Journal of the KIMST, Vol. 23, No. 1, pp. 1-10, 2020
ISSN 1598-9127(print), 2636-0640(online)
DOI https://doi.org/10.9766/KIMST.2020.23.1.001

Research Paper 센서 · 신호처리 부문

가우스 요소함수 망에 기초한 재밍 파라미터 추정

황태현[1] · 길이만[*,2] · 이현구[3] · 김정호[3] · 고재헌[3] · 조제일[4] · 이정훈[4]

[1] 성균관대학교 수학과
[2] 성균관대학교 소프트웨어대학
[3] LIG넥스원㈜ 전자전연구소
[4] 국방과학연구소 제2기술연구본부

Estimation of Jamming Parameters based on Gaussian Kernel Function Networks

TaeHyun Hwang[1] · Rhee Man Kil[*,2] · Hyun Ku Lee[3] · Jung Ho Kim[3] · Jae Heon Ko[3] · Jeil Jo[4] · Junghoon Lee[4]

[1] *Department of Mathematics, SungKyunKwan University, Korea*
[2] *College of Computing, SungKyunKwan University, Korea*
[3] *EW(Electronic Warfare) R&D Lab, LIG Nex1 Co. Ltd., Korea*
[4] *The 2nd Research and Development Institute, Agency for Defense Development, Korea*

(Received 30 August 2019 / Revised 30 December 2019 / Accepted 17 January 2020)

ABSTRACT

Effective jamming in electronic warfare depends on proper jamming technique selection and jamming parameter estimation. For this purpose, this paper proposes a new method of estimating jamming parameters using Gaussian kernel function networks. In the proposed approach, a new method of determining the optimal structure and parameters of Gaussian kernel function networks is proposed. As a result, the proposed approach estimates the jamming parameters in a reliable manner and outperforms other methods such as the DNN(Deep Neural Network) and SVM(Support Vector Machine) estimation models.

Key Words : Electronic Warfare(전자전), Radar Pattern(레이더 패턴), Adaptive Jamming(자율형 재밍), Gaussian Kernel Function Network(가우스 요소함수 망)

기 호 설 명

$\boldsymbol{x}$: 입력 데이터
y : 재밍 파라미터
$\hat{y}$: 재밍 파라미터 예측값
$\overline{y}$: 학습 재밍 파라미터의 평균 값
ϕ_j : j번째 가우스 요소 함수

* Corresponding author, E-mail: rmkil@skku.edu
Copyright ⓒ The Korea Institute of Military Science and Technology

c_j : j번째 가우스 요소 함수 중심
σ_j : j번째 가우스 요소 함수 너비
β : 너비 보정 초 매개변수

1. 서 론

현대전에서는 전자전(EW: Electronic Warfare)이 전쟁의 승패를 좌우하는 매우 중요한 요인이 되고 있으며 전자전에서는 특히 실시간 및 정확한 정보처리가 필수적인 요소로 부각되고 있다[1,2]. 본 연구는 전자전 분야에서 다양한 레이더 신호 분석(항공기, 선박 등)을 통해, 유효한 재밍 신호를 발생하기 위한 파라미터를 자율적으로 추정하는 효과적인 방법론을 구현하고자 한다. 이와 관련된 기능을 수행하기 위하여, 레이더를 이용하여 방사체의 특성들로부터 적절한 재밍 파라미터를 추정하는 부분에 있어서 우수한 성능을 갖추는 것이 전자전에서 매우 중요하다. 기존의 재밍 파라미터를 추정하는 방법은 상대측 레이더 신호로부터 적절한 특성들을 추출하여, 어떤 재밍 파라미터가 효과적인지에 대하여 전자전 관련 전문가가 데이터베이스(DB)에 저장되어있는 데이터를 바탕으로 경험적으로 선정하는 방식으로 이루어졌다. 이러한 방법의 수행을 위해서는 전자전 분야의 뛰어난 전문가가 필요할 뿐 아니라, 전자전 장비의 운용 중 신규 신호를 수신하여 실시간으로 수행되어야할 재밍의 특성상 촌각을 다투는 상황에서 전문가의 분석 및 재밍 파라미터 추정을 수행하는 것은 대단히 비효율적이다. 또한 탐지된 레이더 신호가 기존에 탐지된 적 없는 즉, 데이터베이스에 존재하지 않는 신호인 경우 재밍 파라미터 회귀 자체가 불가능하다. 이러한 문제를 해결하기 위해 자동적으로 수신된 레이더 신호를 분석하여 그에 적절한 재밍 신호를 발생 할 수 있는 재밍 기법 선정과 재밍 파라미터 추정을 가능하게 하는 알고리즘이 요구된다.

본 논문에서는 이를 해결하기 위한 방법으로 방사체로부터 수집되는 레이더 신호 패턴에 따라 적절한 특징을 추출하고, 그 특징을 입력 값으로 사용하여 재밍 파라미터 값을 출력하는 임의의 비선형 함수를 근사하는 방법을 제공하고자 한다. 이와 관련하여 본 논문에서 제시하는 재밍 파라미터 추정의 과정은 Fig. 1과 같다. 추정과정은 먼저 레이더 패턴을 분석하여 방사체 유형을 분류하고 각 유형에 따른 재밍 파라미터를 추정하는 시스템을 구성하였다. 여기서 레이더 유형을 분류하는 방법으로 클래스 확률을 추정하는 클

