마코프 모델을 이용한 펄스반복주기 변조형태 인식

速報 論文
52D-6-7

The Identification of Pulse Repetition Intervals Modulation using Markov Models Approach

金 鏞 佑* · 梁 海 元**
(Yong-Woo Kim · Hai-Won Yang)

Abstract - Many of modern radars use modulated pulse repetition intervals for the purpose of anti-aliasing and ECCM. The interception, analysis and identification of radar signals is a major function of a radar intercept receiver. In this paper, we discuss the identification of pulse repetition intervals modulation of radar signals which is one of the major parameters for the analysis of radar. We proposed a new algorithm based on Markov models approach. This approach is shown to be reliable and robust to the missing pulses, as well as to require only relatively few pulse data.

Key Words : EW, TOA, PRI, Modulation, Markov Model

1. 서 론

레이더는 펄스 형태의 전자파 신호를 대상 물체에 발사하고, 반사되어 돌아오는 신호를 수신하여 목표물의 위치 및 움직임을 탐지한다. 반면, 레이더에 대응하는 전자전(EW; Electronic Warfare) 장비는 레이더 신호를 수신, 분석하고 특징을 추출하여 레이더의 종류 및 상태 등을 식별한다. 전자전 장비가 분석하여야 할 레이더의 특성으로는 펄스의 주파수, 펄스폭, 펄스세기 등 전자파적 특성과, 펄스도착방향, 펄스도착시각 등과 같은 시공간적 특성이 있으며, 스캔주기, 펄스반복주기, 주파수변조특성 등 여러 펄스에 걸쳐 분석되어야 할 특성 등 다양한 것들이 있다.

레이더 신호를 분석하기 위한 많은 연구가 여러 가지 기법을 통하여 연구되어 왔다[1]-[5]. 그러나, 신형 레이더를 사용하는 최신 무기들은 복잡한 신호 변조 특성을 가지고 있어서, 고전적인 신호 분석 방법만으로는 탐지 및 인식이 점점 어려워지고 있다. 따라서, 본 논문에서는 레이더 신호를 확률론적(stochastic)으로 해석하는 방법을 적용해 보기로 한다. 널리 연구되고 있는 확률론적 방법으로는 은닉 마코프 모델(HMM; Hidden Markov Model)과 신경회로망(ANN; Artificial Neural Network)이 있다. 이 중에서 HMM[6]은 평범한 순차적 연산장치에서 사용하기에 적합한 구조를 가지며, ANN은 생체 신경망 체계의 대용량 병렬 연산을 모사하는 구조를 갖는다. 본 논문에서는 간단한 마코프 모델을 이용하여 레이더 펄스 신호의 펄스반복주기(PRI; Pulse Repetition Intervals) 변조(Modulation) 방식을 인식하여, 레이더의 종류를 탐지할 수 있는 방법에 대하여 연구하였다.

* 正 會 員 : 國防科學硏究所 先任硏究員
** 正 會 員 : 漢陽大學校 電子컴퓨터工學部 敎授 · 工博
接受日字 : 2003年 2月 10日
最終完了 : 2003年 4月 12日

2. 레이더 신호 특성

2.1 펄스반복주기 변조형태

레이더 신호의 여러 신호특성 중 본 논문의 연구 대상인 펄스반복주기 변조형태는 다음의 5가지로 분류할 수 있다.

o 고정(Constant) PRI

레이더 펄스가 전자전 장비에 수신된 시각(도착시각)을 TOA(Time Of Arrival)라고 할 때, 두 개 펄스의 TOA 간격을 DTOA(Difference in TOA)라고 하며[4], DTOA의 통계적 평균값을 펄스반복주기(PRI)라고 한다. 이 펄스반복주기가 일정한 펄스열(pulse train)을 고정 PRI 펄스열이라고 한다.

o 지터(Jitter) PRI

잡음성 오차로 인하여 불규칙한 펄스반복주기를 갖는 펄스열을 지터 PRI 펄스열이라고 한다. 지터 PRI 펄스열의 DTOA는 평균 PRI를 중심으로 가우시안 또는 유니폼 분포를 갖는다. 지터의 정도는 지터율로 나타낸다. 만일, 평균 PRI가 100 μsec이고, 지터율이 ±10%인 유니폼 분포를 갖는 지터라면 DTOA는 90~110 μsec사이의 값을 갖게 된다.

o 패턴(Pattern) PRI

펄스 간격이 정형화된 패턴에 의하여 변화되는 경우를 패턴 PRI 라고 한다. 변조 패턴은 사인파, 삼각파 등이 있다.

o 슬라이딩(Sliding) PRI

PRI값이 단조증가 또는 단조감소하는 경우를 슬라이딩 PRI 라고 한다. 단조증가 슬라이딩의 경우, PRI값이 최대값에 도달하면 최소값으로 내려가고 다시 증가해 가는 것을 반복한다

o Dwell & Switch PRI

이 PRI 변조 기법은 일정한 시간동안 P_0의 PRI를 사용하다 PRI를 P_1로 바꾸고, 또 일정한 시간 후에 다시 P_2로 바꾸는 식의 PRI 변조 방식이다.

