

공작기계 컨트롤러용 고속 신경망 필터의 기초설계

김진선*, 신우철+, 홍준희**

The Basic Design of High Speed Neural Network Filter for Application of Machine Tools Controller

Jin-Sun Kim*, Woo-cheol Shin+, Jun-hee Hong**

Abstract

This Paper describes a Nonlinear adoptive noise canceller using Neural Network for Machine Tools Controller System. Back-Propagation Learning Algorithm based MLP (Multi Layer Perceptron) is used as adaptive filters. In this Paper, it is assumed that the noise of primary input in the adaptive noise canceller is not the same characteristic as that of the reference input. Experimental results show that the neural network based noise canceller outperforms the linear noise canceller.

Especially to make noise cancel close to realtime, Primary Input is divided by Unit and each divided part is processed for very short time than all the processed data are unified to whole data.

Key Words : Multi Layer Perceptron (다층 신경망 구조) Back-Propagation Learning Algorithm, (오차 역전파 학습 알고리즘)

1. 서론

공작기계가 무인화, 자동화되어 가면서 작업상태와 공작기계의 상태를 실시간으로 모니터링 하는 센서의 비중이 날로 커 가고 있다. 실제 현대의 초정밀 자동화 기계의 경우 그 가격의 30% 이상이 센서와 그 센서의 신호를 처리하는 유닛의 비용으로 소모되고 있다. 그러나

고급의 센서를 사용 하더라도 작업특성상 공작기계의 센서에는 노이즈가 많이 발생하게 되므로 그 성능을 완전히 발휘하지 못한다.

노이즈를 완전히 차단한다는 것은 현실적으로 불가능하기 때문에 획득된 노이즈 섞인 신호에서 원하는 신호만을 검출해야 한다.

* 주저자, 충남대학교 기계공학과 대학원 (finalguard@hanmail.net)
주소: 305-764 대전광역시 유성구 궁동 220 충남대학교 기계공학과
+ 충남대학교 기계공학과 대학원
++ 충남대학교 기계공학부

노이즈는 크게 규칙성 노이즈와 불규칙성 노이즈로 나뉜다. 규칙성 노이즈의 경우 그 주파수적 특성이 명확하므로 대역통과 필터를 사용함으로써 비교적 손쉽게 제거하는 것이 가능하다. 그러나 실험실과 산업현장에서 발생하는 불규칙성 노이즈는 넓은 주파수 범위에 걸쳐서 생성되고 시간에 따라서 잡음의 성분이 변하는 시변특성(time varying)이 있다.

본 연구는 이런 규칙성 노이즈와 더불어 발생하는 불규칙성 노이즈(시변 노이즈, 랜덤 노이즈)에 대해 능동적으로 대처하는 신경망 적응제어 필터의 설계와 더불어 제어 시스템에 사용해도 될 정도의 빠른 응답성과 처리속도를 갖는 고속신호처리 필터를 설계함에 있어서 필요한 제반 연구를 실시하였다.

신경망을 이용한 적응 노이즈 제거기는 이미 여러 종류가 제안되었는데 대표적으로는 Widrow가 제안한 LMS(least mean square) 알고리즘을 이용한 선형구조의 적응필터가 있다.

LMS 알고리즘은 계산이 간단하고 쉽게 구현할 수 있으므로 여러 분야, 특히 음성필터링 분야에 많이 응용되고 있고 실시간 처리에 사용되고 있다. 그러나 처리하고자 하는 신호가 정적인 경우에는 우수한 성능을 보여주지만 제어기용 센서에서와 같이 그 신호가 시변특성이 있는 경우에 대해서는 필터링 성능이 떨어지는 단점이 있으므로 상기한 공작기계 센서의 노이즈 처리에 사용되기에는 무리가 있다.