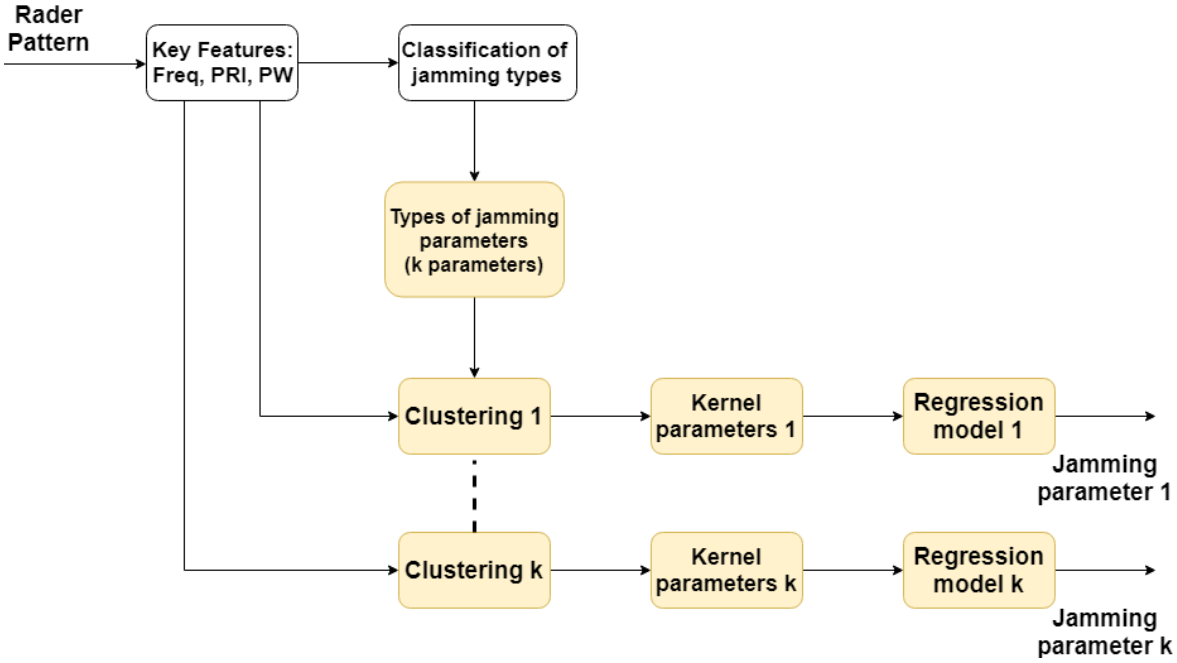

Fig. 1. The flow chart of estimating jamming parameters

래스 확률 출력 네트워크[3]가 사용되었다. 이 방법은 각 방사체 유형에 따른 레이더 패턴의 주요 특징에 대한 확률 분포를 베타분포로 변환한 후 이를 모델링하여 각 방사체 유형에 대한 확률을 추정하여 분류하는 방법이다. 또한 재밍 파라미터를 추정하기 위하여 방사체 유형에 따라 레이더 특징 자료를 재구성하여 레이더 특징 공간과 재밍 파라미터 사이의 사상 관계를 비선형 회귀모형으로 가우스 요소함수 망(Gaussian Kernel Function Network, GKFN)을 이용하여 추정하였다. 기존의 알려진 GKFN은 예측 오차에 따라 커널 함수를 만드는 방법을 사용한 반면[4,5], 본 논문에서는 출력 값에 근거한 입력 공간의 군집화를 이용한 모델 파라미터를 추정하는 새로운 방법과 입력 값의 각 차원의 분산을 고려한 Mahalanobis 거리를 이용하였다. 그 결과 재밍 파라미터 추정에 있어 전자전 전문가와 비견될 정도로 일관된 추정 성능을 발휘 할 뿐 아니라 함수 근사에 있어서 대표적으로 사용되는 DNN (Deep Neural Network), SVM(Support Vector Machine)과 비교하여 제안된 방법이 우수한 성능을 보임을 확인할 수 있었다.

본 논문은 2장에서 재밍 파라미터 추정을 위한 GKFN의 구조 및 학습 알고리즘을 설명하고, 3장에서는 전자전 전문가의 의견을 반영한 레이더/재밍 모의 신호[6]를 이용하여 실험결과를 제시한다. 그리고 4장에서 본 논문의 결론을 제시한다.

2. 가우스 요소함수 망

본 연구에서 주어진 레이더 패턴은 PDW(Pulse Description Word)형태의 데이터 단위를 사용하는데, PDW의 리스트에는 ToA(Time of Arrival), AoA(Angle of Arrival), Frequency, FMOP(Frequency Modulation On Pulse), PW(Pulse Width), PA(Pulse Amplitude), PRI(Pulse Repetition Interval) 등으로 구성되어 있다. 이 중 해당 방사체가 사용하는 주파수 대역인 Frequency와 방사체가 운용하는 Pulse의 시간간격인 PRI, 그리고 Pulse의 폭을 나타내는 PW 수치의 3차원 입력벡터와 재밍 파라미터 사이의 함수 관계를 근사하고자 한다. 미지의 비선형 함수를 근사하는 모델로 방사 기저함수 네트워크(Radial Basis Function Network, RBFN)의 하나인 GKFN을 사용하였다.

RBFN은 입력 층, 은닉 층, 출력 층의 3개의 층에서 활성화 함수로 방사 기저함수(Radial Basis Function, RBF)를 사용한 신경망이다. RBF란 입력 공간에서의 한 점과의 입력 값 사이의 거리에 의해서만 함수 값이 결정되는 다음의 형식을 갖는 실함수(Real valued function)이다[7] :

$$\varphi(\boldsymbol{x}) = \sum_{i=0}^{m} \alpha_i \rho(\|\boldsymbol{x}-\boldsymbol{c}_i\|), \tag{1}$$

여기서 $\boldsymbol{x} \in R^E$: 입력 벡터, $\rho : R \rightarrow R$: 실함수,
m : 은닉층의 뉴런 개수, 그리고
$\boldsymbol{c}_i$: i번째 유닛의 중심.

