

# 뜰개 이동 예측을 위한 신경망 및 통계 기반 기계학습 기법의 성능 비교

이찬재, 김경도, 김용혁\*  
광운대학교 컴퓨터과학과

## Performance Comparison of Machine Learning Based on Neural Networks and Statistical Methods for Prediction of Drifter Movement

Chan-Jae Lee, Gyoung-Do Kim, Yong-Hyuk Kim\*  
Dept. Computer Science, Kwangwoon University

**요약** 뜰개는 해양에서 해수의 특성 및 흐름을 관측하기 위한 장비로서, 해수의 흐름 관측을 이용해 유출유 확산 예측을 위해 사용될 수 있다. 본 논문에서는 관측기관에서 사용하는 뜰개가 특정 시간 간격으로 관측한 바람 및 해수의 특성과 이동경로를 기계학습 기법들을 이용하여 학습시키고 예측하는 모델을 제안한다. 서포트벡터 회귀, 방사기저함수 네트워크, 가우시안 프로세스, 다층 퍼셉트론, 순환신경망을 이용하여 뜰개의 이동경로 예측 방법을 제시한다. 기존 MOHID 수치모델과 비교하여 각 기법별로 4 개의 사례중 3 개에서 성능이 개선되었으며, 가장 좋은 개선율을 보인 기법은 LSTM으로 평균 47.59% 개선되었다. 추후 연구에서는 배깅과 부스팅을 이용하여 가중치를 부여하여 정확도를 개선할 예정이다.

• 주제어 : 유류 유출, 뜰개, 기계학습, 순환신경망, 예측

**Abstract** Drifter is an equipment for observing the characteristics of seawater in the ocean, and it can be used to predict effluent oil diffusion and to observe ocean currents. In this paper, we design models or the prediction of drifter trajectory using machine learning. We propose methods for estimating the trajectory of drifter using support vector regression, radial basis function network, Gaussian process, multilayer perceptron, and recurrent neural network. When the propose mothods were compared with the existing MOHID numerical model, performance was improve on three of the four cases. In particular, LSTM, the best performed method, showed the imporvement by 47.59% Future work will improve the accuracy by weighting using bagging and boosting.

• Key Words : Oil Spill, Drifter, Machine learning, Recurrent neural network, LSTM, Prediction

### 1. 서론

현대 사회에서 뜰개(drifter)는 관측장비로서 많이 사

용되어 오고 있고 유출유 확산 예측과 해류를 관찰 하기 위해 사용되고 있다. 캘리포니아 북부 해안에서 해류를

\*Corresponding Author : 김용혁(yhdfly@kw.ac.kr)

Received September 5, 2017

Accepted October 20, 2017

Revised October 2, 2017

Published October 28, 2017

관측하기 위해 사용되고[1], 또한 멕시코 북동부 만에서 위성 데이터와 순환 모델로 동화되어 사용한다[2]. 그중 포르투갈 리스본 대학에서 개발한 MOHID 수치모델[3]은 수질 상태 측정과 뜰개 이동경로를 예측할 수 있다.

해양관측기관에서는 MOHID 해양 뜰개를 이용한 모델을 만드는데 뜰개는 해수면 위에 떠다니며 해수의 흐름과 방향, 바람의 세기, 자신의 위치를 전송한다. 기존의 모델로 뜰개 위치를 예측할 경우, 0.3° 정도의 오차가 발생하는데 이는 거리상으로 30 km 이상 차이가 나는 거리이며, 실제 유출유 확산 예측에 이용 될 경우, 방사 작업에 있어서 큰 손해를 불러 올 수 있다.따라서 더 정확한 예측 모델이 필요하다.

본 논문에서는 기계학습 기반의 뜰개 예측을 통해 기존의 모델보다 정확한 모델을 제안한다. 기계학습은 데이터의 분류[4] 또는 회귀를 위해 사용되며, 본 논문에서는 회귀를 위한 기법으로 서포트벡터 회귀, 방사기저 함수, 가우시안 프로세스, 다층 퍼셉트론, 순환신경망과 이를 활용한 LSTM을 사용한다. 각 기계학습 기법이 사용된 사례는 위성이미지를 활용한 유출유 발생 탐지[5], 가우시안 프로세스를 이용한 강우계 관측[6],심층 신경망을 이용한 단기 바람예측[7], 방사기저 네트워크 기반의 유류유출 예측 시스템[8], 서포트벡터 머신-방사기저를 이용한 일사량예측[9]이 활용되었다. 2 절에서는 각 기법들의 이론적인 배경에 대해 설명을 하고 3 절에서는 성능평가를 방법을 소개한다. 4 절에서는 기법들의 보정방법, 5 절에서는 실험 결과에 소개하고, 마지막 6 절에서는 결론을 제시한다.