다음으로 신호처리에 많이 사용되는 BP (Back-Propagation Algorithm) 알고리즘 적용 MLP(Multi Layer Perceptron) 구조의 필터의 경우 고정된 데이터의 필터링 시 LMS 보다 필터링 성능이 더 우수하다고 알려져 있다. 그러나 연속적인 데이터의 처리능력이 결여되어 있어 마찬가지로 공작기계용 신호처리에 사용되기에는 부적절하다.

본 논문에서는 MLP구조의 노이즈 필터에 연속된 센서신호를 처리하는 능력을 부여하기 위하여 다음과 같은 방법을 이용하였으며 우수한 필터링 성능과 공작기계컨트롤러에 적용하기 위한 실시간화를 모색하였다.

① 1회 필터링 분량의 데이터 수 (unit) 를 고정하여 필터링을 수행한다.

② 새로운 데이터가 추가 될 때 마다 유닛의 가장 오래된 데이터를 버리고 새로운 데이터를 추가한 것을 새로운 유닛으로 구성한다.

③ 데이터 한 개가 교체된 부분적으로 갱신된 유닛을 새로이 필터링 한다.

④①~③을 반복하면서 필터링 된 데이터를 연속적으로 얻는다.

2. 적응 노이즈 필터링 시스템

2.1 시스템 구조




Fig.1 MLP noise canceller

Fig.1 은 컨트롤러의 센서에 특정 주파수 대역을 갖고 있는 노이즈와 시변노이즈가 동시에 영향을 미칠 때의 노이즈 제거기이다. 목적 신호 $s(k)$ 와 노이즈 $x'(k)$ 의 합이 주 입력 (Primary input)으로 사용되며 기준입력 (Reference)인 $x(k)$ 는 $x'(k)$ 와 상관관계가 있는 신호로서 필터의 입력으로 사용된다.

기본 동작구조는 시스템 출력을 적응필터로 귀환시켜 적응 알고리즘을 통해 전체 시스템의 출력 전력을 최소화하도록 필터 파라미터를 계속 변화시킴으로써 주 입력에 포함된 노이즈의 영향을 줄이는 것이다.

시스템 출력은 다음과 같다.

$$e(k) = \{s(k) + x'(k)\} - y(k) \quad (1)$$

제곱 후 기대치를 적용하면

$$E[e(k)^2] = E[s(k)^2] + 2E\{s(k)\{x'(k) - y(k)\}\} + E[\{x'(k) - y(k)\}^2] \quad (2)$$

$2E[s(k)\{x(k) - y(k)\}^2]$ 항에서 $s(k)$ 는 $x(k)$ 및 $y(k)$ 와 uncorrelated 하므로 전체 기대치는 orthogonal property를 가지므로 "0" 이 된다. 따라서 식 (2)는 다음과

같이 정리 된다.

$$E[e(k)^2] = E[s(k)^2] + E\{[x'(k) - y(k)]^2\} \quad (3)$$

이중 목적 신호만을 추출하는 것이 목적이다. 목적 신호의 파워 $E[s(k)^2]$ 은 필터의 계수와는 무관하므로 필터계수를 조절하여 오차 $e(k)$ 의 파워 $E[e(k)^2]$ 를 최소화 하는 것은 (3)의 두 번째 항

$$E\{[x(k) - y(k)]^2\} \text{을 최소화 하는 것이다.}$$

이를 정리하면

$$E_{\min}\{e(k)^2\} = E\{s(k)^2\} + E_{\min}\{[x'(k) - y(k)]^2\} \quad (4)$$

(4)에서 기대치를 제거하고 정리하면 $x'(k) - y(k)$ 가 최소 값을 가질 때 $e(k) = s(k)$ 가 된다. 따라서 필터는 선 입력 값인 $x(k)$ 값을 입력으로 하여 필터 출력 $y(k)$ 가 현재 입력 값이 $x'(k)$ 값을 추종함으로써 $x'(k) - y(k) = 0$ 으로 하여 목적 신호 $s(k)$ 를 추출 할 수 있다.

