

Risk Classification of Vessel Navigation System using Correlation Weight of Marine Environment

Byoung Ho Song and Sang Hyun Bae[†]

해양 환경 요소 상관관계 가중치를 이용한 선박 항행 시스템의 위험도 분류

송병호 · 배상현[†]

Abstract

Various algorithms and system development are being required to support the advanced decision making of navigation information support system because of a serious loss of lives and property accidents by officer's error like as carelessness and decision faults. Much of researchers have introduced the techniques about the systems, but they hardly consider environmental factors. In this paper, We collect the context information in order to assess the risk, which is considered the various factor of the sailing ship, then extract the features of knowledge context, which is to apply the weight of correlation coefficients among data in context information. We decide the risk after the extract features through the classification and prediction of context information, and compare the value accuracy of proposed method in order to compare efficiency of the weighted value with the non-weighted value. As a result of experience, we know that the method of weight properties effectively reflect the marine environment because the weight accurate better than the non-weighted.

Key words : Risk Decision System, Safety Navigation, Context Aware, Marine Environment, Correlation.

1. 서 론

최근 해양에서의 사고 발생이 계속해서 증가하고 있으며 특히 해양사고 대부분이 운항부주의, 정비 불량 등 인적요인의 의한 어선사고인 것으로 나타났다.

일반적인 사고와는 달리 해양 사고는 인명 피해와 함께 심각한 자본의 손실을 초래한다.

이러한 사고는 대부분 항해사의 운항 부주의, 정비 불량 등 인적요인에 의한 사고가 주된 요인으로 파악되고 있다^[1].

이러한 인적 요인에 의한 해양 사고를 줄이기 위해 환경 자원에 영향을 받지 않는 형태를 지니며 항해사를 보조 혹은 대처할 수 있는 지능형 항행 안전 시스템의 필요성이 제기되어왔으며 이러한 시스템에 대한 연구는 1950년대 유럽에서 시작되어 지금까지도 여러 가지 접근을 통해서 제안되고 있다.

관련 연구를 살펴보면, 퍼지 제어를 이용한 자동 충돌 회피연구^[2]와 뉴로-퍼지 기법을 이용한 선박의 충돌 회피에 대한 연구^[3], JDL(Joint Director of Labs)모듈을 이용한 선박 정보융합 시스템^[4,5]이 있다.

지금까지 제안된 여러 연구들은 타 선박이나 고정 장애물에 대해서 어느 정도의 적절한 회피 결과를 보이지만 주변 환경 요소에 대한 고려는 거의 되어있지 않다는 문제점이 있다. 본 논문에서 고려하는 주변 환경 요소란 수심, 풍속, 풍향, 조류 등 실시간으로 얻을 수 있는 주변 상황에 대한 데이터이다. 실제 항행상황에서 항해사는 구체적인 수치가 아닌 경험에 의한 판단으로 이 주변 환경 요소들을 판단하는데, 이러한 주관적인 판단은 위험도를 가중 시키는 결과를 초래한다.

따라서, 지능형 선박에서는 주변 환경 요소를 고려한 보다 정확하고 신뢰성이 보장된 위험도가 제공되어야 한다. 이에 본 논문에서는 항행 선박의 다양한 주변 환경 요소가 고려된 위험도를 평가하기 위해 해양 환경에 대한 상황 정보와 선박의 위험도를 판단하기 위한 선체 위험 상황 정보(선박의 뒤틀림, 기울기)를 수집한 후 상황 정보 내 데이터 간의 상관계수 가중치를

조선대학교(375 Seosuk-dong, Dong-gu, Gwangju 501-759, Korea)

[†]Corresponding author: shbae@chosun.ac.kr

(Received : March 2, 2011, Revised : March 16, 2011,

Accepted : March 21, 2011)

적용하여 상황 정보의 특징을 추출하였다. 특징 추출 후 상황 정보의 분류와 예측 과정을 거친 후 위험도를 결정함으로써, 정확도를 높이고 예측 확률을 높이고자 한다.