2.2 누락펄스(Missing Pulses)

누락펄스란 레이더에서는 방사하였으나 전자전 수신기가 수신하지 못한 펄스를 의미한다. 누락펄스는 자체 레이더 신호 방사에 의한 블랭킹(blanking), 대기중의 산란이나 감쇄, 타 레이더 신호와의 중첩, 또는 수신기의 처리능력을 초과하는 순간적인 신호밀도증가로 인한 누락 등 여러 가지 원인으로 발생한다. 누락펄스는 레이더 신호의 통계적 특성을 왜곡시키므로, 정확한 신호분석을 위해서는 누락펄스를 고려한 강인한 알고리즘이 요구된다.

3. 펄스반복주기 변조형태 인식

3.1 기존의 방법

변조형태 인식을 위한 기존의 방법으로는 DTOA 히스토그램을 이용하는 방법[1]과 신경회로망을 이용하는 방법[4]이 있다. 히스토그램은 통계적 신호처리에 매우 널리 사용되는 기법으로서, PRI 분석 분야에서 전통적으로 사용되어온 방법이지만, 히스토그램에는 많은 데이터가 필요하다는 단점이 있다. 그림 1은 지터 PRI 펄스열의 DTOA 히스토그램이다. 1000개의 펄스로 구성한 (a)를 보면 DTOA가 가우시안 특성이 나타나 있다. 그러나, 50개의 펄스만으로 구성한 (b)는 이 펄스열이 가우시안 분포를 갖는 지터 펄스열이라고 단정하기 어렵다. 따라서, 이 방법은 레이더 사용 공격무기에 신속한 대응이 필요한 전자전 장비에 적용하기에는 적절치 않다.

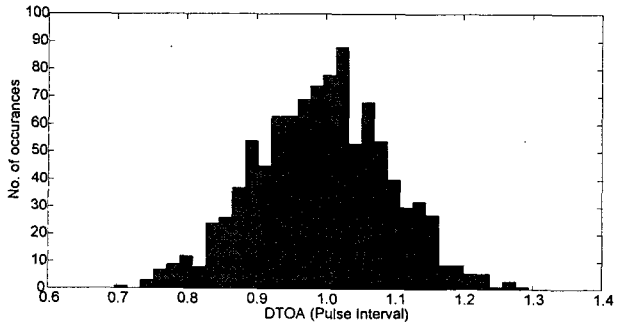

(a) Number of pulses = 1000

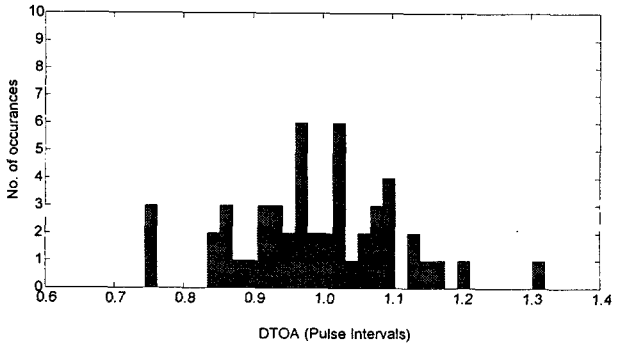

(b) Number of pulses = 50

그림 1 가우시안 지터 펄스열의 DTOA 히스토그램

Fig. 1 A DTOA histogram of a Gaussian Jittered PRI pulse train

신경회로망은 패턴의 형태와 종류를 인식하는 분야에서 매우 우수한 성능을 나타낸다. 그러나, 신경회로망은 회로망을 구성하는 레이어(layer)의 수 및 각 레이어 당 노드(node)의 개수, 회로망 내부에서 노드와 노드의 연결 강도를 결정하는 가중치(weight)의 초기 값 및 학습방법 등에 따라 성능이 달라지기도 한다. 특히, 본 논문의 문제에서는 최초 설계시 결정된 입력 레이어의 노드의 개수에 따라 탐지할 수 있는 변조패턴의 최대 길이가 고정되어, 입력 레이더의 노드 개수보다 큰 변조주기를 갖는 레이더 펄스열이 수신되는 경우 정확한 인식이 불가능할 수 있다.