2.2 신경망 모델

신경망은 회로망 내부에 비선형적 처리능력을 갖춘 유닛으로 구성되어 있고 주위환경에 적응할 수 있는 능력을 갖추고 있다.




Fig. 2. Structure of Neural-Network filter

본 논문에서 사용한 필터는 입력-은닉-출력층이 $P-N-1$ 구조를 갖는 다층신경망 (MLP, Multi Layer

Perceptron)에 오차 역전파 학습 알고리즘 (BP, Back-Propagation Learning Algorithm)을 사용하여 신경망 필터를 구성하였다.

Fig.2는 실험에 사용한 신경망의 구조이다. 입력은 $x(k)$ 부터 $x(k-P+1)$ 까지 P 개만큼 주 입력을 동시에 가지는 매트릭스 X 라 한다. W 는 각 뉴런간의 가중치 매트릭스를 나타낸다. $W^{[1]}$ 의 첨자중 [1]은 입력층에서 은닉층까지의 가중치 매트릭스를 나타내며 [2]는 은닉층으로부터 출력층까지의 가중치를 나타낸다. b 는 바이어스 매트릭스로 첨자 [1]은 은닉층의 바이어스이며 [2]는 출력층의 바이어스이다. n 은 각층의 출력층 매트릭스로 첨자[1]은 활성화 함수를 거치기 전의 은닉층의 출력매트릭스이고 [2]는 활성화 함수를 거치기 전의 출력층 매트릭스이다. a 는 활성화 함수를 거친 각 층의 출력 매트릭스를 의미한다. 은닉층과 출력층의 활성화 함수 (Activation Function)은 Hyperbolic Tangent Sigmoid 함수로 설정한다.

프로그램화 하기 위한 Matrix 구조는 Fig.3 에서와 같이 입력층(Input Layer)의 입력이 P 개이고 X 는 $P \times 1$ 의 구조, 은닉층의 가중치 $W^{[1]}$ 은 $N \times P$ 의 구조, 은닉층의 바이어스와 활성화 함수를 거치기 전, 후의 출력은 $N \times 1$ 의 구조를 갖고 출력층의 가중치 $W^{[2]}$ 는 $1 \times N$ 의 구조를 가지며, 마찬가지로 출력층의 바이어스와 활성화 함수를 거치기 전, 후의 구조는 최종적으로 1×1 의 구조를 갖는다.




Fig. 3. Internal computation of Neural-Network filter

본 논문에서 사용한 MLP의 경우 필터링 전에 사전 파라미터 학습이 필요하다. 이 파라미터학습은 다음과 같은 과정으로 진행된다.

- ① 노이즈가 포함된 신호를 필터통과 시킨다.

- ② 이미 알고 있는 목적 신호 $s(k)$ 와 비교한다.
- ③ 오차 $e(k)$ 가 0이 되도록 각 가중치($W^{[1]}, W^{[2]}$)와 바이어스($b^{[1]}, b^{[2]}$)를 학습 시킨다.
- ④③에서 각 가중치와 바이어스는 정해진 학습률에 따라 변화한다.
- ⑤①의 과정을 오차 $e(k)$ 가 원하는 수렴범위에 들 때 까지 반복한다.
- ⑥ 원하는 수렴범위에 들면 각 가중치와 바이어스를 고정한다.

학습이 완료되면 신경망은 노이즈 필터 전체로 보았을 때 오차 $e(k)$ 가 줄어드는 알고리즘을 내부적으로 갖게 된다.

3. 파라미터 학습

학습에 사용한 신호(Fig.4 Training data)는 기 입력된 목적 신호와 주 입력을 비교하여 노이즈만을 추출하여 선정 하였으며 노이즈가 없는 신호(Amplitude를 0으로 한 신호)와 비교 하면서 그 오차($e(k)$)가 줄어드는 방향으로 학습을 실시하였다. 노이즈의 영향을 크게 하기 위해 센서의 감도는 최대로 고정된 상태에서 데이터를 얻어내었다. 교사신호의 데이터 수는 450개이며 학습 상수는 0.1로 선정하였다.

