

SVM기법을 이용한 진동계의 고장진단에 관한 연구

Abnormal Diagnostics of Vibration System using SVM

고광원*, 오용설**, 정근용**, 허 훈***

Kwang Won Ko*, Yong Sul Oh**, Qeun Young Jung**, Hoon Heo***

Key Words : Diagnostic(진단), SVM(Support Vector Machines), Vibration(진동), Machine Diagnostics

ABSTRACT

When oil pressure of damper is lost or relative stiffness of spring drops in vibration system, it can be fatally dangerous situation. A fault diagnosis method for vibration system using Support Vector Machine(SVM)is suggested in the paper. SVM is used to classify input data or applied to function regression. System status can be classified by judging input data based on optimal separable hyperplane obtained using SVM which learns normal and abnormal status. It is learned from the relationship of system state variables in term of spring, mass and damper. Normal and abnormal status are learned using phase plane as in put space, then the learned SVM is used to construct algorithm to predict the system status quantitatively

기호설명

- c : 스프링 탄성계수
- b : 감쇠 계수
- x : 학습 데이터
- bi : 바이어스(bias)
- w : 가중치(weight)
- ξ : outlier의 벌점(penalty)
- d : Output target
- a : 라그랑지 멀티플라이어

- D_i : 최적 분리면과의 거리
- S_1 : 정상상태 데이터들의 거리의 합
- S_{-1} : 비정상상태 데이터들의 거리의 합

1. 서론

질량과 탄성을 갖는 모든 계는 자유진동을 할 수 있다. 계는 운동방정식으로 모델링 할 수 있고 계의 질량, 강성 및 감쇠는 진동계의 기본적인 요소가 된다.

우리는 이러한 기본적인 요소의 결합으로 적절히 제어된 진동계를 설계하게 된다. 그러나 예기치 못한 감쇠기의 유압이 손실되거나 스프링의 강성도가 떨어지는 경우, 성능 저하 뿐 아니라 치명적인 안전의 위험성을 가져올 수 있다. 기존의 진동 해석 진단 기법에서는 진폭의 역치(Threshold Level)를 검출하거나 신호처리(Signal Processing)을 통한 modulation등의 기법 통해 특징적인 인자(Factor)를 검출하여 진단한다.(1) 또한 Tax와 Duin에 의해 One Class Problem이나 SVDD를 통해 Novelity detection 문제로 진단 기법이 다루어져 왔다.(2)(3) 이 경우는 고장 시의 패턴을 모를 경우 매우 유용한 방법이다. 본 논문에서는 SVM을 이용한 진동계의 고장의 패턴을 인식시키고, 성능저하를 진단하는 기법을 연구해 보고자 한다. 고장 시의 정보

* 고려대학교 제어계측공학과 동적 시스템/제어 연구실
E-mail : kornb@korea.ac.kr
Tel : (02) 3200-3335 Fax : (02) 929-7808

** 고려대학교 제어계측공학과 동적 시스템/제어 연구실

*** 정희원 고려대학교 제어계측공학과

를 이용하여 특정 고장 시와의 유사성을 판단하여 진단하는 기법을 소개한다.

SVM은 입력자료를 구분(Classification)하거나 함수 근사(Regression)에 적용되어 왔다.(4) SVM은 패턴 분리의 최적 Hyperplane을 구하는 QP(Quadratic Programming)의 해를 구하는 것으로 귀결된다. 이러한 최적 분리면은 목시적인 특이공간(Feature Space)으로의 사상(mapping)을 통해 얻어지며, 사상된 다차원공간에서 다시 입력공간(Input Space)에서의 구분(Classification)을 얻게된다. 이를 통해 입력공간에서 선형구분(linear separable)되어지지 않는 문제를 해결할 수 있다. 이러한 장점을 이용하여 Phase Plane에서 진동계의 정상상태와 비정상상태의 특징을 학습하여 성능저하가 발생했을 때를 진단하는 알고리즘을 제안하고자 한다.

본 논문의 구성은 다음과 같다. 먼저 2장에서는 진동시스템을 모델링하고 SVM기법에 대해 설명한다. 3장에서는 고장진단 알고리즘을 설명하고 4장에서는 간단한 모의 실험과 결과를 제시하며, 5장에서는 결론 및 향후과제를 설명한다.