잘 알려진 RBF로는 다음과 같은 가우스 요소함수(Gaussin Kernel Function, GKF)가 사용된 네트워크를 GKFN이라 한다 :

$$\rho(\|\boldsymbol{x}-\boldsymbol{c}_i\|) = \exp\left(\frac{-(\boldsymbol{x}-\boldsymbol{c}_i)^T(\boldsymbol{x}-\boldsymbol{c}_i)}{2\sigma_i^2}\right). \tag{2}$$

GKF 이외에도 RBF의 성질을 만족하는 함수 중에서 GKF이 비선형 함수를 근사하는데 뛰어난 성능을 갖는다는 것이 잘 알려져 있다[7]. 뿐만 아니라 GKFN 모형은 높은 비선형성을 가진 비모수적 추정방법일 뿐 아니라 커널 함수의 국소 성(Locality)을 통한 증분 학습에도 적합하기 때문에 확장성 또한 뛰어난 것으로 알려졌다[4,5,8]. 기존의 GKFN의 파라미터를 학습하는 방법으로 [5]에서 효율적인 방법을 제시하고 있지만, 본 논문에서는 입력 값의 각 차원에 따른 분산을 고려한 Mahalanobis 거리를 사용한 GKFN을 제시하고, 출력 값에 근거한 입력공간의 군집화를 이용한 새로운 학습 알고리즘을 제시하고자 한다. 데이터의 각 차원의 분산 값을 이용한 GKFN은 다음과 같다 :

$$\hat{f}(\boldsymbol{x}) = \sum_{j=0}^{m} w_j \phi_j(\boldsymbol{x}), \tag{3}$$

$$\phi_j(\boldsymbol{x}) = \exp\left(\frac{-d(\boldsymbol{x}, \boldsymbol{c}_j, \boldsymbol{\sigma}_j)^2}{\beta}\right),$$

$$\phi_0 = 1 \text{ (Bias term)}, \; d(\boldsymbol{x}, \boldsymbol{c}_j, \boldsymbol{\sigma}_j) = \sqrt{\sum_{k=1}^{E}\left(\frac{x_j - c_k^j}{\sigma_k^j}\right)^2},$$

여기서 $\boldsymbol{c}_j = (c_1^j, c_2^j, \ldots, c_E^j)$는 j번째 커널 함수의 중심,

$\boldsymbol{\sigma}_j = (\sigma_1^j, \sigma_2^j, ..., \sigma_E^j)$는 j번째 커널 함수의 너비, $\boldsymbol{w} = (w_0, w_1, ..., w_m)$는 커널 함수 결합 가중치에 해당하는 파라미터이고, β는 커널 함수 너비를 보정해주는 초 매개변수(Hyper-parameter)이다. 이러한 GKFN의 구조도는 Fig. 2와 같다.

제안된 GKFN을 직관적으로 살펴보면, Fig. 3에서 보인바와 같이 정의역 공간에서 적절한 위치에 커널 함수를 건설한 후 이를 적절하게 결합하여 함수를 근사하는 방식이기 때문에 GKFN의 성능은 어떤 위치에 어떤 너비를 가지는 커널 함수를 건설하며 어떻게 결합하는지에 따라 성능이 크게 달라진다. 따라서 커널 함수와 함수의 개수를 최적화하는 학습 방법이 GKFN 성능의 중요한 요소로 작용한다.

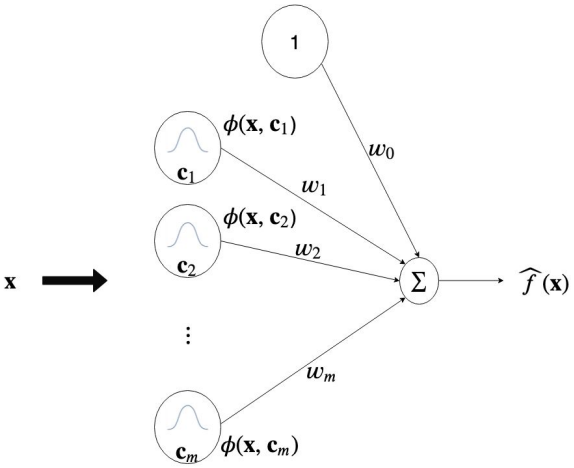

Fig. 2. The structure of Gaussian kernel function networks[9]

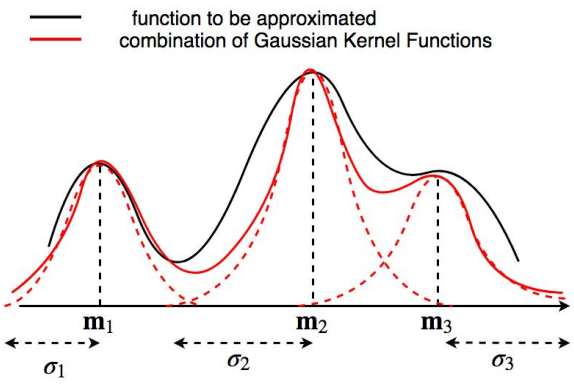

Fig. 3. Function approximation using a GKFN[9]

2.1 GKFN의 구조: 커널 함수의 중심과 너비

구현하고자 하는 커널 함수의 수와 위치는 근사하고자 하는 함수의 모양을 고려해야 하는데, 근사하고자 하는 함수는 미지의 함수이므로, 갖고 있는 입력변수와 출력 값의 분포를 고려하여 커널을 구현하여야 한다. 이를 위하여 함수의 출력 값에 따라 입력 변수를 적절히 군집화 하는 '출력 값에 근거한 k-평균 알고리즘'으로 커널 함수의 위치와 수를 결정한다.

2.1.1 출력 값에 근거한 k-평균 알고리즘

E차원의 입력 변수와 실수의 출력 값을 가지는 샘플 $(\boldsymbol{x}_i, y_i)$, $i = 1,2,...,n$에 대해서 입력 변수의 분포뿐 아니라 출력 값의 분포까지 고려한 군집화를 위해 입력변수의 공간이 아닌 출력 값을 포함한 $E+1$차원인 R^{E+1}차원에서 군집화를 실시한다. 이 때, 각 군집의 밀도를 조정할 파라미터 θ를 결정한 후 군집화 후 출력 값들의 분산을 살핀 후 θ와 비교한 후 더 세부적으로 군집화 할지를 결정한다. 여기서 모든 군집 내의 출력 값의 분산 값이 θ보다 작다면 알고리즘을 멈춘다. 제안된 알고리즘은 다음과 같다 :

단계 1. 초기 군집의 개수는 $k=2$로 설정하고 전체 데이터 집합을 $S = \{(\boldsymbol{x}_i, y_i) | i = 1,2,...,n\}$로 설정한다.