## 2. 기법 개요

### 2.1 서포트벡터 회귀 (Support Vector Regression)

서포트벡터 회귀(SVR)는 학습 데이터의 오류를 최소화 하려는 것보다 일반화된 오류를 최소화 하여 일반화된 결과를 얻으려고 하는 기법이다[10]. 기본적인 개념은 선형 회귀 함수의 계산에 기반하고 시계열 데이터 및 금융 데이터 및 손실 함수 등에 사용된다.

### 2.2 방사기저함수 네트워크(Radial Basis Function Network)

방사기저함수 네트워크(RBFN)는 인공신경망(artificial neural network)의 일종으로서[11], 복잡한 다변수함수를 단변량함수의 선형 결합으로 근사하기 위한 하나의 보간 방법으로 주어진 실측 데이터를 이용하여 원함수를 추정하기 위해 많이 사용되는 기법이다. 기저함수는 양수값을 받아 함수의 가중치를 반환한다.

### 2.3 가우시안 프로세스(Gaussian Process)

가우시안 프로세스(GP)는  $x \in R^d$ 를 인덱스로 갖는 랜덤변수  $f(x)$ 의 집합으로서, 이들 중 임의로 선택된 유한개의 랜덤변수  $f(x_1), \dots, f(x_m)$ 가 반드시 결합 가우시안 밀도를 갖는 성질을 갖는 경우를 의미한다[12]. 가우시안 프로세스 평균함수와 공분산 함수에 의해서 완전히 기술될 수 있다.

### 2.4 다층 퍼셉트론(Multilayer Perceptron)

다층 퍼셉트론(MLP)은 인공신경망의 일부분이다[13]. 다층 퍼셉트론은 간단한 상호 연결된 뉴런 또는 노드로 구성되어 있다. 또한 입력 벡터와 출력 벡터 간의 비선형 맵핑을 나타내고 노드는 가중치로 연결되어 있다.

간단한 비선형 전달함수 또는 활성화 함수에 의해 노드에 대한 출력 신호를 생성한다. 노드의 출력은 연결 가중치에 의해 결정되고, 네트워크 다음 계층에 있는 노드에 대한 입력이 되도록 전달된다. 이것은 정보 처리의 방향을 의미하며, 다층 퍼셉트론은 전방향 신경망(feed-forward neural network)이라고 알려져 있다.

### 2.5 순환신경망(Recurrent Neural Network)

순환신경망(RNN)[14]은 인공신경망의 일종으로서, 기존의 인공신경망에서는 입력과 출력이 독립적으로 진행되는 반면, 순환신경망은 전체 시퀀스에서 이전에 사용된 결과를 다음 계층에 영향을 받는 계층이다. 순환신경망은 식 (1)과 같은 형태를 가진다.

$$H_t = \phi(W_1 H_t + W_2 H_{t-1}) \quad (1)$$

이전의 결과  $H_{t-1}$ 와 입력으로 들어온  $H_t$ 간의 가중치  $W_1, W_2$ 를 준 결과를  $\phi$  함수를 통해 압축이 되는데, 일반적으로 쌍곡탄젠트 또는 시그모이드를 사용하게 된다.

## 2.6 LSTM(Long Short-Term Memory)

LSTM[15]은 특별한 종류의 RNN으로, 기존의 RNN에서 발생하는 장기 의존성 문제(long-term dependency)를 해결할 수 있다. 장기 의존성 문제란, RNN 구조에서 과거의 데이터와 연관되어 있는 현재 혹은 미래의 문제 사이에 순서상의 차이가 크면 클수록 두 정보를 연결하기 힘들어지는 문제를 뜻한다. LSTM은 셀 상태(cell state)와 게이트(gate)라는 요소를 가지고 있다. 여러 개의 셀 상태를 통해 이전의 정보들을 다음 단계로 전달하며, 각각의 셀 상태에서 게이트를 이용하여 정보를 더하거나 제거하는 작업을 한다.