2. 진동 시스템 및 SVM

2.1 M-C-K 시스템 모델링




Fig. 2-1 M-C-K 시스템

Fig.2-1과 같은 시스템은 다음과 같이 시스템이거나

$$m\ddot{x} + b\dot{x} + kx = 0 \quad (식1)$$

또는 비선형 시스템일 수도 있다.

$$m\ddot{x} + b\dot{x} + k_0x + k_1x^3 = 0 \quad (식5)$$

수식적인 모델을 통해 적절히 제어된 시스템을 얻게 된다. 적절히 제어된 탄성 계수 k와 감쇠 계수 c가 비정상상태로 되어질 경우 시스템의 Phase Plane 상에서의 반응은 Fig.2-2와 같다.

Phase Plane에서 어떤 특이점으로 수렴하는 것을 평형점(Equilibrium Point)라고 한다. Fig.2-2와 같은 경우 평형점

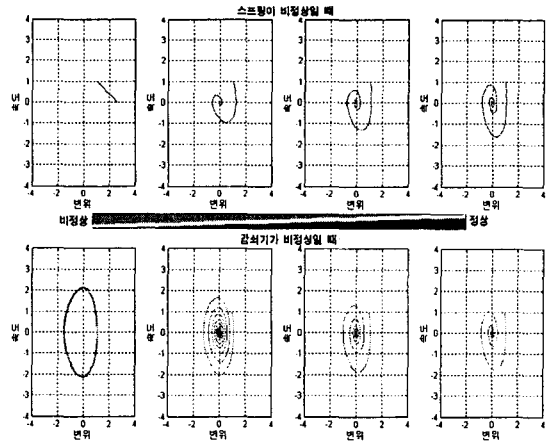


Fig. 2-2 Phase Plane

은 원점이되고 원점으로 수렴하는 정도가 안정하게 된다.(7)

2.2 SVM Classification

SVM은 잘 알려진 신경망(Neural Network)의 일종으로 입력 자료를 구분(Classification)하거나 함수 근사(Regression)에 적용되어 왔다.

SVM은 패턴 분리의 최적 Hyperplane을 구하는 즉, QP(quadratic programming)의 해를 구하는 것으로 귀결된다. 그 과정을 살펴보면 다음과 같다.

$$\{(x_i, d_i)\}_{i=1}^N \quad (식6)$$

where x_i is the input data,

d_i is the target output

Trade-Off 상수 $C > 0$

$$\min \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i \quad (식4)$$

$$\text{s.t. } d_i(\langle w, x_i \rangle + b) \geq 1 - \xi_i, \\ \xi_i \geq 0, \quad i = 1, \dots, N.$$

(식4)는 다음과 같은 쌍대 문제에 해를 구하는 것과 동치이다. 쌍대 문제는 다음과 같다.

$$\max \Theta(a) = \sum_{i=1}^N a_i \frac{-1}{2} \sum_{j=1}^N \sum_{k=1}^N a_j a_k d_j d_k K(x_i, x_j) \quad (식5) \\ \text{s.t. } \sum_{i=1}^N a_i d_i = 0, \quad 0 \leq a_i \leq C, \quad \forall i.$$

C-SVM의 결정함수는 다음과 같다.

$$f(x) = \text{sgn}(\langle w, \phi(x) \rangle + bi) \\ = \text{sgn}\left(\sum_{i=1}^N \alpha_i d_i K(x_i, x) + bi\right). \quad (\text{식6})$$

위와 같은 패턴분류의 방법에서 새로운 Test Vector를 분류하는 방법은 Fig.2-3의 그림과 같이 나타내어진다. 이 때 결과는 최적 분리면과 떨어진 거리의 부호 즉, sgn function으로 판단하게 된다.

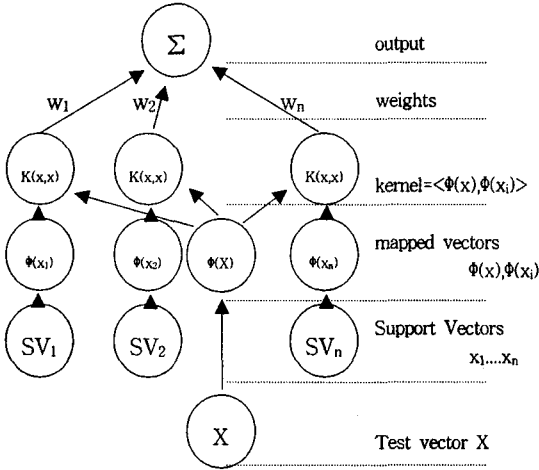


Fig. 2-3 SVM의 학습과 판단의 개념도

여기서

$$\langle w, \phi(x) \rangle + bi \\ = \sum_{i=1}^N \alpha_i d_i K(x_i, x) + bi. \quad (\text{식7})$$

(식7)은 고차원으로 사상(Mapping)된 특이공간(Feature space)에서의 최적 분리면과 시험 입력(Test Data)간의 거리에 비례한 값을 얻게 된다. 여기서 Support Vector는 분리면에 가장 가까이 있는 학습데이터이고 거리를 정규화하여 1이나 -1에 해당한다. 그러나 분리면에서 멀리 떨어진 데이터는 1보다 크다.