따라서, 본 논문에서는 히스토그램 방식에 비해 상대적으로 적은 개수의 펄스만으로도 변조형태 인식이 가능하며, 인식에 필요한 펄스의 개수를 필요에 따라 유연성 있게 조절할 수 있는 구조를 갖는 마코프 모델(Markov Model)을 이용한 변조형태 인식 알고리즘을 제안한다.

3.2 마코프 모델 (Markov Model)

이산시간, 이산상태로 모델링할 수 있는 어떤 시스템이 있다고 하자. 이 모델은 정수(integer)로 번호를 부여한 유한한 개수의 상태(state)를 가지며 이산 시간이 흐름에 따라 시스템의 상태가 다른 상태로 변해 간다고 가정하면, 이 모델의 구조는 상태의 개수와 허용 가능한 상태 천이에 의해서 결정된다[6].

이산시간 k에서 관찰한 모델의 상태를 $x(k)$라고 하면, $x(1), x(2), \cdots, x(K)$는 시간 K까지 모델의 상태 관측 시퀀스가 된다. 모델이 S개의 상태(state)로 구성된다고 하자. $1 \le i,j \le S$인 임의의 i, j에 대하여, 시간 $k-1$에서 상태가 i이었다면, 시간 k에서 상태 j로 천이할 상태천이확률(state transition probability)은 (1)과 같이 표현된다.

$$\Pr\{x(k)=j \mid x(k-1)=i\} = a_k(j|i) \tag{1}$$

그런데, 모델링되는 시스템이 시간의 흐름에 따라 상태천이확률이 달라지지 않는 시불변 시스템이라고 하면, 상태천이확률은 시간 k에 무관하므로 그냥 $a(j|i)$로 표현할 수 있으므로, 간단히 a_{ij}라고 표현하기로 하자.

$1 \le i,j \le S$인 모든 i, j에 대한 상태천이확률을 정리한 행렬을 상태천이행렬 (state transition matrix)이라고 하면, 상태천이행렬은 (2)와 같이 정의된다.

$$\boldsymbol{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1(S-1)} & a_{1S} \\ \vdots & & a_{ij} & & \vdots \\ a_{S1} & a_{S2} & \cdots & a_{S(S-1)} & a_{SS} \end{bmatrix} \tag{2}$$

여기서 상태천이행렬 $\boldsymbol{A}$의 각 행(row)의 합은 항상 1이 된다. 시간 k에서 $x(k)$가 임의의 상태 s에 있을 상태확률(state probability)을 $\Pr(x(k)=s)$이라고 하면, $1 \le s \le S$인 모든 s에 대한 상태 확률을 (3)과 같은 상태확률벡터 (state probability vector) $\boldsymbol{P}(k)$로 표현할 수 있다.

$$P(k) \equiv \begin{bmatrix} \Pr(x(k)=1) \\ \Pr(x(k)=2) \\ \cdots \\ \Pr(x(k)=S) \end{bmatrix}^T \tag{3}$$

$P(k)$와 A를 알면 다음과 같이 $P(k+1)$을 구할 수 있다.

$$P(k+1) = P(k)A \tag{4}$$

$k \to \infty$가 되면, 시스템은 $P(k)$의 초기값인 $P(1)$의 확률 분포 값에 상관없이 평형상태(equilibrium state)에 수렴하게 되어 $P(k+1) = P(k)$가 된다. 따라서 평형상태에서의 $P(k)$는 상수 벡터 $P = [p_1\ p_2\ \cdots p_S]$로 나타낼 수 있다.

따라서, $k \to \infty$일 때 (4)는 다음과 같이 정리될 수 있다.

$$P(A-I) = 0_{1\times S} \tag{5}$$

그런데 homogeneous한 (5)만으로는 P를 구할 수 없으므로, non-homogeneous한 보조방정식 (6)을 추가하면 평형상태에서의 상태확률벡터 P를 구할 수 있다[7].

$$\sum_{i=1}^{S} p_i = 1 \tag{6}$$

이렇게 계산된 상태천이행렬과 평형상태에서의 상태확률벡터를 원소로 하는 집합 M을 마코프 모델이라 하고, (7)과 같이 표현한다.

$$M = \{ A,\ P \} \tag{7}$$

마코프 모델이 어떤 시스템을 모델링하기 위해서는 학습이 필요하다. 마코프 모델의 학습이란 행렬 A와 벡터 P의 값을 결정하는 일이다. A의 원소 a_{ij}를 결정하는 방법에는 두 가지 방법이 있다[8].