## 3. 성능 검증 척도 및 실험환경

### 3.1 성능 검증

성능 검증을 하기 위해서는 여러 통계분석이 필요하지만 가장 중요한 기준은 정확도이다. 본 연구에서 사용할 검증 방법은 MAE(mean absolute error), RMSE (root mean square error), NCLS(normalized cumulative Lagrangian separation)의 비교를 통해 성능 검증을 하였다. MAE는 모델 평가 방법으로 많이 사용되고 있으며, RMSE는 기상, 대기 및 기후 연구에서 모델 성능을 측정할 때 표준 통계 척도로 사용되고 있다. 또한 NCLS는 다양한 동적 영역에서의 궤도를 측정하는데 사용되고 있다 [16]. MAE와 RMSE는 오차의 제한이 없으나, NCLS는 0과 1 사이의 범위에 속한다.

MAE, RMSE, NCLS는 각각 식 (2), (3), (4)와 같다.

$$MAE: \frac{1}{n} \sum_{i=1}^n |\epsilon_i| \quad (2)$$

$$RMSE: \sqrt{\frac{1}{n} \sum_{i=1}^n \epsilon_i^2} \quad (3)$$

$$NCLS: 1 - \left( \frac{\sum_{i=1}^n d_i}{\sum_{i=1}^n l_i} \right) \quad (4)$$

$\epsilon$  와  $d_i$  는 각각 오차와 거리를 의미하고  $l_i$  는  $\sum_{i=1}^n d_i$  를 뜻한다.

MAE는 모든 오류에 대해 동일한 가중치가 주어지지만, RMSE는 큰 오류에 대해 큰 패널티가 주어진다. NCLS는 거리에 따른 패널티를 감소 시켜주는 방법으로 값이 클수록 정확도가 높아지는 방법이다.

모든 실험은 교차검증(cross-validation)을 통해 평가했다. 교차검증은 지도학습 모델의 성능을 평가하기 위해 사용되는 실험 방법이다. 전체 데이터를  $N$  개의 구간으로 나누어  $N-1$  개의 구간을 학습데이터로 구성하고 나머지 1 개를 검증데이터로 구성하여  $N$  번 반복해서 실험한다. 이때  $N$  개의 구간이 각각 한 번씩 검증데이터로 구성되도록 한다.

결과는  $N$  개의 구간의 평균으로 나타내었고, MAE와 RMSE는 낮을수록 정확도가 높고, NCLS는 1에 가까울수록 정확도가 높다.

### 3.2 실험 데이터

주어진 데이터는 한국해양기상기술로부터 받은 데이터로서 2015년 11월 6일부터 경도 125° 위도 36.5° 부근에서 측정된 7 개 뜯개에서 관측된 683 개의 관측자료를 담고 있다. 각 지역의 뜯개는 25 ~ 238 개의 관측자료를 보유하고 있다. 예측 모델을 만들기 위해 학습 데이터와 테스트 데이터를 구분한다. 예측모델은 교차검증을 통해 7 개의 사례 이외의 데이터를 학습 데이터로 사용하고, 해당 사례를 테스트 데이터로 사용하여 평가한다. 이 중 가장 많은 데이터를 보유하고 있는 사례 1, 5, 6, 7을 사용하여 평가할 것이다.

<Table 1> Dataset

Dataset	Number of training data	Number of test data
Instance 1	438	238
Instance 2	651	25
Instance 5	568	108
Instance 6	677	111
Instance 7	564	112
Instance 8	638	38
Instance 9	632	44

## 4. 파라미터 설계

### 4.1 서포트벡터 회귀

#### 4.1.1 데이터 타입: 표준화

통계에서의 표준화는 데이터의 원시 점수에서 모집단 평균을 뺀 다음, 모집단 표준편차로 나눈 값이다. 원시점수의 표준점수  $z$  는 식 (5)과 같다.

$$z = \frac{x - \mu}{\sigma} \quad (5)$$

$\mu$ 는 모집단의 평균이고  $\sigma$ 는 모집단의 표준편차이다.