단계 2. k-평균 알고리즘을 이용하여, S를 k개의 군집으로 군집화를 한다.

단계 3. 각 군집에 대해서, j번째 군집 내의 출력 변수들(y_i^j)의 분산을 계산한다. 그리고 이 값을 $var(S_j)$, $j = 1,2,...,k$로 설정한다.

단계 4. j번째 군집의 분산 값, $var(S_j)$이 특정 값, θ보다 작다면 $k = k-1$, $S = S \backslash S_j$ (단, $A \backslash B = A - B$ 차집합 연산을 의미한다.)로 설정한다. 반면에, θ보다 크다면 $k = k+1$후 다시 단계 2로 돌아가 반복한다.

단계 5. 모든 $var(S_j)$ 값이 θ보다 작거나 더 이상 군집화 할 데이터가 없으면($S = \phi$) 알고리즘을 멈춘다.

제안된 방법인 '출력 값에 근거한 k-평균 알고리즘'을 이용하여 커널을 설치할 위치와 커널의 개수를 결정하고 각 커널에 필요한 파라미터를 계산한다. 커널 함수의 중심으로는 각 군집의 중심 중 입력변수에 해당되는 부분을 사용하고, 커널 함수의 너비로는 군집 내의 데이터들의 분산을 사용한다. 이의 한 예제는 Fig. 4와 같다. 즉, 제안된 알고리즘은 자료의 입력 값

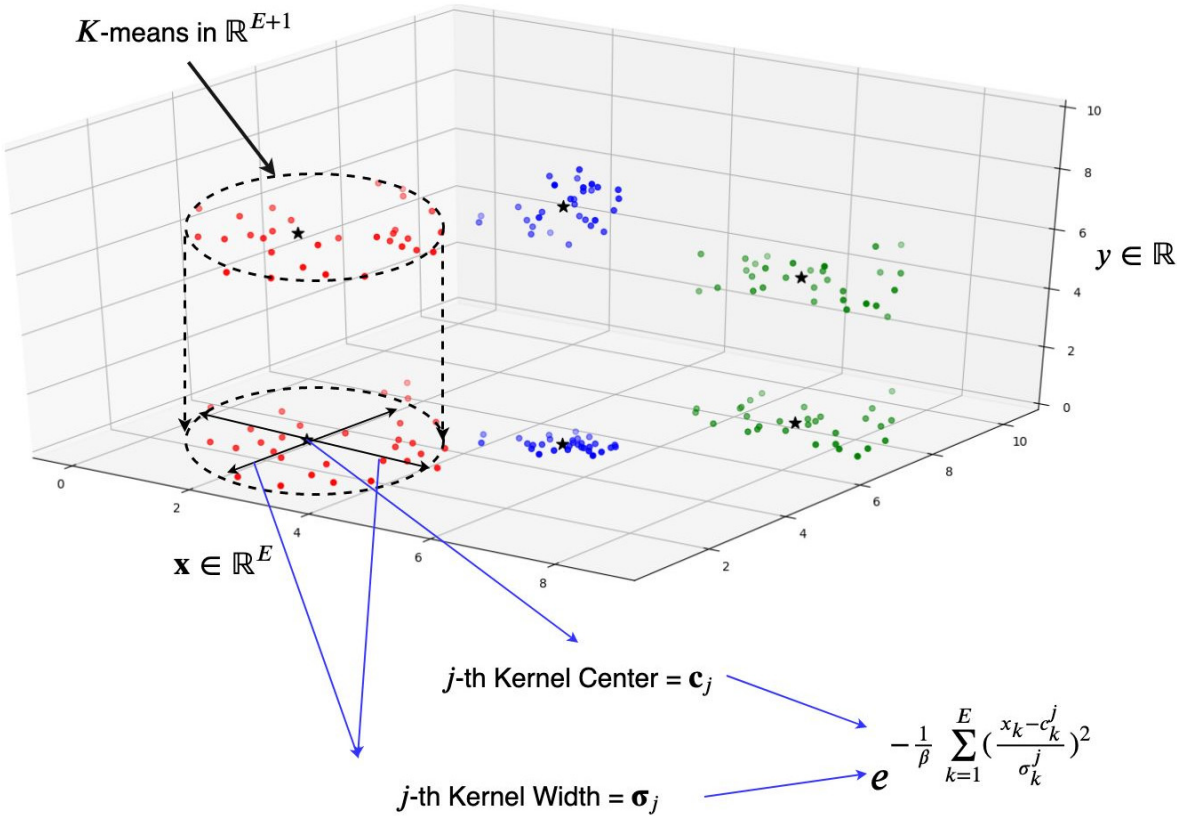

Fig. 4. Computing Gaussian kernel centers and widths

의 분포뿐만 아니라 출력 값의 분포도 고려하여 GKF들을 배치하게 된다. 그 결과 자료 분포에 따라 보다 적합하게 주어진 함수를 근사하게 된다.