파라미터 튜닝 횟수는 교사신호용 노이즈와 파라미터 수정 후 샘플 데이터의 신호를 비교해 적절한 수준이라 판단되는 700회로 설정 하였다.




Fig.4 Training data

신경망의 구조는 처리 속도향상 및 고속처리 시의 데이터 량을 수정하기 쉽게 하기위해 P-N-1구조를 택하여 각 층의 뉴런의

수를 변화시켜 가면서 실시하였으며 최종적으로 18-7-1 의 구조를 선택 하였다.

이 시스템의 튜닝 파라미터 수는 각층의 가중치와 바이어스로 총 141개이고 학습 후 각 파라미터를 고정시킨 후 샘플 데이터로 다시 교사 신호를 넣으면 Fig.5 같은 결과로 필터링이 이루어 졌음을 알 수 있다.

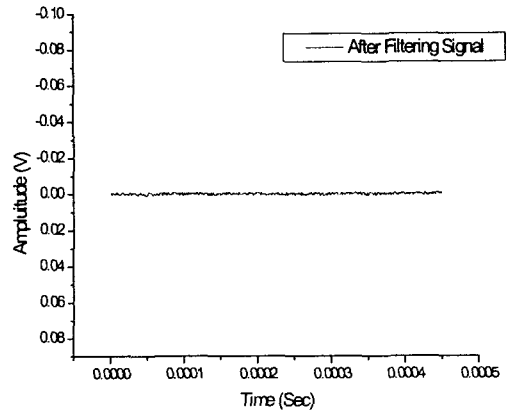


Fig.5 System Output with training data after training

4. 실험 및 결과

실험에 사용한 데이터는 Function Generator에서 직접 받아 들인 신호를 목적 신호($s(k)$)로 간주 하고 동일 신호를 가진기를 통해 물체운동으로 바꾼 후 이를 다시 센서를 통해 전압신호로 바꾼 신호를 주 입력 (Primary Input, $s(k) + x'(k)$)으로 설정하였다.

노이즈의 통계적 특성은 급변하지 않는다는 가정 하에 학습은 대표적 노이즈를 1회 (700번의 파라미터 튜닝) 만 실시하였고 추가 학습은 실시하지 않았다.

Fig. 6은 실험에 사용한 신호로서 100Hz 가진 신호를 0.01초 (sec)동안 1데이터의 시간 간격을 1×10^{-6} 초로 하였으며 총 1만개의 실험 데이터를 얻었다.

Fig. 6에서 목적 신호가 노이즈에 심하게 오염 되었다는 것을 알 수 있다. 현재 노이즈는 정현파 노이즈와 랜덤 노이즈가 모두 포함된 상태이다.

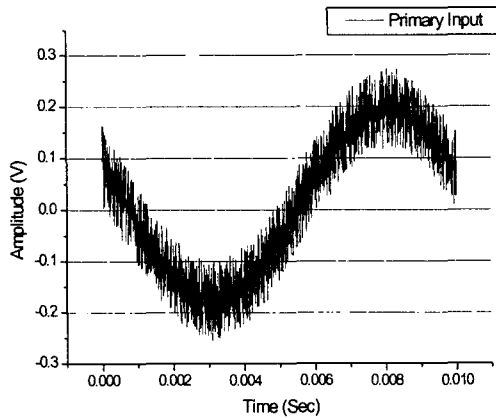


Fig.6 Primary Input

이를 Fig. 7과 같이 Primary Input을 450개의 단위의 유닛으로 묶어 1만 번의 연산을 수행 하였다. t_0 에서 t_{450} 까지의 데이터 유닛 d_1 을 필터링 하여 하나의 값 y_1 을 얻었으며 유닛 d_1 에서 가장 처음의 값 1 을 제거 하고 가장 최신의 값 451 을 취함으로서 d_1 보다 갱신된 유닛 d_2 를 얻을 수 있다. 갱신된 유닛 d_2 필터링 하여 y_2 를 얻을 수 있으며 y 값을 계속 적층해 나가면서 전체의 필터링 된 값을 얻어 내었다. 처음 t_{450} 까지의 시간 동안 필터링은 제대로 이루어지지 않으며 이는 필터링 초기의 지연시간으로 나타난다.