이 방법을 적용하려는 때는 2 개 이상의 대상의 단위가 다를 때 대상 데이터를 같은 기준으로 볼 수 있게 해야한다. 또한 이 방법은 데이터를 다소 평평하게 하는 특성을 가지고 이 방법을 적용하면 간극이 줄어드는 효과를 발생하여 간극이 큰 데이터의 간극을 줄이는 결과를 얻게 된다.

#### 4.1.2 복잡도 상수

복잡도 상수는 오 분류에 대한 허용 오차를 설정 하는 값이다. 가설 함수(hypothesis function)의 차수를 정해주는 값으로, 높은  $c$ 의 값은 경계를 부드럽게 만들고 낮은  $c$ 의 값은 경계를 단단하게 만든다.  $c$ 의 값에 따라 가설함수의 형태가 달라지게 되는데  $c$ 의 값이 작으면 부적합(underfitting)이 일어나고,  $c$ 의 값이 너무 크면(overfitting)이 일어날 수 있다.


#### 4.1.3 커널(kernel)

최대 마진 초평면 문제에 커널 트릭을 적용해서 비선형 문제를 제안한다. 비선형 분류 알고리즘은 선형 분류 알고리즘과 비슷하지만 내적 연산이 비선형 커널로 대체된다. 이를 통해 변환된 특징 공간의 최대 마진 초평면 문제를 해결할 수 있다. 여기서 말하는 변환은 비선형 변환이거나 차원을 높이는 변환이 된다.

#### 4.1.4 보정 결과

<Table 2> Parameter of SVR

Parameter	Value
Complexity constant	3.0
Filter type	Standardize training data
Kernel	Polynomial kernel



SVR은 복잡도 상수를 1에서 10까지 1의 단위로 적용하고 필터는 표준화, 정규화로 적용하여 복잡도 상수 3과 표준화가 최적의 결과를 보였다. [Table 2]와 같이 설정했다. [Fig. 1]은 대부분의 사례에서 개선되었으나, 사례 7에서의 결과가 안 좋게 나와 전체 평균은 미미한 차이를 보이게 됐다.

## 4.2 방사기저함수

### 4.2.1 능형 회귀

능형 회귀는 다중 공선성으로 부터 영향을 받는 다중 회귀 데이터를 분석하는 기술이다. 다중 공선성이 발생하면 발생하면 편향되지는 않지만, 분산의 크기 때문에 실제 값과 차이가 날 수 있다. 회귀 분석에서 편차를 더함으로써 능형 회귀는 표준 편차를 줄여준다


### 4.2.2 기저함수

기저함수(basis function)는 함수 공간의 기저인 함수를 말한다. 기저함수로는 다항식 기저함수와 푸리에 기저함수가 존재하고 2차 다항식에서  $\{1, t, t^2\}$ 은 기저 함수이다. 모든 연속 함수들은 기저함수들의 선형 결합으로 표시할 수 있다.

### 4.2.3 보정 결과

<Table 3> Parameter of RBFN

Parameter	Value
Number of basis functions	2
Ridge	2
Scale Optimization	Use scale per unit
Tolerance	1.0e-6



RBFN은 Ridge를 0.01에서 10까지 변경을 진행해보고 2가 가장 좋은 값을 가졌다. 전체적으로 개선이 되었으나, 사례 7의 결과는 안 좋게 나왔다.

### 4.3 가우시안 프로세스

#### 4.3.1 데이터 타입: 표준화

통계에서의 표준화는 데이터의 원시 점수에서 모집단 평균을 뺀 다음, 모집단 표준편차로 나눈 값이다. 자세한 내용은 4.1.1의 내용과 같다.


#### 4.3.2 가우시안 잡음

가우시안 잡음은 가우시안 분포라고도 하는 정규분포의 확률 밀도 함수와 같은 통계적 잡음을 의미한다. 즉, 잡음이 취할 수 있는 값은 가우시안 분포이다.

#### 4.3.3 보정 결과

<Table 4> Parameter of GP

Parameter	Value
Filter type	Standardize training data
level of Gaussian noise	1.0
Decimal places	2



[Table 4]에서 필터 타입을 표준화를 하였다. 데이터 개선 정도는 [Fig. 3]과 같이 개선되었다.

### 4.4 다층 퍼셉트론

#### 4.4.1 활성화 함수

인공신경망 모델에서 뉴런의 주요 기능은 입력과 연결 강도의 합을 구한 다음, 활성화 함수에 의해 출력을 내보내는 것을 말한다.