2.2 커널 함수의 결합 가중치

GKFN에서 n개의 학습 데이터 $(\boldsymbol{x}_i, y_i)$, i = 1, 2, ..., n에 대해 m개의 커널 함수가 결정되었다고 했을 때, 커널 함수의 결합 가중치는 학습 데이터의 오차를 최소로 하도록 결정된다. 학습 데이터에 대한 GKFN의 오차제곱 합(Sum of Square Residuals, SS_R)은 다음과 같다 :

$$SS_R = \sum_{i=1}^{n}(y_i - \hat{f}(\boldsymbol{x}_i))^2. \tag{4}$$

이때, SS_R을 최소화하기 위한 가중치 벡터는 다음을 만족 한다 :

$$\frac{\partial SS_R}{\partial w_j} = 0\ , j = 0, 1, \ldots, m. \tag{5}$$

이로부터 다음의 식을 얻을 수 있다 :

$$2\sum_{i=1}^{n}(y_i - w_0 - w_1\phi_1(\boldsymbol{x}_i)\ \cdots\ - w_m\phi_m(\boldsymbol{x}_i)) \cdot (-\phi_j(\boldsymbol{x}_i)) = 0$$
$$j = 0, 1, \ldots, m. \tag{6}$$

이렇게 얻어진 $m+1$개의 식을 행렬로 나타내면 다음과 같다 :

$$X^T X\boldsymbol{w} = X^T\boldsymbol{y}, \tag{7}$$

여기서 $X = \begin{bmatrix} \Phi(\boldsymbol{x}_1) \\ \vdots \\ \Phi(\boldsymbol{x}_n) \end{bmatrix} \equiv \begin{bmatrix} 1 & \phi_1(\boldsymbol{x}_1) & \cdots & \phi_m(\boldsymbol{x}_1) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \phi_1(\boldsymbol{x}_n) & \cdots & \phi_m(\boldsymbol{x}_n) \end{bmatrix}$

$$\boldsymbol{y} = [y_1, y_2, \cdots, y_n]^T, \quad \boldsymbol{w} = [w_0, w_1, \cdots, w_m]^T.$$

따라서 최적의 결합 가중치는 다음과 같이 결정 된다 :

$$\boldsymbol{w}^* = (X^T X)^{-1} X^T \boldsymbol{y}. \tag{8}$$

2.3 초 매개변수 β의 최적화

군집화 후 각 군집내의 너비를 적절하게 보정해주는 초 매개변수 β는 베이즈 최적화(Bayesian optimization)을 이용하여 결정한다. 베이즈 최적화는 기계학습 알고리즘의 초매개변수를 결정하는데 있어서 매우 효율적인 방법으로, 함수의 값을 계산할 때의 계산비용이 큰 함수에 대해서 특히 유용하다.

베이즈 최적화 방법은 초기 몇 번의 탐색을 통해 가우스 과정(Gaussian Process, GP)를 이용하여 목적함수에 대한 확률적인 추정을 수행한 후 최적의 값을 찾기 위한 다음 탐색 후보로써 획득 함수(Acquisition function)를 이용하여 결정한다[10]. 획득 함수로써 현재까지 조사된 점 중 목적함수의 최댓값보다 큰 값을 도출할 확률에 해당하는 값(Exploration)과 GP로 추정한 목적함수의 불확실성이 큰 영역에 해당하는 값(Exploitation)의 균형을 이용한 함수를 사용한다[11]. 여기서 베이즈 초 매개변수 최적화 과정은 다음과 같다 :

목적함수 $h(x)$에 대하여,

단계 1. 기존에 탐색된 $(x_1, h(x_1))$, $(x_2, h(x_2)), \ldots,$ $(x_t, h(x_t))$에 대하여 GP로 추정한 모델에 대하여 획득 함수를 최대로 하는 점을 찾고 그 점을 x_{t+1}이라 한다.

단계 2. x_{t+1}에 대한 $h(x_{t+1})$의 값을 계산한다.

단계 3. 기존에 탐색된 데이터에 대해 $(x_{t+1}, h(x_{t+1}))$을 추가하여 GP를 이용하여 다시 $h(x)$를 추정한다.

단계 4. 단계 1로 돌아가 과정을 반복한다.

이러한 최적화 과정은 GKFN의 커널 너비를 매우 효과적으로 최적화 하여 전체적으로 주어진 자료에 잘 부합하도록 기여한다.

2.4 신뢰구간 추정

재밍 파라미터 추정 시 추정 값이 어떤 유효 범위 내에서 존재하는지 판단하는 것은 재밍의 성공과 직결된다. 이를 위하여 데이터 측정 시에 생기는 노이즈가 평균이 0이고 분산이 ν^2인 정규분포를 따른 다는 가정을 한다면, 재밍 파라미터의 구간추정이 가능하다.

노이즈의 정규분포로부터 커널 가중치 또한 평균이 $\boldsymbol{w}^*$이고 분산이 $\nu^2(X^T X)^{-1}$인 정규분포가 됨으로 결합 가중치의 확률 분포는 다음의 정규분포를 따른다 :

$$\boldsymbol{w} \sim N(\boldsymbol{w}^*, \nu^2 (X^T X)^{-1}). \tag{9}$$

여기서 재밍 파라미터 예측 값 $\hat{f}(\boldsymbol{x}) = \sum_{j=0}^{m} w_j \phi_j(\boldsymbol{x})$의 평균과 분산을 살펴보면 다음과 같다 :

$$E[\hat{f}(\boldsymbol{x})] = E\left[\sum_{j=0}^{m} w_j \phi_j(\boldsymbol{x})\right] = \sum_{j=0}^{m} E[w_j]\phi(\boldsymbol{x}) = \hat{f}(\boldsymbol{x}) \tag{10}$$

$$\begin{aligned} var(\hat{f}(\boldsymbol{x})) &= var\left(\sum_{j=0}^{m} w_j \phi_j(\boldsymbol{x})\right) \\ &= Cov\left(\sum_{j=0}^{m} w_j \phi_j(\boldsymbol{x}), \sum_{l=0}^{m} w_l \phi_l(\boldsymbol{x})\right) \\ &= \sum_{j=0}^{m}\sum_{l=0}^{m} \phi_j(\boldsymbol{x})\phi_l(\boldsymbol{x}) Cov(w_j, w_l) \\ &= \Phi(\boldsymbol{x})^T (X^T X)^{-1} \Phi(\boldsymbol{x}) \nu^2 \end{aligned}$$

즉,

$$\hat{f}(\boldsymbol{x}) \sim N(\sum_{j=0}^{m} w_j^* \phi_j(\boldsymbol{x}), \Phi(\boldsymbol{x})^T (X^T X)^{-1} \Phi(\boldsymbol{x}) \nu^2). \tag{11}$$