- o **파라미터적 접근방법** : 상태천이확률의 확률밀도함수(PDF)를 알고 있다면, 수식적으로 확률 값을 구할 수 있다.
- o **비-파라미터적 접근방법** : 이 경우는 반복된 실험으로 축적된 통계적 데이터를 이용하여, (8)과 같이 상태천이 확률 값을 예측한다.

$$a_{ij} = \frac{N(j|i)}{N(i)} \tag{8}$$

여기서, $N(i)$는 시스템의 상태가 i이었던 횟수이고, $N(j|i)$는 상태가 i에서 j로 천이된 횟수이다. 모든 a_{ij}가 결정되면 p_i는 (5)와 (6)으로 계산될 수 있다.

3.3 마코프 모델을 이용한 변조형태인식

레이더 펄스의 PRI 변조형태를 하나의 시스템으로 볼 때, 각 변조형태를 마코프 모델로 모델링하는데 필요한 상태(state)를 결정해야 한다.

k번째 펄스의 TOA가 t_k일 때, 인접한 두 펄스의 TOA 간격 DTOA는 $d_k = t_{k+1} - t_k$와 같이 계산된다. 이 때, 인접한 두 DTOA들의 간격 D^{2}TOA를 z_k로 표현하면 (9)와 같이 계산될 수 있다.

$$z_k = d_{k+1} - d_k = t_{k+2} - 2t_{k+1} + t_k \tag{9}$$

여기서 $k = 1,2,\cdots,K-2$이며 K는 펄스의 개수이다. 이 때, z_k의 부호를 $\zeta(k)$라고 하고 (10)과 같이 정의하자.

$$\zeta(k) = sgn(z_k) \tag{10}$$

실제 데이터에서는 측정 및 양자화 오차가 존재하므로 (10)의 부호 함수는 다음과 같이 오차 범위를 허용해야 한다.

$$sgn(x) = \begin{cases} -1, & \text{if } x \le -\varepsilon \\ 0, & \text{if } |x| < \varepsilon \\ 1, & \text{if } x \ge \varepsilon \end{cases} \tag{11}$$

여기서 ε은 매우 작은 상수이다.

값 $\zeta(k)$의 누적합(cumulated sum) $S_{cs}(k)$를 (12)와 같이 계산한다. 전체 데이터의 개수가 $K-2$개이고 각 $\zeta(i)$의 값이 -1, 0, 1중 한가지 값을 가지므로, 누적합 $S_{cs}(k)$의 값은 [-1, 1]의 범위 내에 존재하게 된다. 이 $S_{cs}(k)$가 각 PRI 변조형태를 구분할 수 있는 특징을 만들어낸다.

$$S_{cs}(k) = \frac{1}{K-2}\left(\sum_{i=1}^{k} \zeta(i)\right) \tag{12}$$

고정 PRI의 경우 $d_k = C$(상수)이므로 z_k는 항상 0이다. 따라서, $\zeta(k)$도 0이 되며 누적합 $S_{cs}(k)$도 모든 k에 대하여 0이 된다. 또한, 패턴 PRI 중 패턴함수가 사인파인 경우는 z_k가 코사인이 되며 $\zeta(i)$는 1과 -1을 일정 기간씩 반복하는 형태가 된다. 따라서 누적합 $S_{cs}(k)$는 삼각형의 형태를 반복하게 된다. 단조증가 슬라이딩 (▲), 패턴(*), Dwell & Switch(◇), 그리고 지터 PRI(-)의 $S_{cs}(k)$ 그래프를 그림 2에 보였다.

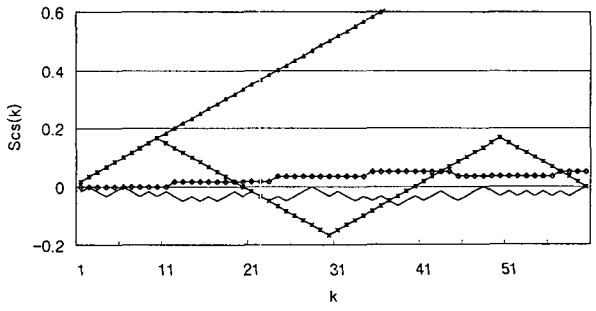

그림 2 변조형태별 펄스번호 대 S_{cs} 그래프

Fig. 2 The pulse number to S_{cs} graph for each PRI modulation types

이 $S_{cs}(k)$의 변화를 마코프 모델의 상태(state)로 정의하면, 상태는 유지, 증가, 감소의 3가지 값을 갖는다. 따라서, 모델 내에서 상태의 개수는 $S=3$이 되며, 각 k번째 펄스에서의 상태는 (13)과 같이 계산될 수 있다.