#### 4.4.2 오류 함수

예측값과 실제값 간에 오류를 최소화 하기 위한 함수다. 예측값과 실제값 간에 차이가 커질수록 오류 함수의 값은 커지고 예측값과 실제값이 최적화 될수록 오류 함수는 0으로 수렴한다.


#### 4.4.3 은닉층

인공신경망에서의 은닉층은 출력층과 입력층을 연결해주는 계층이다. 은닉층은 출력층과 관계있는 시냅스 후(post-synaptic) 뉴런과 연결 되어 있기 때문에 은닉층은 시냅스 전(pre-synaptic) 뉴런이다.

#### 4.4.4 보정 결과

<Table 5> Parameter of MLP

Parameter	Value
Activation Function	Approximate sigmoid
Loss function	Square error
Decimal places	2
Number of hidden unit	1
Ridge	0.01
Tolerance	1.0e-6



[Table 5]에서는 은닉노드의 개수를 1에서 5까지 적용하였으며 1에서 가장 좋은 결과값이 나타났다. 사례 1과 7에서 상당한 개선정도를 보여 [Fig. 4]와 같이 개선된 결과를 보였다.

### 4.5 순환신경망 & LSTM

#### 4.5.1 에폭(Epoch)



신경망에서 몇 번이나 학습 데이터를 사용했는지를 뜻한다. 각 에폭마다 비용함수를 초기화시켜 최소화 하기 위해 조정되어 결과를 나타낸다.

#### 4.5.2 보정 결과

RNN과 LSTM은 [Table 6]과 같이 에폭만 변경하여 데이터를 적용했다. 1,500부터 3,000까지 500단위로 적용하였으나 RNN은 2,500에서 가장 좋은 결과를, LSTM은 1,500에서 가장 좋은 결과를 보여줬다.

<Table 6> Parameter of RNN & LSTM

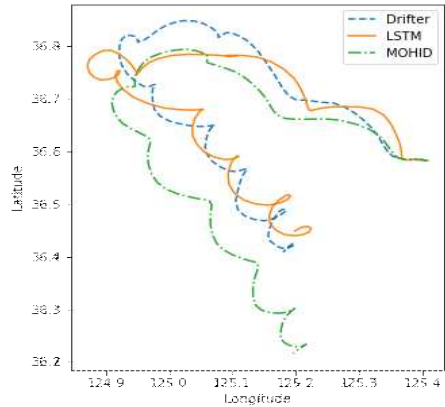
Parameter	Value in RNN	Value in LSTM
Learning rate	0.01	0.01
Epoch	2500	1500
Loss function	square error	square error
Number of hidden unit	1	1
Activation funcion	sigmoid	sigmoid



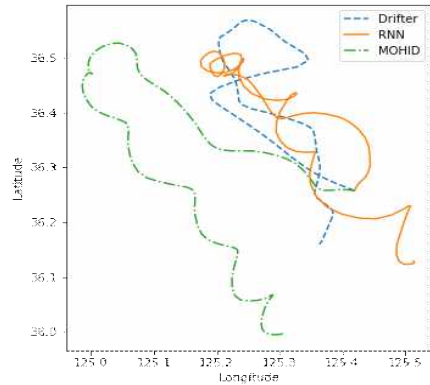
### 5. 실험 결과

각 기법 별 사례를 MAE, RMSE, NCLS 나타내고 가장 좋게 나온 것을 굵은 글씨로 표시했다. 전체적인 비교에서 RNN과 LSTM이 가장 좋은 결과를 보여줬다. MOHID 수치모델과의 비교에서는 전체적으로 더 나은 결과를 보여줬으며 사례 6에서 RNN은 68%의 개선을 보여준다. 사례 7은 LSTM이 가장 좋은 정확도를 보였으나, 기존의 학습 모델에 비해 안 좋은 정확도를 나타냈다. [Fig. 7]과 [Fig. 8]은 각각 가장 높은 정확도를 보인 사례 6에서의 RNN과 사례 5에서의 LSTM의 궤적글 보여준다. 직선(—) 데이터가 실제 실험 데이터이고, 쇠선(- · - ·) 데이터가 기존의 모델이다. 마지막 점선(- -) 데이터는 기계학습으로 모델을 생성한 데이터다. 사례 5와 같은 경우, 실제 경로와 매우 흡사한 경로를 보이고 있다.