한편, 실제 재밍 파라미터 값인 y는 $y|_{\boldsymbol{x}} \sim N(y, \nu^2)$이므로 두 정규 분포와 노이즈 분산 ν^2의 불편 추정량(Unbiased estimator)값인 $\hat{\nu} = SS_R/(n-m-1)$를 사용하면 다음과 같은 t분포를 얻을 수 있다 :

$$\frac{y|_{\boldsymbol{x}} - \hat{f}(\boldsymbol{x})}{\hat{\nu}\sqrt{1 + \Phi(\boldsymbol{x})^T (X^T X)^{-1} \Phi(\boldsymbol{x})}} \sim t_{N-m-1}. \tag{12}$$

따라서, 임의의 신뢰수준 $100(1-\alpha)\%$에 대한 재밍 파라미터 추정 값 $\hat{f}(\boldsymbol{x})$의 구간 추정은 다음과 같다 :

$$y|_{\boldsymbol{x}} \in \left(\hat{f}(\boldsymbol{x}) \pm t_{\frac{\alpha}{2}, N-m-1} \hat{\nu}\sqrt{1 + \Phi(\boldsymbol{x})^T (X^T X)^{-1} \Phi(\boldsymbol{x})}\right). \tag{13}$$

제안된 신뢰구간은 실제 값이 추정 값을 기준으로 어느 정도의 범위 안에 있을 수 있는지에 대한 정보를 제공한다. 또한 재밍 파라미터가 유효하지 않은 경우 신뢰구간을 이용하여 재 추정도 가능하다.

2.5 재밍 파라미터 재 예측

본 방법에서 최초의 레이더 패턴으로부터 재밍 파라미터 추정이 실패했을 경우 GKFN의 실제 재밍 파라미터의 구간추정을 이용하여 재밍 파라미터를 재 예측할 수 있다. 제안된 방법은 Fig. 5와 같이 추정한 재밍 파라미터의 구간 추정의 상한 값과 하한 값 중 임의로(1/2의 확률로) 선택하여 다시 재밍을 시도한다. 이는 정보가 부족한 상황 혹은 이전에 수집되지 않은 레이더 패턴에 대한 상황에서도 추정을 할 수 있다는 의미가 있다. 그 결과 실제 환경에서 재밍의 성공률을 높이는데 기여할 수 있다.

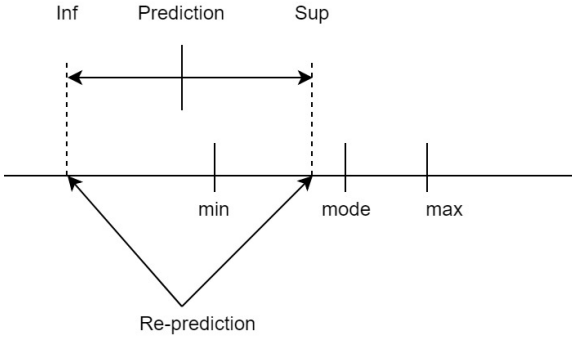

Fig. 5. Reestimation of jamming parameters

2.6 재밍 파라미터 예측을 위한 GKFN

앞의 2.1~2.5의 과정을 정리하여 GKFN모델을 이용한 재밍 파라미터 추정 알고리즘은 다음과 같다 :

단계 1. 입력 변수와 출력 값으로 구성된 데이터에 대해 '출력 값에 근거한 k-평균 알고리즘'을 이용하여 커널 함수의 개수를 결정한다.
단계 2. 각 군집의 중심, 분산을 이용하여 커널 함수의 중심 및 너비를 결정한다.
단계 3. 오차 제곱 합을 최소로 하는 커널 가중치를 결정한다.
단계 4. 베이즈 최적화 탐색 방법을 사용하여 초 매개변수 β를 결정한다.
단계 5. 측정 노이즈의 분산의 불편 추정 값을 계산하여 예측치의 구간추정을 계산한다.
단계 6. 재밍 실패의 경우 예측치의 구간추정을 이용하여 구간추정의 상, 하한 값 중 하나를 선택하여 재밍을 다시 시도한다.

3. 실 험

제안된 GKFN 모델에 실제 데이터를 적용하여 재밍 파라미터 예측 및 실패한 데이터에 대해서 재 예측을 진행하고 그에 대한 오차분석을 진행하였다.

3.1 실험 자료 및 성능 척도

실험에 사용된 자료는 전자전 전문가의 의견을 반영한 레이더/재밍 모의신호를 토대로[6] 진행하였다. 주어진 데이터는 다양한 방사 신호 종류의 레이더 특징에 따른 자료로서 방사체에 따른 Frequency, PRI, PW의 값을 가지는 3차원의 벡터와 그에 해당하는 재밍 파라미터를 출력 값으로 구성되어 있다. 이러한 재밍 파라미터 추정의 성능 평가를 위하여 주어진 시험 자료 n_0개에 대하여 회귀모형 평가를 위한 측도로 다음의 결정계수(R^2)가 사용되었다 :

$$R^2(\%) = 1 - \frac{\sum_{i=1}^{n_0}(y_i - \hat{f}(\boldsymbol{x}_i))^2}{\sum_{i=1}^{n_0}(y_i - \bar{y})^2}, \tag{14}$$

여기서 $\bar{y} = \frac{1}{n_0}\sum_{i=1}^{n_0} y_i.$

정의된 측도 R^2는 일반적으로 0과 1사이 값의 범위를 나타내며, 주어진 자료의 변동 량 중 추정한 모형이 얼마만큼의 변동 량을 설명하는가에 대한 지표를 나타낸다. R^2가 1에 가까울수록 추정한 모형이 실제 자료에 잘 부합한다고 해석할 수 있다.