Fig.7 Divide Primary Input

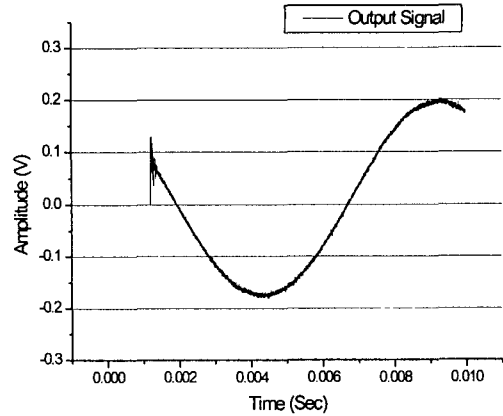


Fig 8. Output Signal

Fig. 8에서 필터링 후 대부분의 노이즈가 제거된 Output Signal을 확인 할 수 있었다. 신호 대 잡음 비(SNR)의 향상은 필터링 전 6.02[dB]에서 19.08[dB]로 향상되었다.

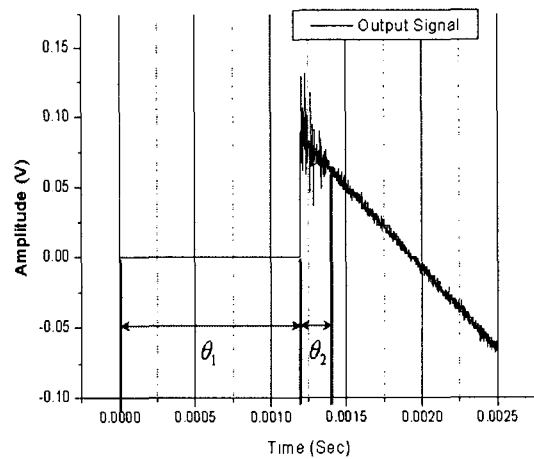


Fig.9 Phase Delay

Fig.9 에서 보이는 신호처리에 따른 필터의 무반응 시간 θ_1 에 의한 위상지연시간은 0.001195 sec로 위상으로 환산하면 21.51 Degree를 보였다. 필터링 개시 후 1 단위까지의 데이터를 받아들여 처리 하는 동안 걸린 지연시간 $\theta_2 (= t_{450})$ 는 0.00045sec로 1단위까지의 데이터 수 450에 해당하는 시간이다.

위상지연을 주로 유발 시키는 필터의 무반응 시간 θ_1 은 Hardware에 의한 처리속도 지연으로 시뮬레이션에 사용한 PC의 CPU 인 Pentium 4 2.4C 의 Buffer Memory Loadig시간

및 Ram과 CPU 상의 FSB(Front Side Bus) 속도, Mainboard의 Bus 클럭속도 (100MHz)등 총체적 Hardware의 성능에 의한 것으로 추정된다.

CPU의 처리 속도는 위상지연이 늘어나지 않는 것으로 미루어 안정된 것으로 나타났으며 처리속도 향상을 위해 Hyper-Threading 기법을 사용해 부분적 병렬처리를 행하였고 그 결과 연산 속도를 25~30% 향상시켜 사용하는 것이 가능하였다.