해양 환경 요소가 선박에 미치는 영향에 따라 위험 정도를 학습 후 분류하는 KNN(k-Nearest neighbor) 알고리즘을 이용하였고, 제안한 방법의 효율성을 비교하기 위해 가중치 적용과 미적용 시 정확도를 비교하였다. KNN 알고리즘의 적용에 있어서 각 속성에 대하여 정확한 가중치 부여는 KNN 알고리즘의 성능에 많은 영향을 미친다. 즉, 모든 속성을 같은 비중으로 판단하게 되면 KNN 알고리즘은 높은 성능을 제공할 수 없다. 저장된 데이터베이스에서 항행중인 선박의 위험 정도를 예측 할 때 데이터베이스의 풍속, 수심, 조류 속성은 선박의 뒤틀림 정도나 기울기 정도에 대하여 높은 연관을 가지며 따라서 높은 가중치를 부여하여야 한다. 이와 같이, 데이터베이스에서 특정한 목적속성(target attribute)의 값을 예측/분류 하고자 할 때 목적 속성을 제외한 다른 속성의 가중치는 목적 속성에 따라서 그 값을 달리하게 된다. 본 논문은 다음과 같이 구성되었다. 2장에서는 관련 연구 동향을 알아보고 3장에서는 입력 사례 데이터 측정 및 사례베이스 구축, 4장은 시스템 구현 결과를 보여주고 5장에서는 성능 평가에 대해서 기술한다. 6장에서는 결론과 향후 연구 방향을 제시한다.

2. 관련 연구

2.1. 해양 환경 요소 상관관계

본 논문에서는 선박의 항행시 해양 환경 요소가 선체에 미치는 위험도를 상관계수 가중치를 이용하여 추정하고자 한다. 선박의 항행시 영향을 미치는 해양 환경은 선박 주변의 해류 및 조류, 수심, 풍향 및 풍속 등 선박에게 직·간접적으로 영향을 끼치는 모든 요소들을 말한다. 최근 선박 주변의 해류 및 조류 요소와 풍속, 풍향 요소는 선박 내 동력기관의 출력이 향상됨으로써 그 방향과 속도가 본선의 항로 설정에 미치는 영향이 예전보다 적어졌다. 하지만 그 방향과 속도에 따라서 위험도가 기하급수적으로 증가하므로, 여전히 주의해야 할 환경 요소이다. 기존의 연구에서 해양 환경 요소는 제한 항행구역으로 가정하거나 본선의 항행에 영향을 끼치지 않는 고정 요소로 가정을 하는 경향이 있다.

실제 항행상황에서 항해사는 구체적인 수치가 아닌 경험에 의한 판단으로 이 주변 환경 요소들을 판단하

는데, 이러한 주관적인 판단은 위험을 초래한다. 한편, 항행 중인 선박에서 발생하는 정보들은 그 양이 많고 빠르게 갱신된다. 그로 인해 항해사는 견시 업무의 대부분을 정보 확인에 소모하게 되고, 기존 업무에 추가적인 업무 부담을 초래한다.

이러한 문제를 해결하기 위해 항행정보지원체계의 의사결정 지원을 위한 다양한 알고리즘과 시스템 연구가 진행되고 있다^[6,7]. 기존의 연구에서는 해양 환경 요소들간의 관계를 고려하지 않고 위험도를 계산하였다. 하지만 해양 환경 요소와 선박의 항행 데이터간의 관계를 고려한다면 위험도의 정확도를 높일 수 있다.

본 논문에서는 항행 선박의 다양한 주변 환경 요소가 고려된 위험도를 평가하기 위해 해양 환경에 대한 상황 정보를 수집한 후 상황 정보 내 데이터 간의 상관 계수 가중치를 적용하였다.

2.2. Knn 알고리즘

본 논문에서는 해양 환경 요소가 선박에 미치는 영향에 따라 위험 정도를 학습 후 분류하는 최근접 이웃 알고리즘 알고리즘을 이용하였다.

최근접 이웃 알고리즘(k nearest neighbor algorithm)은 이미 알려진 개체들을 훈련 집합(training set)의 형태로 메모리에 기억한 다음 그 중 유사한 개체를 선택하여 선택된 개체의 값에 따라 새로운 개체의 값을 예측하는 방식의 분류 알고리즘이다.