여기서 KT condition에 의해 다음과 같은 성질이 갖는다.

$$\alpha_i [1 - d_i (w^T x_i + b_i)] = 0 \quad (\text{식8})$$

$$\therefore \begin{cases} \alpha_i = 0 & \text{if } d_i (w^T x_i + b_i) \neq 1 \\ \alpha_i \neq 0 & \text{if } d_i (w^T x_i + b_i) = 1 \end{cases} \quad (\text{식9})$$

즉, 서포트 벡터의 α_i 값은 0이 아닌 값이 되고 나머지 데이터들은 0에 가까운 값이 된다. 여기서 α_i 값은 0에 가

까운 값이 되면 결과에 영향을 미치는 정도가 매우 작다는 것을 알 수 있다.

3. 고장진단 알고리즘

시스템은 2.1장에서 다루었던 M-C-K 시스템으로 모델링 되는 시스템이라 가정한다. 또한 시스템은 조절히 제어되어 안정하다고 가정하고, 시스템의 고장 시 정보를 알고 있다고 가정한다.

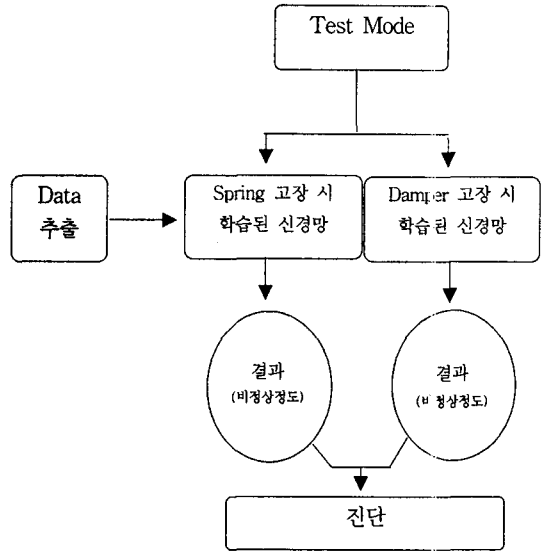


Fig. 3-1 진단 알고리즘의 개념도

이것은 스프링이 없는 시스템의 결과는 Fig.3-1과 같은 결과를 얻는 것은 자명한 일이다. 왜냐 하면 스프링 상수가 0이면 변위가 1에 있을 때, 안정되어있다 가정하면 변위와 속도는 변화하지 않으며 그 자리에 머물러 있게 된다는 것을 알 수 있다.

또한 감쇠기가 역할을 하지 못한다면 Fig. 3-1와 같이 진동하면서 Phase Plane상의 원을 그릴 것은 자명한 일이다. 이러한 가정 하에서 SVM을 이용하여 정상상태(현 상태)와 가정된 비정상상을 학습시킨다. 그러면 학습된 두 가지 신경망을 얻게 된다.

Test Mode가 되면 시스템이 안정된 상태에서 변위를 1을 설정한다. 그런 후 시스템의 추이를 기록한 뒤 데이터의 일부분을 추출하여 SVM알고리즘을 통해 이미 학습되어진 신경망에 입력시켜 고장을 판단한다.




Fig. 3-2 스프링 이상 시 구분

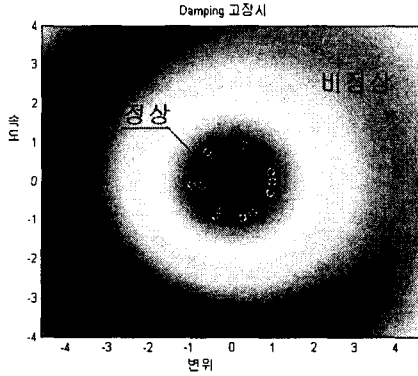


Fig. 3-3 감쇠기 이상 시 구분

최적 분리면과 시험 데이터와의 거리는 다음과 같다.

$$D_i(x) = (\langle w, \phi(x) \rangle + bi) = \left(\sum_{i=1}^N a_i d_i K(x_i, x) + bi \right) \quad (식10)$$

where $i=1, \dots, N$ (추출된 Data의 개수)

$$S_1 = \sum_{i=1}^N \left\{ D_i \frac{(\text{sgn}(D_i) + 1)}{2} \right\} \quad (식11)$$

$$S_{-1} = \sum_{i=1}^N \left\{ D_i \frac{(1 - \text{sgn}(D_i))}{2} \right\} \quad (식12)$$

(식11)과, (식12)를 통해 추출된 데이터가 정상과 비정상 영역에서의 최적 분리면과의 거리의 합을 구할 수 있다. 이 값들은 정상에 가까울수록 큰 양수(+)를 갖고 비정상에 가까울수록 음수의 값을 가지게 된다.