$$x(k=1)=s_1$$
$$x(k>1)=\begin{cases} s_1, & \text{if } S_{cs}(k)-S_{cs}(k-1)=0 \\ s_2, & \text{if } S_{cs}(k)-S_{cs}(k-1)>0 \\ s_3, & \text{if } S_{cs}(k)-S_{cs}(k-1)<0 \end{cases} \tag{13}$$

여기서, s_1='유지', s_2='증가', s_3='감소'의 상태를 의미한다. 변조형태를 알고있는 펄스열의 TOA 데이터로부터 (9)~(12) 과정을 거쳐 (13)의 $x(k)$를 구하고, (8)의 방법으로 a_{ij}가 학습되면 상태천이행렬 $\boldsymbol{A}$ 결정되고, $\boldsymbol{A}$를 이용하여 평형상태 상태확률벡터 $\boldsymbol{P}$를 각각 계산하면 (7)의 마코프 모델이 한 개 구성된다. 이와 같은 방법으로 모두 M개의 마코프 모델을 (14)와 같이 구성한다.

$$\boldsymbol{M}_m=\{\boldsymbol{A}_m, \boldsymbol{P}_m\} \qquad (m=1, \cdots, M) \tag{14}$$

여기서 M은 인식해야할 PRI 변조형태의 종류로 결정된다.

PRI 변조형태 인식을 위하여 수신한 레이더 펄스열로 구성한 마코프 모델을 (15)로 표현하자.

$$\boldsymbol{M}^*=\{\boldsymbol{A}^*, \boldsymbol{P}^*\} \tag{15}$$

PRI 변조형태 인식의 최종 목표는 $\boldsymbol{M}^*$와 가장 유사한 $\boldsymbol{M}_m$을 찾는 것이다. 유사도는 (16)의 평가함수로 평가한다.

$$J_m=\alpha\|\boldsymbol{A}_m-\boldsymbol{A}^*\|^2+(1-\alpha)\|\boldsymbol{P}_m-\boldsymbol{P}^*\|^2 \tag{16}$$

여기서 $\|\cdot\|$는 정방행렬 및 벡터의 노음이며, $\alpha(0<\alpha<1)$는 상태천이행렬과 상태확률백터의 비중을 조절하기 위한 계수이다. 따라서, J_m값이 가장 작은 변조형태가 분석대상 레이더 펄스열의 변조형태로 판정된다. 본 논문에서 제안한 PRI 변조형태 인식시스템의 구조를 그림 3으로 나타내었다.

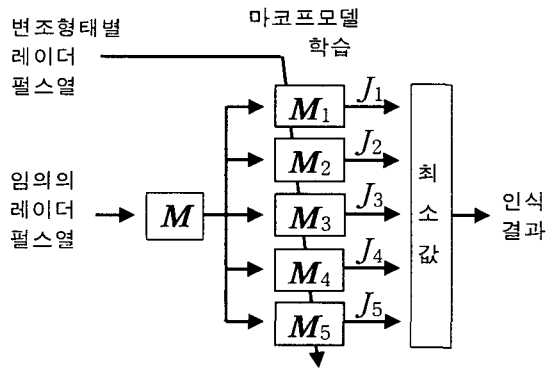

그림 3 마코프 모델을 이용한 PRI 변조형태인식 시스템구조
Fig. 3 System structure of PRI modulation identifier using Markov models

4. 모의 실험

4.1 PRI 변조형태 인식시스템 구성

제2장에서 설명한 변조형태 중 고정 PRI는 쉽게 인식이 가능한 형태이므로 인식 대상에서는 제외하며, 슬라이딩 PRI는 단조증가와 단조감소로 나누어 인식한다. 따라서, 패턴, 단조증가, 단조감소, D&S, 그리고 지터의 5가지 변조형태로 구분하여 변조형태를 인식하기로 한다.

(11)의 파라미터 ε은 0.1 μsec를 사용하였으며 각 변조형태별 마코프 모델을 생성하기 위한 학습에는 각 변조형태별로 약 2만~3만개씩의 모의 레이더 펄스를 사용하였다. 슬라이딩이나 패턴 PRI의 주기는 20~60펄스에서 생성하였으며, D&S의 스위칭 단수는 3~5단으로 하였고, 지터는 지터율 ±5%~±15%의 유니폼 분포로 생성하였다. 또한, 누락펄스가 전혀 없는 경우와 5% 및 10%의 누락펄스가 있는 경우를 포함하였다.