KNN 알고리즘은 입력 패턴이 주어졌을 때 유사도 함수에 기반하여 미리 저장 되어있는 표준 패턴들의 집합에서 입력 패턴과 가장 유사한 k 개의 표준 패턴들을 선택한다.

선택된 k 개의 표준패턴들의 클래스들을 확인하여 가장 많이 선택된 표준 패턴들의 클래스를 입력 패턴의 클래스로 결정한다. 그림 1은 kNN 알고리즘의 수행 과정을 나타낸다. KNN 알고리즘에 대한 선행 연구를 살펴보면 KNN 알고리즘은 최초로 Cover 와 Har에 의

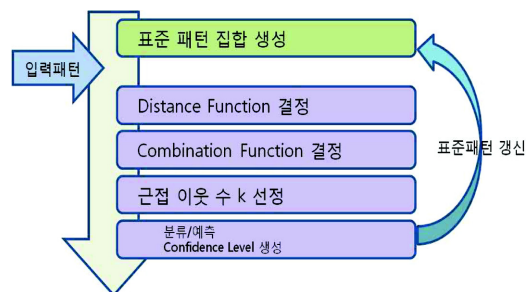


그림 1. kNN 알고리즘 수행 과정.
Fig 1. kNN Algorithm Execute Process.

하여 각각 독립적으로 제안되었다^[8]. 이 후 Smith와 Medin 등에 의하여 KNN 알고리즘은 논리적으로 그 타당성을 인정받았지만 실제 알고리즘을 위한 모델은 개발되지 않은 상태였다^[9]. 이후 Aha, Kibler and Albert에 의하여 몇 개의 개체중심 학습(instance-based learning, IBL) 알고리즘이 개발되었다^[10]. KNN 알고리즘은 여러 분야에서 적용되고 있으며 그 성능을 검증 받고 있는 기계 학습 방법 중의 하나이다.

3. 시스템 구성 및 설계

본 논문에서는 항행 선박의 다양한 주변 환경 요소가 고려된 위험도를 평가하기 위해 해양 환경에 대한 상황 정보와 선박의 위험도를 판단하기 위한 선체 위험 상황 정보(선박의 뒤틀림, 기울기)를 측정하였다. 즉, 해양 환경 요소에 대한 각각의 데이터에 대해 상관계수 가중치를 적용하여 선박의 뒤틀림과 기울기에 미치는 위험도를 결정한다. 그림 2는 항행 선박의 위험도 평가를 위한 시스템의 전체 구성도 이다.

제안하는 시스템은 크게 전처리 단계, 상관관계 가중치 계산, 위험도 평가 과정으로 이루어진다.

전처리 단계에서는 센서와 AIS로부터의 초기 입력 데이터를 분류하여 데이터베이스에 저장한다.

상관관계 가중치 계산 단계에서는 측정된 해양 환경 데이터 간의 상관계수 가중치를 적용하여 상황 정보의 특징을 추출하였다.

위험도 평가 단계에서는 상관계수 가중치가 적용된 데이터를 Knn 알고리즘을 이용하여 위험도를 분류, 예측한다.

3.1. 해양 환경 요소 데이터

본 논문에서 주변 환경 요소 데이터는 AIS(Automatic Identification System)에서 제공하는 정보를 이용하였다.

AIS는 선박의 위치, 침로, 속력 등 항해 정보를 실시간으로 제공하는 첨단 장치로서, 국제 해사 기구(IMO)가 추진하는 의무 사항이며, 선박 자동 식별 장치(AIS)가 도입되면 주위의 선박을 인식할 수 없는 경우에도 타선의 존재와 진행 상황 판단이 가능하고, 시계가 좋지 않은 경우에도 선명 · 침로 · 속력 식별이 가능하여 선박 충돌 방지, 광역 관제, 조난 선박의 수색 및 구조 활동 등 안전 관리를 더욱 효과적으로 수행할 수 있는 시스템이다. AIS 시스템에서 측정되는 풍속은 보통 초당 미터(%)나 노트(Knot)로 표시한다. 그리고 일반적인 풍속계로 잴 수 없을 정도로 매우 강한 바람에 대해

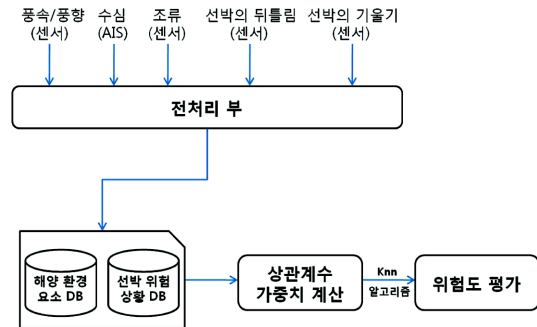


그림 2. 시스템 구성도.
Fig 2. System block diagram.