다음으로 재밍 파라미터 자체를 추정하는 것 이외에도, 재밍 파라미터 값을 레이더가 인식할 수 있는 허용 범위가 있는데, 실제로 그 범위 안에 들어오는지 아닌지도 확인해야할 중요한 특징이다. 각 모델의 예측 값이 허용 범위 내에 들어가는 빈도를 적중률로써 다음과 같이 정의 한다 :

$$\text{적중률}(\%) = \frac{\text{허용 범위 내에 예측 값이 있는 경우}}{\text{총 테스트 데이터의 개수}} \quad (15)$$

생성된 레이더 PDW set에 포함된 패턴(Frequency, PRI, PW)과 그에 해당하는 재밍 파라미터, 허용 범위로 이루어진 1722개의 데이터를 8:1:1의 비율로 학습데이터, 검증데이터, 테스트데이터로 분할하여 사용하였다.

3.2 실험 결과

현재 수집된 데이터의 레이더의 패턴을 분석하여 그에 맞는 재밍 파라미터를 추정하는데 있어 GKFN의 성능을 살펴보기 위해서는 비교되는 모델 들 또한 레이더 패턴과 재밍 파라미터 간의 사상 능력(Mapping capability)이 뛰어난 모델로 선택하였다. 이를 위하여 비교적 적은 파라미터로 우수한 사상능력을 성능을 갖는 SVM(Support Vector Machine)과 복잡한 비선형 관계의 데이터를 모델링하는데 자주 사용되는 DNN (Deep Neural Network)을 사용하였다. 입력데이터가 3차원으로 이루어진 특성상 CNN(Convolution Neural Network)의 적용이 어렵고, 시계열의 형태가 아니기 때문에 RNN(Recurrent Neural Network)은 사용하지 않았다.

실험은 Scikit-learn[12]에서 제공하는 패키지를 사용하였고 비교방법은 성능평가를 위하여 주로 사용되는 10등분 교차 평가(10-Fold cross evaluation)를 이용 하였다. 즉, 데이터를 총 10등분 하여 8등분을 학습, 1등분을 검증 그리고 남은 1등분을 테스트하는 것을 반복하여 성능 척도의 평균값을 기록하였다.

GKFN의 경우 군집화 단계에서 각 군집 내 입력 변수의 출력 값의 분산이 전체 출력 값의 1/2000배가 되도록 하여 약 100여개의 커널을 건설하였다. 여기서 제안된 알고리즘을 적용한 결과의 한 예제로서 학습 데이터와 커널의 위치 분포는 Fig. 6과 같다. SVM의 경우 Penalty 파라미터와 Epsilon tube를 검증데이터로 최적화하여 사용하였다. DNN의 경우 4개의 은닉 층(각 32, 64, 32, 16개의 노드)을 구성하였고, 활성화 함수로 ReLu, 최적화는 Adam을 이용하였다. 각 모델의 성능은 Table 1에 요약하였다. 실험 결과를 통해 제안된 GKFN 모델이 SVM, DNN보다 재밍 파라미터 자체를 추정하는데 있어서 뿐만 아니라 재밍 허용 구간에 적중률도 더 뛰어남을 확인할 수 있었다.

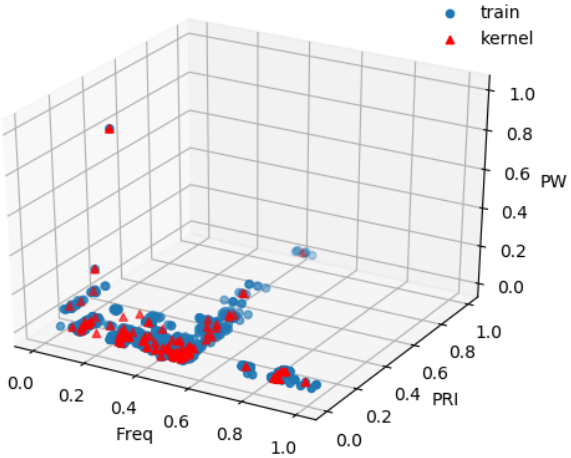

Fig. 6. Distributions of training data and kernel centers

Table 1. Comparing the performances of estimating jamming parameters

회귀 모형	GKFN	SVM	DNN
train R^2	0.6099	0.0054	0.0091
train 적중률 (%)	0.9723	0.8727	0.9082
test R^2	0.4889	-0.0031*	0.0019
test 적중률 (%)	0.9628	0.8688	0.9065

*일반적으로 R^2의 값은 0과 1사이의 값을 나타내지만, 음수의 값을 나타낸다는 것은 제안된 모델의 오차가 학습데이터의 평균치로 예측했을 때의 오차보다 크다는 것을 의미 한다.

이와 같은 성능 평가의 결과는 GKFN의 출력 값에 근거한 k-평균 알고리즘에 의해 설명될 수 있다. 각 군집 내에 있는 데이터들은 비슷한 출력 값을 나타내도록 모여 있기 때문에 적은 수의 파라미터(GKFN 파라미터 수 : 3*200+101+1 = 702, DNN 파라미터 수 : 3*32*64*32*16 = 3145728)로 샘플 데이터의 대표성을 잘 나타냈기 때문이다. 게다가 연산 량(사칙연산의 횟수)에 있어서도 GKFN은 DNN에 비해 약 1/25배의 적은 연산 량을 보인다 : GKFN의 연산 량 : 13*100+101+100 = 331, DNN의 연산 량 : (5*32+32)+(63*64+64)+(127*32+32)+(63*1) = 8447.

또한 SVM이나 DNN의 R^2값을 보면 알 수 있듯이 레이더의 패턴과 재밍 파라미터 값 사이의 비선형성

이 크기 때문에 이 모델들로는 레이더 특징들과 재밍 파라미터간의 함수를 구현하는데 있어서 상당히 어려움이 있음을 알 수 있다. 그리고 DNN의 경우에는 모델의 구조를 결정함에 있어서 제시된 최적화의 방법론이 없기 때문에 사용자 입장에서 구조 결정의 어려움이 따른다. 반면에, GKFN의 경우 각 군집내의 출력값의 분산만 지정해주면 되기 때문에 구조를 결정하는 데 있어서 수월하다는 것을 알 수 있다.