학습 중 상태천이행렬의 임의의 i번째 행의 수가 한 번도 발생하지 않아 $\sum_{j=1}^{3} a_{ij}=0$이 되는 것을 방지하기 위해서 모든 $N(j|i)$의 값은 학습시작 전에 1로 초기화하였다. 실제 학습에 사용되는 펄스의 수가 약 2만~3만개 정도 되므로 0대신 1로 초기화하는 것은 문제가 되지 않는다. 학습이 완료되면 5가지 변조형태별 마코프모델 $\boldsymbol{M}_m$ $(m=1,2,\cdots,5)$이 완성된다.

본 알고리즘의 성능 검증을 위한 PRI 변조형태 인식실험에 사용한 모의 신호는 각 변조형태별로 누락펄스가 없는 경우와 5%, 10%, 15%의 누락펄스를 갖는 경우의 4가지 경우를 발생하였다. 또한, 각 경우에서 인식에 사용하는 펄스 샘플의 수를 10, 15, 20, 25, 30, 40, 50, 60의 8가지 경우로 변경해가며 인식률의 변화를 비교하였다.

상태천이행렬과 상태확률백터의 비중을 조절하기 위한 (16)의 계수 α가 변조형태 인식률에 영향을 미칠 수 있다. 최적의 α를 찾기 위해서는 α값을 (0, 1)사이에서 변화시켜가며 실험해보고 그 결과로 α값을 결정해야 한다.

실험결과, α값의 변화에 따른 인식률의 변화는 크지 않았으며, 각 변조형태, 누락펄스, 펄스 샘플의 수에 따른 변화 추세도 일정한 함수관계를 갖지 않았다. 따라서, 정량적으로 최적인 α값을 찾을 수는 없었으나, 상태천이행렬과 상태확률백터의 비중을 1:1로 하는 α=0.5를 사용한 결과 그림 4~7의 결과와 같은 인식성공률을 보일 수 있었다.

4.2 실험 결과

o 패턴 PRI

그림 4는 정현파 패턴변조 PRI 펄스열의 인식결과이다. 그림에서 4개의 선은 누락펄스가 없는 경우(○), 누락펄스율이 5%인 경우(×), 10%인 경우(□), 그리고 15%인 경우(▽)의 인식결과를 의미한다. 가로축은 변조 인식에 사용한 펄스 샘플의 개수이며, 세로축은 인식 성공률이다. 패턴 주기가 20펄스인 (a)에서, 누락펄스가 없는 신호의 경우는 100%의 인