서는 F-스케일로 나타낸다.

해상에서 사용되는 풍속 측정기의 경우는 Vane probe 방식을 사용하며 5~40 m/s의 풍속 측정에 이상적이다. Vane probe 측정원리는 vane의 회전 수를 전 기신호로 바꾸는 원리에 기반하여 풍속을 측정한다.

3.2. 선체 위험 상황 데이터

항행 중인 선박은 주변 환경 요소의 영향에 의해 선박의 기울기와 뒤틀림 정도가 달라질 것이다.

선체의 운동은 단방향성이 아닌 전방향성을 가지고 있기에, 모든 방향에서의 흔들림을 종합적으로 고려해야 한다. 표 1은 선체의 흔들림 운동에 대한 설명이다.

3.2.1. 선박의 기울기 측정

본 논문에서는 3축 가속도 센서인 withrobot사의 myAccel3LV02 보드를 이용하여 선체의 기울기를 측정하였다. myAccel3LV02 보드는 한 개의 센서 보드에

표 1. 선체의 흔들림 운동
Table 1. Body of a ship wavering movement

종류	내용
롤링 (횡동요)	배가 폭 방향으로 좌우로 흔들리는 운동
핏 (종동요)	배의 선수와 선미가 번갈아 가며 상하로 올라갔다 내려갔다 하는 운동
히빙 (상하요)	배 전체가 위로 솟구쳐 올랐다가 다시 떨어지는 것(배 전체가 아래, 위 운동)
스웨이잉 (좌우요)	배 전체가 옆으로 미끄러지듯이 좌우로 왔다 갔다 하는 운동
씨징 (전후요)	배 전체가 앞뒤로 왔다 갔다 하는 운동
요잉 (선수요)	배의 선수가 좌우로 도는 운동

```

1 Acc = load('Accel.txt');
2
3 ts = 0.01;
4 EncAngle = Acc(:,1)*360/2000;
5 AccY = Acc(:,2);
6 AccZ = Acc(:,4);
7 [N, temp] = size(EncAngle);
8 t = 0:ts:(N-1);
9
10 AccAngle = -atan(AccY./AccZ)+180/pi;
11
12 figure
13 plot(t, EncAngle)
14 grid on
15 hold on
16 xlabel('second');
17 ylabel('degree');
18 plot(t, AccAngle, 'r');
19 legend('Encoder', 'Accelerometer');
20 hold off
    
```

그림 3. 가속도 변환 소스 코드.
Fig 3. Acceleration conversion source cod.

서 3축 가속도를 측정하고 측정 범위는 -40도에서 +85도까지이며 12비트 ADC를 내장하여 디지털 값을 출력한다. 센서로부터 전송된 데이터는 x, y, z 세 방향의 좌표를 나타내는 데이터이다. 식 1과 같이 atan 함수를 이용해서 선체의 기울어진 각도를 측정한다.

$$\theta = \tan^{-1}\left(\frac{y}{z}\right) \quad (1)$$

여기서, y는 가속도 센서의 y 출력 값이고 z는 가속도 센서의 z 출력 값이다. 그림 3은 가속도 변환 소스 코드이다.