전체 데이터 처리량은 CPU의 연산 곱 처리속도 2468Mflops의 44%에 해당하는 987Mflops의 초당 처리 데이터량이 산출되었고 실험에 사용한 데이터가 0.000001 sec 의 시간 간격을 갖고 있는 것을 감안하면 1 회의 필터링에 987flops 의 연산량이 소모되었다는 것을 알 수 있다. 이는 H/W모니터링 프로그램인 "산드라 2002Pro" 를 기준으로 산출 하였다.

θ_2 의 경우 필터의 알고리즘에 따라 필연적으로 생기는 필터링 지연 시간으로 초반 데이터가 입력될시 필터에서 요구하는 450개 단위의 데이터 숫자에 미치지 못하므로 제대로 필터링이 되지 않은 Output 데이터가 산출되나 시간이 흐름에 따라 알고리즘구동에 필요한 데이터의 갯수 450개가 채워지면서 원하는 Output 신호가 출력되는 것을 알 수 있었다.

5. 결 론

본 논문에서는 특정 주파수를 갖지 않는 시변 노이즈들에 대한 원신호의 추출, 복원을 그 목적으로 한다.

이를 위해 MLP신경망 필터에 BP 알고리즘을 적용하여 파라미터(각 층의 가중치, 바이어스)를 튜닝한 후 파라미터를 고정하였다.

연속된 데이터의 처리를 위해 시뮬레이션을 통해 기 입력된 Primary Input 신호를 각각의 유닛단위로 묶어 필터링을 하였다.

유닛은 갱신하면서 연속적으로 필터링을 실시하였다. 유닛을 갱신하는 방법상 새로 얻은 유닛은 바로 전의 유닛에 비해 겨우 2개의 데이터만 바뀌었을 뿐으로 448개의 데이터는 중복 계산되었다. 이는 입력 데이터가 많을수록 보다 일반화된 값이 출력되는 신경망 필터의 특성을 보장해주고, 입력신호의 수와 출력신호의 양을 같게 해 주어 소실되는 데이터의 량을 없애주는 효과를 가져왔지만 필터링 초반의 지연시간($\theta_2 = t_{450}$)이 발생하였고 필터의 처리해야 할 데이터 량이 급증하였다. 신경망 필터의 초기에는 이 급증한 데이터를 처리하는 것이 불가능 했으므로 실시간 처리에 알맞은 알고리즘(LMS)을 따로 개발했다. 그러나

최근에는 Processor의 급속한 발달로 필터링 효율은 LMS 알고리즘 적용 선행적용 필터 보다 좋으나 실시간 데이터의 처리에 어려움이 많았던 BP 알고리즘의 MLP 구조의 신경망으로 실시간에 가까운 고속 데이터 처리를 행하는 것이 가능했고, 저주파 기준신호에서 노이즈를 처리 하는 것이 가능했다.

참 고 문 헌

(1) B. Widrow and S. D. Stearns, 1985 *Adaptive signal Processing* Printice-Hall, Inc., Englewood Cliffs, pp. 84~166

(2)B. Kosko, 1992, *Neural Networks for Signal processing*. Prentice-Hall International

(3)S. Haykin, 1991, *Adaptive Filter Theory*. Prentice-Hall, Inc., Englewood Cliffs, pp.29-48

(4)Hagan, Demuth, Beasle, 1996 *Neural Network Design*, PWS Publishing Company.

(5)B. Widrow 1975 "Adaptive noise cancelling : principle and applications" Proc. IEEE, Vol. 63, pp. 1692-1716

(6) W.G.Kencht, M.E. Schenkel, 1995"Neural Network Filters for Speech Enhancement" IEEE Trans. on Speech And Audio Processing, Vol. 3, No. 6, 433

(7) Woo-Hyuk Kwak, Won-Woo Park, Han-Go Choi 1998 Design of an Adoptive Noise Canceller using Neural Networks K.N.U.T Research Journal Vol.19, pp. 141~149

(8) Joong-Woo Kim, Seong-Gon Kong, 2001 Speech Enhancement under Noisy Enviroment using Neuro-Fuzzy Filter