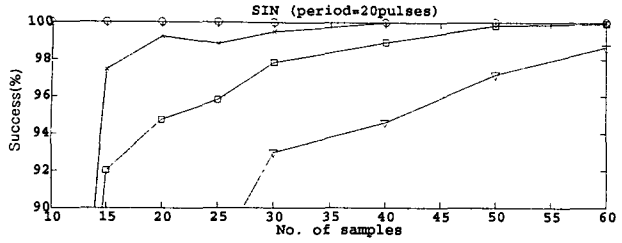

(a) Pattern period = 20 pulses

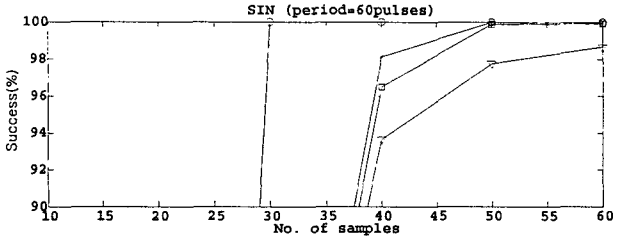

(b) Pattern period = 60 pulses

그림 4 정현파 패턴의 인식결과

Fig. 4 Identification result of sine pattern

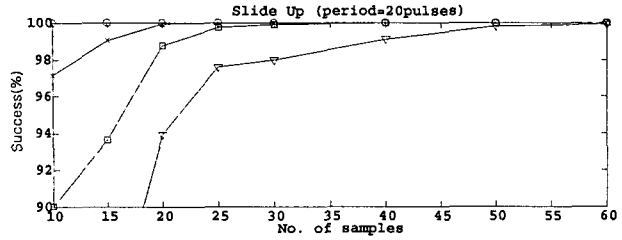

(a) Period = 20 pulses

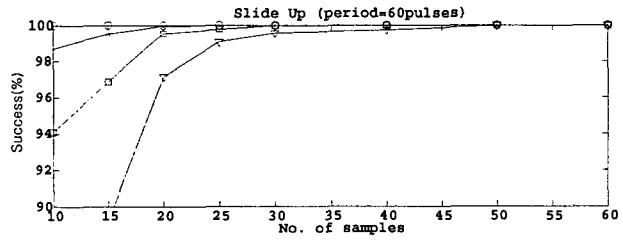

(b) Period = 60 pulses

그림 5 슬라이딩 PRI의 인식결과

Fig. 5 Identification result of sliding PRI

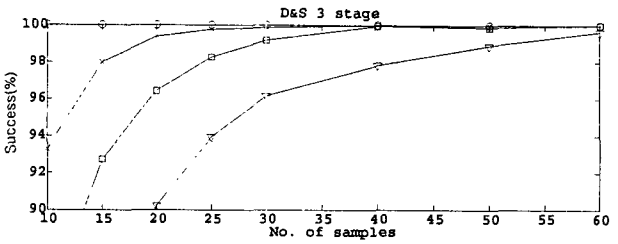

(a) Stage = 3

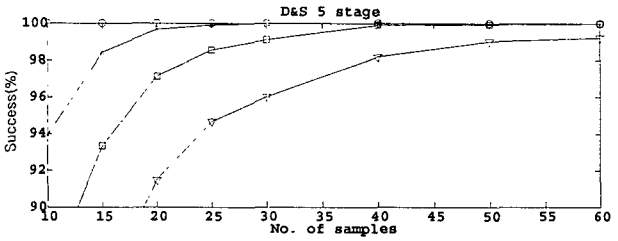

(b) stage = 5

그림 6 Dwell & Switch의 인식결과

Fig. 6 Identification result of D&S

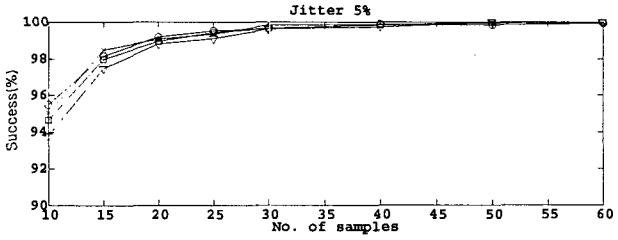

(a) Jitter rate = ±5%

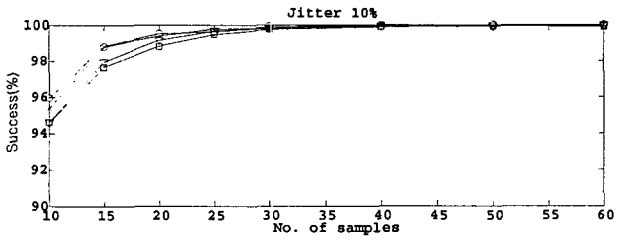

(b) Jitter rate = ±10%

그림 7 지터 PRI의 인식결과

Fig. 7 Identification result of jitter PRI

식 성공률을 보였으나, 누락펄스율이 점차 커짐에 따라 인식에 실패하는 비율이 점차 커짐을 알 수 있다. 또한, 같은 누락펄스율을 갖는 경우, 인식에 사용되는 샘플의 수가 많으면 인식 성공률이 높아짐을 알 수 있다.

누락펄스율이 10%이내에서 샘플의 개수가 60개 이상이면 거의 100%의 인식 성공률을 나타낸다. 그림 4의 (b)는 주기가 60펄스인 경우의 인식 결과이다. (a)의 경우보다 패턴 주기가 길기 때문에 인식에 필요한 최소 펄스의 수가 40펄스로 많아졌다. 그러나 두 경우 모두 60개의 펄스를 사용하여 98% 이상의 인식성공률을 보였다.

o 슬라이딩 PRI

그림 5는 주기가 각각 20, 60인 슬라이딩 PRI 펄스열의 패턴변조 인식결과이다. 두 경우 모두 누락펄스가 없는 경우는 100%의 인식 성공률을 보였으며, 샘플의 수가 60개인 경우 누락펄스의 비율에 관계없이 모든 경우에서 100%의 인식 성공률을 보였다.

o Dwell & Switch

그림 6은 각각 3단과 5단 D&S 펄스열의 인식 결과이다.이 경우도 누락펄스가 없는 경우는 100%의 인식 성공률을 보였

으며, 누락펄스 및 샘플의 수에 따른 인식 성공률의 변화는 앞의 경우와 유사한 추세를 보였다. 샘플 수 60개에서는 모든 경우에 99%이상의 인식성공률을 보였다.