3.2.2. 선박의 뒤틀림 측정

선박 환경의 특수사항인 선체저항과 흔들림 운동을 고려하여 선체에 가해지는 외력에 의한 뒤틀림을 측정하기 위하여 스트레인 게이지 센서를 이용하여 선체의 좌우 뒤틀림에 대한 변형율을 측정한다. 스트레인 게이지는 측정하는 대상의 변형을 직접 측정할 수 있으며, 이를 전기적인 신호로 바꾸어 우리가 얻고자 하는 변형율을 측정할 수 있다. 변형의 방향에 따라 얻은 전압 신호를 A/D 변환기를 통해서 오실리코프상에 저장하고 후처리하였다. 그림 4를 보면 게이지 센서로부터 수신한 데이터는 AD627을 통해 SIGOUT으로 빠져 나간다. SIGOUT은 신호가 매우 약하므로 2번의 증폭회로를 거치게 되고 증폭회로를 거친 데이터는 컨트롤러의 ADC채널로 입력된다.

그림 5는 A/D 변환기를 통해서 오실리코프상에 저장된 선박의 뒤틀림 정도를 나타낸다. 빨간 선을 기준으로 왼쪽으로 휘었을 때에 위로 올라가고, 오른쪽으로 휘었을 때에 아래로 내려가게 된다.

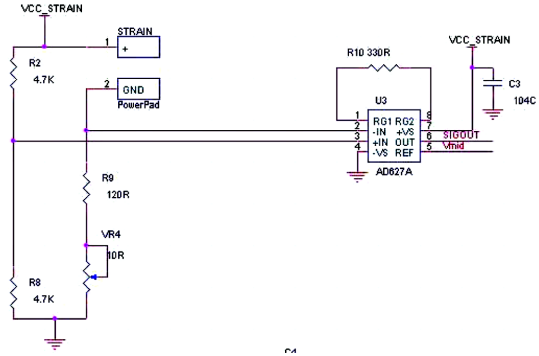


그림 4. 스트레인 게이지 센서 구성.
Fig. 4. Composition of strain gauge sensor.



그림 5. 뒤틀림 실험 결과.
Fig. 5. Result of warping.

3.3. 상관계수 가중치

수집된 주변 해양 환경에 대한 상황 정보 내 데이터 간의 상관계수 가중치를 적용하여 특징을 추출하였다. 먼저, 상관 관계 가중치를 부여하기 위해서 상황 정보 내 데이터를 식 (2)를 이용하여 정규 분포를 따르도록 표준화하였다.

$$\alpha = \frac{X - \text{Min}(X)}{\text{Max}(X) - \text{Min}(X)} \quad (2)$$

표준화된 데이터에 상관관계를 적용하기 위해서는 상관계수를 이용한다.

상관계수는 두 데이터간의 상관관계의 정도를 나타내는 수 값으로 1과 -1 사이의 값을 가진다.

두 데이터간의 상관관계가 높으면 1에, 낮으면 0에 가깝고, 정반대인 경우에는 -1에 가까워진다^[11].

본 논문에서는 데이터가 정규 분포를 따를 때에 상관계수를 구하는 방법인 피어슨 상관계수를 이용하였다.

피어슨 상관계수를 구하는 식은 식 (3)과 같다.

$$r_{pearson} = \frac{\sum XY - \frac{\sum X \sum Y}{N}}{\left(\sum X^2 - \frac{(\sum X)^2}{N}\right)\left(\sum Y^2 - \frac{(\sum Y)^2}{N}\right)} \quad (3)$$

식 (3)과 같이 피어슨 상관계수를 이용하여 상관계수를 계산하면 환경 요소 데이터간의 상관관계를 나타낼 수 있다.

3.4. Knn 알고리즘을 이용한 위험도 분류

본 논문에서는 해양 환경 요소와 연관성에 따라 상관계수 가중치가 적용된 데이터에 대해 위험도를 분류하기 위해 KNN 알고리즘을 이용하였다.

KNN 알고리즘은 입력 패턴이 주어졌을 때 유사도 함수에 기반하여 미리 저장 되어있는 표준 패턴들의 집합에서 입력 패턴과 가장 유사한 k 개의 표준 패턴들을 선택한다.

선택된 k 개의 표준패턴들의 클래스들을 확인하여 가장 많이 선택된 표준 패턴들의 클래스를 입력 패턴의 클래스로 결정한다.

