에 보통 상용 라이브리리를 이용하여 계산한다. 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.

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

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.

Linear kernel : $K(x_i, x) = x^T x_i$

Polynomial kernel of degree d :

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

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

이 커널 함수의 역할은 입력 데이터를 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 서보 시스템의 기계 방정식은 다음과 같이

주어진다.

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

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 마찰계수 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.

$$y = T_e(t)$$

$$x = \begin{bmatrix} dw_m \\ w_m \end{bmatrix}$$

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

$$b = T_L$$

SVR에서 C와 ϵ 값은 시스템이나 훈련 데이터의 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. 또 C값은 SVR의 Kernel을 Linear로 선택했을 경우 블록 최적화 문제의 해에 거의 영향을 주지 않기 때문에 본 논문에서는 커널 함수를 Linear로 설정하고 C값은 일정한 값 0.001로 고정해서 사용한다.

Quadratic Loss Function을 사용하여 블록 최적화 문제는 다음과 같은 함수를 최소화 하는 문제로 바뀐다.

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

식 (10)의 함수를 최소화하는 라그랑지안 계수 $\alpha_i, \alpha_i^*, i = 1, \dots, N$ 를 찾으면 θ 와 b 는 다음과 같이 쓸 수 있다.

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

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

4. 실험 결과

제안된 방법의 타당성을 검증하기 위하여 서보 구동 장치에 SVR알고리즘을 구현하고 220[V], 400[W]급 서보 전동기에 대하여 실험을 수행 하였다. 부하 관성은 전동기에 연결되며, 관성비를 전동기 자체 관성의 1배에서 20배로 변화시켜가며 실험을 수행하였다. 전동기 자체 관성 계수는 $3.6e-5 \text{ kgm}^2$, 부하 토크는 0 Nm 이다. 매 실험마다 관성비는 고정되어 있으며, Linear Kernel을 모든 실험에 사용하였다. 다양한 부하 관성을 전동기에 연결해서 그 때마다 부하를 포함한 전체 관성, 마찰 계수, 부하 토크를 추정하였다. 서보 구동 장치의 CPU는 120MHz 클럭으로 동작하는 TMS320VC33 DSP를 사용하였으며, 온라인 SVR 알고리즘은 속도 지령이 변할 때 1.4msec 마다 샘플링하여 10개의 샘플로 전체 관성, 마찰 계수, 부하 토크를 추정한다. 속도 정보를 위해 전동기 축에 1024p/r의 분해능을 가지는 엔코더를 연결하였으며, 속도의 미분은 오일러 방정식을 이용해 간단히 구하였다. 잘 알려져 있듯이 속도의 미분은 작은 잡음에 의해서도 쉽게 왜곡될 수 있다. 그러나 SVR 알고리즘은

이런 잡음의 의해 속도와 속도 미분의 정보가 왜곡됨에도 불구하고 훌륭한 성능을 발휘한다.




그림 2 5배 부하 관성에 대한 실험 결과 (초기J=1/5Jm)

- (a) 관성 계수 추정 전후의 속도 응답
- (b) 확대한 속도 응답
- (c) 토크 응답
- (d) 추정된 관성 계수
- (e) 추정된 마찰 계수
- (f) 추정된 부하 토크




그림 3 20배 부하 관성에 대한 실험 결과 (초기J=1/5Jm)

- (a) 관성 계수 추정 전후의 속도 응답
- (b) 확대한 속도 응답
- (c) 토크 응답
- (d) 추정된 관성 계수
- (e) 추정된 마찰 계수
- (f) 추정된 부하 토크

그림 2 와 3은 초기에 부하 관성의 20%로 관성 값을 잘못 알고 있다고 가정하여 속도 제어기 이득을 계산하였다. 0rpm~1000rpm 스텝 지령에 대한 속도 응답과 표시

된 시점에서 SVR 알고리즘에 의하여 기계적 상수와 부하 토크를 추정하여 속도 제어기의 이득을 보상한 후의 속도 응답, 추정된 기계적 상수 및 부하 토크를 보이고 있다. 속도 응답의 경우 보상 전 약 200rpm의 오버 슈트가 보상 후 약 100rpm이하로 줄어들고, 특히 SVR이 작은 샘플링으로 짧은 시간 내에 추정이 이루어지기 때문에 속도 응답이 정상 상태에 도달하기 전에 속도 제어기의 이득이 보상 되어져 오버 슈트/언더 슈트가 거의 발생하지 않는다. 그림 2와 3에서 속도 지령이 1000rpm에서 0rpm으로 떨어지는 순간에 SVR 알고리즘이 동작하고 즉시 속도 제어기 이득에 보상이 이루어져 0rpm에서 언더 슈트가 거의 발생하지 않았다. 토크의 모양을 보면, 추정 직후의 토크의 모양이 보상이 완벽히 이뤄진 후의 토크 모양과 비슷함을 알 수 있다. 그림 3에서처럼 정상 상태 도달 시간이 오래 걸리는 큰 관성 계수를 가질 경우 토크의 모양은 SVR의 동작과 함께 보상이 완벽히 이루어진 후의 토크의 모양과 거의 같다.

또한 기존의 추정 알고리즘은 관성 계수와 마찰 계수, 부하 토크를 두 번에 걸쳐 추정하지만 [11], SVR 알고리즘은 한번의 추정으로 모든 상수 값을 알 수 있다. 추정 결과는 그림 2와 3에서 보는 바와 같이 허용 오차 범위 내에서 잘 추정함을 볼 수 있다.

5. 결 론

본 논문에서는 SVR 알고리즘을 사용하여 서보 시스템의 기계적인 상수 및 부하 토크를 온라인으로 추정하는 방법을 제안하였다. 제안된 방법은 속도 지령이 변할 때마다 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.

[참 고 문 헌]

- [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 2nd ed.*, 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," *In 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.
- [11] S. J. Hong, H. W. Kin, and S. K. Sul, "A Novel Inertia Identification Method for Speed Control of Electric Machine," in *Proc. IEEE ICON*, vol.2, pp.1234-1239, 1996.