o 지터 PRI

그림 7은 지터율 ±5%, ±10%인 유니폼 분포의 지터 PRI 펄스열의 인식 결과이다. 지터 PRI의 인식성공률이 가장 높게 나타났다. 지터신호 자체가 잡음적 특징을 가지고 있기 때문에 누락펄스의 비율에 따라 인식률차이가 거의 없으며, 지터율이 커질수록 오히려 인식률이 조금이나마 향상되는 모습이 보인다. 샘플의 수가 40펄스 이상인 경우 99.5%이상의 인식 성공률을 보였다.

5. 결 론

레이더 펄스 신호의 펄스반복주기 변조형태를 인식하기 위한 새로운 방법으로서, 마코프 모델을 이용한 방법을 제시하였고 이의 성능을 검증하기 위한 모의 실험을 실시하였다. 이 방법은 수십 개의 펄스 데이터만으로도 변조형태 인식이 가능하므로 수백 개 이상의 많은 펄스가 필요한 히스토그램 방법에 비하여 신호수집에 소요되는 시간이 적게 소요되므로, 레이더를 사용하는 공격무기에 대응하기 위한 전자전 장비의 신호분석 시간 단축에 기여할 수 있으며, 변조패턴의 주기에 구애받지 않는 마코프 모델의 생성이 가능하므로, 고정된 노드의 개수로 인하여 인식 가능한 패턴 주기가 제한 받는 신경회로망에 비하여 인식에 필요한 펄스 개수를 필요에 따라 적절히 변경해가며 인식할 수 있는 유연성을 가지고 있다.

모의 실험 결과, 최대 15%의 누락펄스 상황에서 60개의 레이더 펄스만으로 98.6%이상의 인식성공률을 보였으며, 10%이내의 누락펄스 상황에서는 50개의 펄스만으로도 99.8% 이상의 인식성공률을 보였다.

참 고 문 헌

[1] D. J. Milojevic and B. M. Popovic, "Improved algorithm for the deinterleaving of radar pulses" IEE Proc.-F, Vol. 139, No. 1, pp. 98-104, February 1992.

[2] A. Logothetis and V. Krishnamurthy, "An Interval-Amplitude Algorithm for Deinterleaving Stochastic Pulse Train Sources," IEEE Trans. on Signal Processing, Vol., 46, No. 5, pp 1344-1350, May 1998.

[3] K. Nishiguchi and M. Kobayashi, "Improved Algorithm for Estimating Pulse Repetition Intervals", IEEE Tran. on Aerospace and Electronic Systems, Vol. 36, No. 2, pp.407-421, April 2000.

[4] G. P. Noore, "A Neural Approach to Automatic Pulse Repetition Interval Modulation Recognition", Proc. of Information, Decision and Control, IEEE, pp. 213-218, 1999.

[5] 김용우, 양해원, "2차원 TDOA 히스토그램을 이용한 스태거 PRI 펄스열의 펄스반복주기 탐지 알고리즘", 제어·자동화·시스템공학 논문지, 제8권 제8호, pp. 673-681, 2002. 8.

[6] L. R. Rabiner, "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition", Proc. of the IEEE, Vol. 77, No. 2, pp. 257-286, February 1989.

[7] R. W. Hamming, Coding and Information Theory, Prentice-Hall, pp. 80-84. 1986.

[8] T. Breikin, V. Arkov and G. Kulikov, "On Stochastic System Identification: Markov Models Approach", Proc. of the 2nd Asian Control Conference, Seoul, pp. 22-25, July 1997.

저 자 소 개

김 용 우 (金 鎔 佑)

1963년 7월 13일생. 1987년 한양대 전기공학과 졸업. 1989년 동 대학원 전기공학과 졸업(공학석사). 1996년~현재 동 대학원 박사과정. 1989년~현재 국방과학연구소 선임연구원.

Tel: 042-821-3531. Fax: 042-821-2225.
E-mail: ywkim63@add.re.kr

양 해 원 (梁 海 元)

1950년 3월 20일생. 1971년 서울대 전기공학과 졸업. 1973년 동 대학원 전기공학과 졸업(공학석사). 1982년 일본 Kyoto대 전기공학과 졸업(공학박사). 1993년 미국 Yale대 방문교수. 1986~현재 한양대학교 전자컴퓨터공학부 교수.

Tel: 031-400-5162. Fax: 031-406-7769.
E-mail: hwyang@hanyang.ac.kr