본 논문에서 입력 패턴과 표준 패턴과의 유사도 총 유사도 $S(N, O)$ 는 식 (4)와 같이 속성 i 별로 유사도 점수인 $f(N_i, O_i)$ 를 구하고, 각 속성의 가중치를 곱한 후 이를 총합하여 계산한다.

$$S(N, O) = \frac{\sum_{i=1}^n f(N_i, O_i) \times W_i}{\sum_{i=1}^n W_i} \quad (4)$$

여기에서, n 은 속성의 개수, $f(N_i, O_i)$ 는 사례 N 과 O 의 i 속성 간의 유사도 점수, W_i 는 i 속성의 가중치를 의미한다.

속성 간의 유사도 점수인 $f(N_i, O_i)$ 는 속성의 유형(수치형, 범주형)에 따라 달라지는 데 본 논문에서는 입력 데이터가 모두 수치형이기 때문에 유사도 점수는 식 (5)와 같이 계산한다.

$$f(N_i, O_i) = 1 - \frac{a_i - b_i}{\max_i} \quad (5)$$

Knn 알고리즘은 최근접 이웃의 수 k 와 유사도 산출에 사용되는 속성들의 가중치로부터 많은 영향을 받게 된다.

본 논문에서는 풍속, 수심, 조류의 표준화 데이터 벡터를 생성한 후, 각 가중치 벡터에 대해서 k 를 1부터

```

step 1 :  $D_k = \{ \}$ ;
step 2 :  $(d_m, m_s) = (\phi, 0)$ ;
step 3 : For each  $d_i \in D$  {
step 3-1 :  $s_i = compute\_similarity(d, d_i)$ 
step 4 : if  $(m_s < s_i)$  {
            $D_k = D_k \cup \{ < d_i, s_i > \} - \{ d_m, m_s \}$ 
            $(d_m, m_s) = find\_minimal\_similarity(D_k)$ 
           }
        }
step 5 :  $C$ 의 계수를 0으로 초기화
step 6 : For each  $d_{s_i} \in D_k$  {
step 7 :    $C$ 의 계수 증가
        }
step 8 :  $C$ 를 계수값으로 정렬하여 출력
    
```

그림 6. 알고리즘 구성.
Fig. 6. Algorithm configuration.

10까지 1씩 증가시키면서 실험을 수행함으로 시스템을 최적화 한다.

그림 6은 본 논문에서 제안한 선체의 위험도를 분류하기 위한 Knn 알고리즘의 구성도이다.

여기에서, D_k 는 k 개의 가장 큰 유사성을 갖는 표준패턴의 집합, C 는 분류, m_s 는 D_k 에서 최소 유사성, 출력은 등급화된 C 를 의미한다.

Knn 알고리즘의 구성은 다음과 같은 프로시저를 따른다.

- ① k 값을 선정한다.
- ② 새로운 패턴과 표준 패턴들의 특징 값들을 이용하여 유클리디언 거리를 계산한다.
- ③ 계산된 거리 값들 중에서 가장 가까운 거리 값의 표준 패턴을 k 개만큼 선정한다.
- ④ k 개만큼 선정된 거리 값들 중 가장 많이 선택된 타입을 위험도 타입으로 선정한다.

3.5. 인공 신경망 모형

본 논문에서는 제안한 Knn 알고리즘의 유용성을 검증하기 위한 비교 대상으로 신경망 분석을 수행하였다.

신경망 알고리즘은 다층 퍼셉트론 구조로 비선형 판별 문제를 해결할 수 있는 알고리즘으로 많이 이용되어 왔으며, 기타 인공지능 기법에 비해 예측력이 우수하다고 알려져 있다.

본 논문에서 사용한 신경망은 가장 일반적인 형태의 신경망인 다층 퍼셉트론(MLP)을 사용하였으며 오류역전파 알고리즘을 적용하여 신경망을 학습하였다.

일반적으로 신경망의 성능에 영향을 미치는 요인으로는 은닉층 수, 은닉노드 수, 학습 횟수 등이 있다.

본 논문에서는 은닉층이 하나인 2층 퍼셉트론 구조에 은닉 노드 수는 3개, 학습 데이터로부터의 영향을 최소화하고 신뢰성을 확보하기 위해 10-Fold 교차검증을 수행하였다.