이것은 Fig 3-1에서 보면, 초기 값을 변위 1에 놓았을 때, 시스템이 평형상태(Equilibrium Point) 접근한다면 원점이 있는 방향 즉, 최적 분리면을 넘어 D_i 가 양수(+)인 곳으로

이동하게 된다. 그렇게 되면 S_1 은 양수가 더해지게 되므로 점점 커지게 된다. 때문에 최적 분리면을 빨리 넘는 것이 보다 더 S_1 을 크게 할 것이고, 빨리 넘어간다는 것은 스프링 상수 k 값이 크다는 것을 의미한다. 반면 S_{-1} 의 절대값은 더 이상 커지지 않고 수렴하게 될 것이다.

Fig. 3-3에서도 보면 변위를 1에 놓아 시험 할 때, 위와 같은 이유로 최적 분리면을 넘는 시점에 따라 특징을 지을 수 있다. 때문에 정상상태에 가까운지 비 정상상태와 가까운지를 판단할 수 있게 된다.

4. 모의 실험

Fig 2-1과 같은 시스템을 비선형 모델링하면 (식2)와 같이 된다. 이것을 시뮬레이션 하게 되면 Fig. 4-1과 같이 된다.

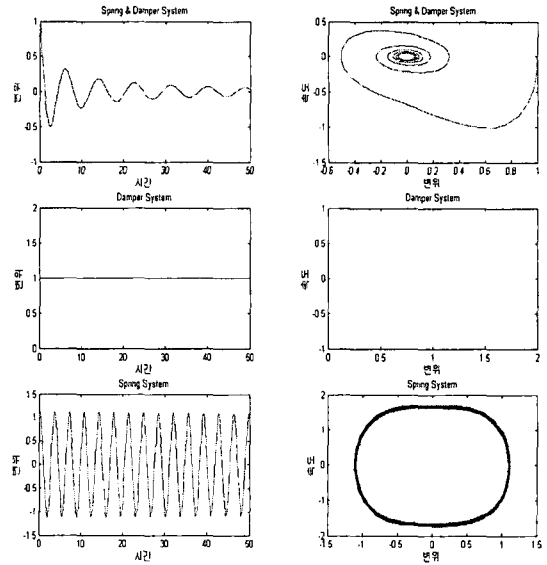


Fig. 4-1 사용한 모델

모의 실험에서의 파라미터들은 다음과 같다.

SVM 에 사용한 Bayesian-RBF Kernel에서의 파라미터는 다음과 같다.

$$\sigma=3, \quad C=1000$$

비선형 모델식(2)에서의 파라미터는 다음과 같다.

$$k_0=0.5, \quad k_1=3, \quad b=1$$

시뮬레이션 파라미터는 시간은 50초까지이고, 초기 값은 변위가 1인 안정된 상태라 한다.

Fig. 4-1과 같이 정상일 때, 원점 즉, 평형상태 (Equilibrium Point)로 접근하게 된다. 그러나 스프링이 없을 경우 변위는 움직이지 않으며, 감쇠기가 없을 경우 계속 진동하게 된다.

정상상태와 이 두 가지 비정상상태를 신경망에 학습시킨다. 그런 후 순차적으로 스프링 상수를 변화해 가면서 시뮬레이션하고, 감쇠 상수를 변화해 가면서 시뮬레이션 한다. 이러한 비정상 상태의 정보를 바탕으로 SVM을 통해 시뮬레이션 해보면 Fig 4-2, Fig 4-3와 같다.




Fig. 4-2 스프링 비정상 상태의 학습

Fig 4-2에서 보면, 특이 공간에서 입력공간의 평형점은 분리면과 거리가 크며, 그러므로 빨리 수렴할수록 평형점 근처의 시험데이터가 많아져 S_1 의 크기가 커지게 된다. 반면에 S_{-1} 은 초기 분리면 바깥쪽에서 얻어진 값을 유지하게되어 매우 느리게 증가하게 된다.




