외란을 포함한 학습 데이터에 강인한 시스템 모델링

A Robust Learning Algorithm for System Identification

°한 상 현*, 윤 중 선**

* 부산대학교 지능기계공학과(Tel : 82-51-510-3084; Fax : 82-51-510-3084; E-mail : dolp1234@hanmail.net)
** 부산대학교 기계공학부(Tel : 82-51-510-2456; Fax : 82-51-510-3084; E-mail : jsyoon@hyowon.pusan.ac.kr)

Abstract : Highly nonlinear dynamical systems are easily identified using neural networks. When disturbances are included in the learning data set for system modeling, modeling process will be poorly performed. Since the radial basis functions in the radial basis function network(RBFN) are centered at the points specified by the weights, RBF networks are robust for approximating the process including the narrow-band disturbances deviating significantly from the regular signals. To exclude(filter) these disturbances, a robust algorithm for system identification, based on the RBFN, is proposed. The performance of system identification excluding disturbances is investigated and compared with the one including disturbances.

Keywords : system identification, radial basis function network(RBFN), robust learning, disturbance filtering

1. 서론

비선형성이 강한 시스템은 센서로 측정한 입출력 관계를 이용하여 신경회로망으로 모델링할 수 있다. 시스템 자체의 문제점이나 센서의 잡음(noise), 신호의 미분 등으로 인해 시스템의 입출력 관계에 외란이 포함된 데이터가 존재할 경우 시스템을 제대로 모델링할 수 없다. 좁은 대역에서의 외란신호(narrow-band disturbances)는 공학적인 시스템에서 흔히 발생하며 제어와 시스템 모델링에 많은 문제점을 야기한다. 이처럼 센서에 감지되는 외란성분을 제거해 시스템의 모델링 성능을 향상하고자 하는 연구가 진행되고 있다[5, 8].

radial basis function network(RBFN)은 전 대상 영역을 유한개의 기저함수로 나타내므로 매우 좁은 영역에 민감하지 않는 특성을 가진다. 오히려 이러한 성질을 외란이 포함된 데이터의 학습에 적용하면, 정규 데이터에서 벗어나는 외란 신호조차도 정규 신호로 보고 학습하려는 기존의 신경회로망과는 달리 이러한 외란 신호를 걸러주는 강인한 시스템 모델링이 가능할 것이다.

RBFN을 이용하여 시스템의 입출력 관계에 포함된 외란을 찾아내어 제거하고 제거된 시스템의 입출력 데이터를 이용하여 좀더 성능이 향상된 시스템 모델을 구한다. 이러한 외란 신호에 강인한 시스템 모델링 기법을 제안하고 제안된 모델링 기법을 외란을 포함한 시스템에 적용하여 검증한다.

2. 시스템 모델링을 위한 Radial Basis Function Network(RBFN)

2.1 회귀연결강도를 가지는 RBFN(GRBFN)

RBFN은 식 (1)과 같은 비선형 radial basis function(RBF) $\phi(x)$의 선형결합으로 비선형 함수식을 근사화한다[3, 9].

$$F(\boldsymbol{x}) = \sum_{i=1}^{N} \omega_i \phi_i(\boldsymbol{x}) \tag{1}$$

여기서, RBF $\phi(x)$는 입력 벡터 $\boldsymbol{x}$와 중심벡터 c사이의 거리 $r=\|\boldsymbol{x}-\boldsymbol{c}\|$에 의존하는 다차원 함수로 정의된다. 대표적인 RBF로 중심벡터 c에서 최대값을 가지고 중심에서 거리가 멀어질수록 단조감소하는 식 (2)의 Gaussian 함수가 있다.

$$\phi_i = \phi_i(\|\boldsymbol{x} - \boldsymbol{c}\|) = \exp\left[-\frac{(\boldsymbol{x} - \boldsymbol{u}_i)^2}{2\sigma_i^2}\right] \tag{2}$$

식 (2)의 Gaussian 함수를 RBF로 사용하면 비선형 함수식 (1)은

$$F(\boldsymbol{x}) = \sum_{i=1}^{N} \omega_i \exp\left[-\frac{(\boldsymbol{x} - \boldsymbol{u}_i)^2}{2\sigma_i^2}\right] \tag{3}$$

와 같다. 식 (3)과 같은 RBFN의 학습 파라미터는 RBF의 중심벡터 u와 폭 σ, 연결강도(weight) ω이다.

두 개의 입력변수 x, y와 하나의 출력변수 O_1을 가지는 RBFN의 구조는 그림 1과 같다. 은닉층이 RBF 연산만을 수행하므로 구조가 일반적인 신경회로망보다 간단하다. 출력값 또한 이들 RBF 출력값의 선형결합이므로 학습도 다층 퍼셉트론보다 훨씬 간단하고 수렴속도도 빠르다.

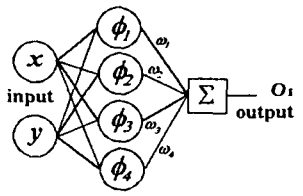

그림 1. Radial basis function network(RBFN)의 구조

Langari와 Wang은 상수값을 연결강도 ω_i로 가지는 RBFN과 달리 입력벡터 $\boldsymbol{x}$의 선형결합으로 이루어진 회귀연결강도를 가지는 RBFN(generalized RBFN-GRBFN)을 제안하였다[6]. 입력변수에 의존하는 연결강도 ω_i는 식 (4)와 같다. 상수로 표현할 때보다 파라미터 수가 늘어나는 만큼 오차가 줄어들게 된다[6].

$$\omega_i = \boldsymbol{a}_i^T \boldsymbol{x} + b_i \tag{4}$$