4. 실험 및 구현 결과

본 논문에서는 해양 환경 요소가 선박에 미치는 영향에 따라 각 요소들의 상관관계에 따라 가중치를 부여하여 위험도를 분류하는 KNN(k-Nearest neighbor) 알고리즘을 이용하였고, 제안한 방법의 효율성을 비교하기 위해 가중치 적용과 미적용 시 정확도를 비교하였다.

시물레이션을 위해 해양 환경 요소인 풍속, 조류, 수심 데이터는 AIS 데이터를 가정하였고, 항행 중인 선박의 뒤틀림과 기울기 데이터를 추정하였다.

상관 관계 가중치를 부여하기 위해서 상황 정보 내 데이터를 정규 분포를 따르도록 표준화하였고, 피어슨 상관계수를 이용하여 상관 관계를 계산하였다.

수집한 해양 환경 요소 데이터와 선박의 위험 상황 데이터간의 상관계수를 계산한 결과 값은 표 2와 같다.

표 2에서 나타나는 결과를 보면, 해양 환경 요소 중 풍속과 조류의 속도가 선박의 위험 상황 발생에 가장 큰 영향을 미치는 것을 보여주고 있다.

표 2와 같이 계산된 상관계수를 이용하여 각 속성에 대한 가중치를 부여하여 상황 정보로 변환한다.

변환된 상황 정보들에 대해 Knn 알고리즘 학습을 수행하였고, 실험 결과에 대해 학습 데이터로부터의 영향을 최소화하고 신뢰성을 확보하기 위해 10-Fold 교차검증을 수행하였다.

실험 데이터는 테스트 데이터와 검증용 데이터로 구분되며 각각 7:3의 비율로 사용하였고, 테스트 집합의 모든 개체에 대하여 예측결과를 실제 결과와 비교하여 그 정확도를 계산하였다.

표 3은 각 데이터에 대하여 속성의 가중치를 고려한 알고리즘과 고려하지 않는 알고리즘의 정확도를 표준 편차의 범위와 함께 보여주고 있다.

표 2. 상관 관계 결과
Table 2. Result of Correlation

	풍속	수심	조류의 속도
뒤틀림	0.93	0.63	0.87
기울기	0.95	0.75	0.91

표 3. 가중치 적용에 따른 정확도 비교
Table 3. Performance evaluation of data

Fold 번호	가중치 적용시	가중치 미적용시
1	87.2 ± 2.28	85.3 ± 2.51
2	88.6 ± 2.71	83.4 ± 2.70
3	89.3 ± 2.55	86.3 ± 2.58
4	88.2 ± 2.64	86.9 ± 2.95
5	91.4 ± 1.57	88.2 ± 2.12
6	94.3 ± 1.28	86.5 ± 1.97
7	91.7 ± 1.53	89.8 ± 1.84
8	90.1 ± 2.02	86.2 ± 2.95
9	89.5 ± 2.35	85.7 ± 3.01
10	87.6 ± 2.43	84.1 ± 2.73




그림 7. 알고리즘 정확도 비교.
Fig 7. Algorithm configuration.

표 3과 같이 속성의 가중치를 고려한 알고리즘과 고려하지 않는 알고리즘의 정확도를 측정한 결과 모든 경우에 대하여 속성의 가중치를 적용한 방법이 속성의 가중치를 고려하지 않는 방법에 비하여 높은 정확도를 보임을 알 수 있다.

제안한 알고리즘의 유용성 확인을 위해서 은닉층이 하나인 2층 퍼셉트론 구조에 은닉 노드 수는 3개인 신경망 모델과 성능을 비교 하였다. 그림 7은 알고리즘 성능 평가 결과이다.

그림 7을 보면 본 논문에서 제안한 가중치를 부여한 Knn 알고리즘의 평균 정확도가 신경망 알고리즘을 적용한 모델보다 위험도 분류 정확도가 높음을 알 수 있다.

그림 8은 유사도 분류 k 개수를 조정해 가면서 실험을 수행한 결과이다. k의 개수가 아주 낮거나 높은 경우에는 정확도가 상대적으로 감소함을 알 수 있었고 k가 7인 경우에 가장 좋은 성능을 보였다.