Fig. 4-3 스프링상수 변화 시 S값

Fig 4-3를 통해 정상 궤적을 그릴 때는 최적 분리면과의 거리가 멀어지고 또한 평형점으로 향하기 때문에 S_1 의 값이 증가하게 된다. 이렇게 증가하는 수치를 기준으로 상태를 판별하게 된다. 이 경우 ' 좋음', '보통', '나쁨'의 기준으로 상태를 나누었다.

정량적인 수치로 구별해 보면 표4-1과 같이 구별해 볼 수 있다. 이 구분에서는 S_1 을 기준으로 판별하였다.

k 비율	S_1	S_{-1}	상태
0.1	249.063996	-6.147397	나쁨
0.2	283.787449	-6.013190	
0.3	342.577581	-5.900501	
0.4	384.876254	-5.808193	
0.5	425.093557	-5.72872	
0.6	468.379033	-5.679891	
0.7	502.719461	-5.653047	
0.8	534.069560	-5.632847	보통
0.9	562.832634	-5.611938	
1.0	587.119414	-5.592397	

표 4-1 스프링 상수 변화에 따른 S 값과 상태 구분




Fig. 4-4 감쇠기 비정상 상태의 학습

Fig 4-4에서 보듯이 비 선형적인 궤적을 따라 최적 분리면이 결정되어진 것을 알 수 있다.

그러나 S_1 과 S_{-1} 의 변화는 매우 정상적이지 않은 부분에서만 급격히 떨어지는 것을 알 수 있다. 이것은 Fig. 4-4에서 보듯이 시스템이 최적분리면 주위를 천천히 돌아 평형점으로 접근하기 때문에 다른 궤적을 그려도 S값의 차이가 벌어지지 않는다.

5. 결론 및 향후 과제

SVM을 이용하여 Phase Plane 상의 정상 진동계의 패적과 비정상 진동계의 패적을 학습시켜 새로운 시험데이터를 구분하였다. 비선형적인 결과를 적절히 분할하여 판단하고여 시스템을 정상상태인지 비정상적인 상태인지를 알 수 있었다. 이것은 기존의 방법과 같이 시스템의 특징적인 인자 (Factor)를 검출하여 진단하는 것과 유사하다. 모의 실험에서 스프링 상수의 비율을 변화시킬 때는 매우 뚜렷하게 상태를 구별할 수 있었으나 감쇠 상수의 비율이 변화할 때는 극단적인 경우에만 진단이 가능하였다. 그러므로 본 논문의 기법은 스프링 고장 시 진단에 더 좋은 성능을 낸다고 볼 수 있다. 향후 과제로는 다양한 시스템에 적용과 외란 이나 복합적인 고장 시 발생하는 문제점을 광범위하게 실험하는 것이다. 또한 다른 기법들과 비교하고 장단점을 파악하는 것이다.




Fig. 4-5 감쇠 계수 변화 시 S값

Fig. 4-5에서의 감쇠 계수에 따른 응답의 변화는 스프링 상수가 변화할 때만큼 뚜렷하지는 않지만 극단적인 '매우 나쁨'의 경우를 진단하는 것은 가능하다. 정량적인 수치로 판단해 보면 표4-2와 같다.

참고 문헌

- (1) R.G. White J. G. Walker, 1982, Noise and Vibration, Ellis Horwood
- (2) David M.J. Tax, Alexander Ypma and Robert P. W. Duin "Support vector data description applied to machine vibration analysis" Pattern Recognition Group
- (3) Alexander Ypma and Robert P. W. Duin "Novelty detection using Self-Organizing Maps" Pattern Recognition Group
- (4) Christopher M. Bishop, 1995 Neural Networks for Pattern Recognition Oxford University Press
- (5) Simon Haykin, 1999 Neural Networks - a comprehensive foundation, Prentice Hall,
- (6) William T. Thomson, 1998, Theory of Vibration with Applications, Prentice Hall
- (7) Jean-Jacques E. Slotone and Weiping Li, 1991, Applied Nonlinear Control, Prentice Hall,

b 비율	S_1	S_{-1}	상태
0.1	384.591334	-31.649731	매우 나쁨
0.2	417.679571	-19.844635	
0.3	418.466847	-15.200858	
0.4	415.099539	-14.675924	나쁨
0.5	414.879261	-14.301215	보통
0.6	407.299010	-13.874325	
0.7	405.092824	-13.821332	
0.8	405.392177	-13.948206	
0.9	403.233573	-13.815910	
1.0	399.598730	-13.889069	

표 4-2 감쇠 계수 변화에 따른 S 값과 상태 구분