MOHID 모델 대비 기법의 정확도는 LSTM이 47.59%의 개선율을 보였고, RNN이 45.29%의 개선율을 보였다.



[Fig. 7] Trajectories in Case 5: actual position, LSTM, and MOHID model



[Fig. 8] Trajectories in Case 6: actual position, RNN, and MOHID model

### 6. 결론 및 향후 연구

본 논문에서는 기존의 MOHID 수치모델을 개선하기 위해 기계학습 기법을 사용하여 기존의 뜰개의 이동경로 예측을 하는 모델을 만들었다. 저자가 아는 한 뜰개 이동 경로 예측에 기계학습 기법을 적용한 최초의 시도이다. 기계학습 기법으로는 SVR, RBFN, GP, MLP, RNN, LSTM 등 6 개를 사용하여 모델을 만들었다. 전체적으로 MOHID 수치모델에 비해 평균 29.61% 개선되었으며, 그 중 가장 좋은 성능을 보인 RNN과 LSTM이 각각 45.29%, 47.59%의 개선율을 보였다.

추후 연구 주제는 현재까지 연구한 내용을 바탕으로 앙상블을 통해 개선해 나가는 방향으로 진행할 예정이다.

<Table 7> Performance comparison of all the tested methods

	Evaluatiuon	Cross-validation						
		SVM	RBFN	GP	MLP	FNN	LSTM	MOHIDmodel
Instance 1	MAE	0.0667	0.0929	0.0939	0.0901	<b>0.0576</b>	0.0632	0.1354
	RMSE	0.0980	0.1422	0.1398	0.1368	<b>0.0939</b>	0.0974	0.2166
	NCLS	0.9383	0.9104	0.9119	0.9138	<b>0.9408</b>	0.9386	0.8634
Instance 5	MAE	0.0927	0.0971	0.0970	0.0996	0.0529	<b>0.0410</b>	0.1229
	RMSE	0.1520	0.1631	0.1610	0.1652	0.0854	<b>0.0615</b>	0.1895
	NCLS	0.7721	0.7529	0.7585	0.7497	0.8718	<b>0.9077</b>	0.7153
Instance 6	MAE	0.0389	0.0316	0.0355	0.0372	<b>0.0212</b>	0.0234	0.0664
	RMSE	0.0613	0.0497	0.0546	0.0569	<b>0.0328</b>	0.0371	0.1165
	NCLS	0.9204	0.9354	0.9290	0.9261	<b>0.9572</b>	0.9516	0.8479
Instance 7	MAE	0.0657	0.0854	0.0661	0.0718	0.0700	<b>0.0656</b>	<b>0.0440</b>
	RMSE	0.0984	0.1310	0.0960	0.1041	0.1097	<b>0.0992</b>	<b>0.0631</b>
	NCLS	0.8805	0.8409	0.8834	0.8736	0.8664	<b>0.8791</b>	<b>0.9231</b>

\*The lower values of MAE and RMSE are, the higher accuracy is. On the other hand, the closer to 1 NCLS is, the higher accuracy is.

구체적으로는 각각의 데이터를 바탕으로 모델을 만든 후에 가중치를 주는 배깅(bagging)과, 데이터에 여러 알고리즘으로 모델을 만든 후에 가중치를 주는 부스팅(boosting)을 통해 개선해 나아갈 예정이다. 또한 가중치 부여 방법을 성능에 따른 가중치를 할당 해주는 방법과 진화연산과 다른 기계학습 기법을 이용하여 가중치를 최적화 하는 방법을 연구할 예정이다.

### ACKNOWLEDGMENTS

본 논문은 해양경찰청의 재원으로 재난안전기술개발 사업단의 지원을 받아 수행된 연구입니다. [KCG-01-2017-05]

논문에 사용된 데이터를 가공하고 제공해준 ㈜아라중합기술의 김도연 이사님께 깊은 감사의 말을 전합니다.

### REFERENCES

[1] Davis, R. E. "Drifter observations of coastal surface currents during CODE: the statistical and dynamical views." *Journal of Geophysical Research: Oceans* Vol. 90, No. C3, pp.4756-4772, 1985.