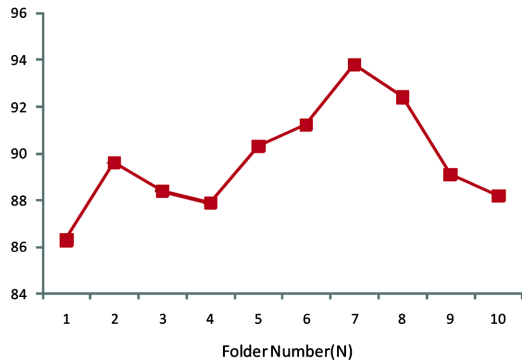


그림 8. k 개수에 따른 정확도 변화.
Fig 8. Accuracy change by number of k.

5 결 론

최근 해양에서의 증가하는 사고 발생은 인명 피해와 함께 심각한 자본의 손실을 초래하므로 해상 상황에 따라 항행정보지원체계의 의사결정 지원을 위한 다양한 알고리즘과 시스템 도입이 필요하다.

본 논문에서는 항행 선박의 다양한 주변 환경 요소가 고려된 위험도를 평가하기 위해 해양 환경 요소와 선체 위험 상황 정보(선박의 뒤틀림, 기울기)를 수집한 후 상황 정보 내 데이터 간의 상관관계 가중치를 적용하여 상황 정보의 특징을 추출하였다.

특징 추출 결과 해양 환경 요소 중 풍속과 조류의 속도가 선박의 위험 상황 발생에 가장 큰 영향을 미치는 것으로 나타났다. 각 데이터에 대하여 속성의 가중치를 고려한 알고리즘과 고려하지 않는 알고리즘의 정확도를 측정 한 결과 모든 경우에 대하여 속성의 가중치를 적용한 방법이 속성의 가중치를 고려하지 않는 방법에 비하여 높은 정확도를 보임을 알 수 있다.

기존의 선박 항행 시스템은 항행 주변 환경 요소가 고려되어 있지 않기 때문에, 보다 안전한 항행 안전 상황에 관한 정보를 제공하는 요소 기술로 활용 가능할 것이다.

감사의 글

이 논문은 2010년도 조선대학교 학술연구비의 지원을 받아 연구 되었음.

참고문헌

- [1] 양원재, 금종수, “항해사의 피로도 평가모델에 관한 연구”, 해양환경안전학회, 2006년도 춘계 학술발표회, pp. 1- 6, 2006.
- [2] K. Hasegawa, “Automatic Collision Avoidance System for Ships using Fuzzy Control”, 8th Ship Control System Symposium, Hague, pp. 34-58, 1987.
- [3] 안진형, “뉴로-퍼지 기법을 이용한 선박의 충돌 회피에 관한 연구”, 서울대학교 대학원, 2005.
- [4] T. Neumann, “Multisensor Data Fusion in the decision process on the bridge of the vessel”, Gdynia Maritime University, Ddynia, Poland, 2007.
- [5] 김도연, 조대운, 이미라, 박계각, “정보융합 기술 기반의 지능형 항행안전정보 시스템”, 한국지능시스템학회논문지, Vol 20, No.2, pp. 226-233, 2010.
- [6] 손남선, 김선영, “시뮬레이터 기반 음성을 이용한 항행정보 안내시스템의 개발”, 한국해양환경공학회지 제 5권 제 3호, pp. 28-34, 2002.
- [7] 김도연, 이미라, 박계각, “퍼지를 이용한 항행 선박 주변 환경의 위험도 평가”, 한국 지능 시스템 학회, Vol.20, No.1, pp. 276-280, 2010
- [8] T. M. Cover and P. E. Hart, “Nearest Neighbor Pattern Classification”, IEEE Transactions on Information Theory, Vol. 13, 1967.
- [9] E. E. Smith and D. L. Medin, “Categories and Concepts”, Cambridge, MA: Harvard University Press, 1981.
- [10] D. Aha, D. Kibler and M. Albert, “Instance-based Learning Algorithms”, Machine Learning, 6(1) pp. 37-66, 1991.
- [11] S.-B. Cho, J. W. Ryu, “Classifying gene expression data of cancer using classifier ensemble with mutually exclusive features”, Proceedings of the IEEE, Vol. 90 Issue.11, 2002.