3.3 재 예측 실험결과

추정 재밍 파라미터가 재밍 허용 범위에 벗어나는 경우 제안한 재밍 재 예측 방법을 이용하여 재밍을 시도하였다. 예를 들어, 실제 재밍 파라미터(y)가 10.836의 값이고 재밍 허용 범위가 (8.8363, 11.8363)으로 주어진 레이더 패턴의 GKFN의 예측치($\hat{y}$)가 8.3273인 경우 재밍 허용범위에 들지 않으므로 재밍에 실패하게 된다. 하지만 이 때 GKFN의 재밍 파라미터 구간 추정의 예측범위는 (6.7851, 9.8696)으로 주어지는데, 이 구간의 상한 값(9.8696)과 하한 값(6.7851) 중 하나를 임의로 선택하여 다시 재밍을 시도하는데 이 때, 상한 값이 선택이 되면 재밍에 성공하게 된다. 그 결과 Table 2에 정리한데로 적중률은 평균적으로 향상되는 변화를 보였다.

결론적으로 제안된 GKFN 모델은 재밍의 적중률 면에서 매우 우수한 성능을 보였다. 또한 제안된 방법은 재밍 파라미터의 추정, 신뢰구간을 이용한 실제 파라미터 값의 범위, 그리고 재밍 실패 시 대안 추정 값을 제공함으로서 실제 환경에서 보다 유연하게 대처할 수 있는 방법론을 제시한다.

Table 2. Comparing the performances before and after reestimating jamming parameters

	Train	Test
기존	0.9723	0.9628
재 예측	0.9847	0.9791

4. 결 론

본 연구에서 대상 위협에 유효한 재밍 기법 및 신호 추정에 대해 현재 전자전 전문가의 경험적 판단에 의존하는 환경에서, 신뢰성 있는 대량의 데이터를 사용하여 수학적 모델을 통해 재밍 기법 및 신호를 추정 할 수 있는 알고리즘을 제시하였다. 본 연구의 방법론으로서 레이더 패턴으로부터 재밍 파라미터를 추정하기 위하여 가우스 요소함수 망(Gaussian Kernel Function Network, GKFN)의 최적화 및 학습 알고리즘을 제시하였고, 실험을 통하여 제안된 방법이 매우 효과적임을 보였다. 본 연구의 결과는 다음과 같이 정리할 수 있다 :

먼저 수집된 데이터로부터, 입·출력 값을 포함한 한 차원 높은 공간에서의 군집화를 통해 입력 데이터의 공간적 특성뿐만 아니라 출력 값의 변동성도 반영하여 군집화 함으로써 각 군집 내의 데이터는 입력 데이터의 특성도 비슷할 뿐 아니라 출력 값도 비슷하게 되는 군집화 방법을 제시하고 그 군집의 중심과 너비를 파라미터로 하는 GKFN 모델을 제시하였다. 또한 베이즈 최적화를 이용하여 커널과 너비와 관련된 초매개변수를 최적화 하였다.

다음으로 데이터 측정에 있어서 생기는 노이즈의 분산을 추정하여, 재밍 파라미터의 점 추정뿐 아니라 구간추정까지 제시하였다. 또한 재밍 파라미터 허용 구간을 벗어나는 경우, 구간추정의 상·하한 값을 이용한 신호 재 예측 방법을 제시하였고, 제안된 방법의 우수성을 확인하였다. 그 결과 제안된 방법은 재밍 파라미터 추정에 있어 전자전 전문가와 비견될 정도로 일관된 추정 성능을 발휘 할 뿐 아니라 함수 근사에 있어서 대표적으로 사용되는 DNN(Deep Neural Network), SVM(Support Vector Machine)과 비교하여도 제안된 방법이 우수한 성능을 제공함을 보였다.

후 기

본 연구는 국방과학연구소 및 LIG넥스원의 산학협력(LIGNEX1-2017-0581) 지원 아래 수행되었습니다.

References

[1] D. Schleher, “Introduction to Electronic Warfare,” Eaton Corp, AIL Div., Deer Park, NY, 1986.

[2] D. Schleher, “Electronic Warfare in the Information Age,” Artech House Publishers, 1999.

[3] S. Lee, H. Bae, R. Kil, and C. Jo, “Classification of the Trained and Untrained Emitter Types based on Class Probability Output Networks,” Neurocomputing, Vol. 248, pp. 67-75, 2017.

[4] S. Lee and R. Kil, “A Gaussian Potential Function Network with Hierarchically Self-Organizing Learning,” Neural Networks, Vol. 4, No. 2, pp. 207-224, 1991.

[5] R. Kil, “Function Approximation based on a Network with Kernel Functions of Bounds and Locality: an Approach of Non-Parametric Estimation,” ETRI Journal, Vol. 15, No. 2, pp. 35-51, 1993.

[6] R. Wiley, “ELINT: The Interception and Analysis of Radar Signals,” Artech House Publishers, 2006.

[7] M. D. Buhmann, “Radial Basis Functions: Theory and Implementations,” Volume 12, Cambridge University Press, 2013.

[8] E. Parzen, “On the Estimation of a Probability Density Function and Mode,” Annals of Mathematical Statistics, Vol. 33, pp. 1065-1076, 1962.

[9] T. Hwang, “Combination of Gaussian Kernel Function Networks for Traffic Flow Prediction,” Sungkyunkwan University, Thesis, 2018.

[10] E. Brochu, V. M. Cora, N. Freitas, “A Tutorial on Bayesian Optimization of Expensive Cost Functions, with Application to Active User Modeling and Hierarchical Reinforcement Learning,” eprint arXiv: 1012.2599, arXiv.org, 2010.

[11] J. Snoek, H. Larochelle, R. P. Adams, “Practical Bayesian Optimization of Machine Learning Algorithm,” eprint arXiv:1021.2599, arXiv.org, 2012.

[12] Pedregosa, F. et al., “Scikit-Learn: Machine Learning in Python,” Journal of Machine Learning Research, Vol. 12, pp. 2825-2830, 2011.