[2] Fratantoni, D. M. "North Atlantic surface circulation during the 1990's observed with satellite tracked drifters." *Journal of Geophysical Research: Oceans* Vol. 106, No. C10, pp.22067-22093, 2001.

[3] MOHID, Water Modeling System, <http://www.mohid.com>

[4] Y. D. Yun, Y. Wook. Yang, H. S. Ji, H. S. Lim, "Development of Smart Senior Classification Model based on Activity Profile Using Machine Learning Method", *Journal of the Korea Convergence Society*, Vol. 8, No. 1, pp.25-34, 2017.

[5] Matkan, A. A., M. Hajeb, and Z. Azarakhsh. "Oil spill detection from SAR image using SVM based classification." *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* Vol. 1. No. 3, pp.55-60, 2013.

[6] Yoo, C. S., and Park, J. Y. "Combining radar and rain gauge observations utilizing Gaussian-process based regression and support vector learning." *Journal of Korean Institute of Intelligent Systems* Vol. 18, No. 3, pp.297-305, 2008.

[7] Đalto, M., Vašak, M., Baotić, M., Matuško, J., and Horvath, K. "Neural-network-based ultra-short-term wind forecasting." *European Wind Energy Association 2014 Annual Event 2014*.

[8] Baruque, B., Corchado, E., Mata, A., and Corchado, J. M. "forecasting solution to the oil spill problem

based on a hybrid intelligent system." Information Sciences Vol. 180, No.10, pp.2029-2043, 2010.

[9] Ramedani, Z., Omid, M., Keyhani, A., Shamshirband, S. and Khoshnevisan, B. "Potential of radial basis function based support vector regression for global solar radiation prediction." Renewable and Sustainable Energy Reviews 39, pp.1005-1011, 2014.

[10] Basak, D., Pal, S., and Patranabis, D. C. "Support vector regression." Neural Information Processing-Letters and Reviews Vol. 11, No. 10, pp.203-224, 2007.

[11] Orr, M. J. Introduction to Radial Basis Function Networks, Institute for Adaptive and Neural Computation, Edinburgh Univ 1996.

[12] Rasmussen, C. E., and Williams, C. K. Gaussian Processes for Machine Learning. Vol. 1. MIT press 2006.

[13] Gardner, M. W., and Dorling, S. R. "Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences." Atmospheric Environment Vol. 32, No. 14, pp.2627-2636, 1998.


[14] Mikolov, Tomas, et al. "Recurrent neural network based language model." Interspeech. Vol. 2. 2010.

[15] Sak, Haşim, Andrew Senior, and Françoise Beaufays. "Long short-term memory recurrent neural network architectures for large scale acoustic modeling." Fifteenth Annual Conference of the International Speech Communication Association. 2014.

[16] Liu, Y., and Weisberg, R. H. "Evaluation of trajectory modeling in different dynamic regions using normalized cumulative Lagrangian separation." Journal of Geophysical Research: Oceans Vol. 116, No.C9, 2011.

저자소개

이 찬 재(Chan-Jae Lee) [정회원]



- 2017년 2월 : 광운대학교 전자계량공학전공 학사
- 2017년 3월 ~ 현재 : 광운대학교 컴퓨터과학과 석사과정

<관심분야> : 기계학습, 최적화

김 경 도(Gyoung-Do Kim) [정회원]



- 2016년 8월 : 광운대학교 컴퓨터소프트웨어전공 학사
- 2016년 9월 ~ 현재 : 광운대학교 컴퓨터과학과 석사과정

<관심분야> : 데이터마이닝, 기계학습, 최적화

김 용 혁(Yong-Hyuk Kim) [정회원]



- 1999년 2월 : 서울대학교 전산과학전공 학사
- 2001년 2월 : 서울대학교 전기컴퓨터공학부 석사
- 2005년 2월 : 서울대학교 전기컴퓨터공학부 박사

- 2005년 3월 ~ 2007년 2월 : 서울대학교반도체공동연구소 연구원
- 2007년 3월 ~ 2017년 2월 : 광운대학교 컴퓨터소프트웨어학과 조교수/부교수
- 2017년 3월 ~ 현재 : 광운대학교 소프트웨어학부 교수

<관심분야> : 최적화, 진화연산, 지식공학