

교통 네트워크 모델 기반 이상 운항 선박 식별에 관한 연구

오재용* · 김혜진**†

*, ** 한국해양과학기술원 부설 선박해양플랜트연구소 책임연구원

Navigational Anomaly Detection using a Traffic Network Model

Jaeyong Oh* · Hye-Jin Kim**†

*, ** Principal Researcher, Korea Research Institute of Ships and Ocean Engineering, Daejeon, Korea

요약 : 해상교통관제센터(VTS)의 관제사는 구역 내 교통 상황을 빠르고 정확하게 파악하여 관제가 필요한 선박에게 정보를 제공하는 역할을 수행한다. 그러나 교통량이 급격히 증가하는 경우 관제사의 업무 부하로 인해 관제 공백이 발생하기도 한다. 이러한 이유에서 관제사의 업무 부하를 줄이고, 일관성 있는 관제 정보를 제공할 수 있는 관제 지원 기술의 개발이 필요한 실정이며, 본 논문에서는 구역 내 이상 운항 선박을 자동으로 식별하는 모델을 제안하였다. 제안하는 이상 운항 식별 모델은 규칙 기반 모델, 위치 기반 모델, 맥락 기반 모델로 구성되며, 대상 해역의 교통 특성에 최적화된 교통 네트워크 모델을 사용하는 특징이 있다. 구현된 모델은 시범센터(대산항 VTS)에서 수집되는 실해역 데이터를 적용하여 실험을 수행하였다. 실험을 통해 실해역의 다양한 이상 운항 상황이 자동으로 식별됨을 확인하였고, 전문가 평가를 통해 식별 결과를 검증하였다.

핵심용어 : 해상교통, 교통 네트워크 모델, AIS, 항적, 이상 운항

Abstract : Vessel traffic service operators (VTSOs) need to quickly and accurately analyze the maritime traffic situation in the vessel traffic service (VTS) area and provide information to the vessels. However, if traffic increases rapidly, the workload of VTSOs increases, and they may not be able to provide adequate information. Therefore, it is essential to develop VTSO support technologies that can reduce their workload and provide consistent information. In this paper, we propose a model for automatically detecting abnormal vessels in the VTS area. The proposed model consists of a positional model and a contextual model and is specifically optimized for the traffic characteristics of the target area. The implemented model was tested by using real-world data collected at a test center (Daesan Port VTS). Our experiments confirmed that the model could automatically detect various abnormal situations, and the results were validated through expert evaluation.

Key Words : Maritime traffic, Traffic network model, AIS, Vessel trajectory, Navigational anomaly

1. 서론

해양 사고는 해양 및 내수면에서 선박의 설비 또는 운용과 관련하여 발생한 사고를 의미하며, 선박의 충돌뿐만 아니라, 좌초, 전복, 침몰, 화재, 기관 손상 등 다양한 유형이 존재한다(Ministry of Government Legislation, 2023). 이러한 해양 사고는 인적, 경제적 손실을 동반하며, 심각한 해양환경 오염을 일으키기도 한다. 특히 항만시설 부근에서는 여러 선박이 복잡하게 운항하고 있으며, 이곳에서 발생하는 해양 사고는 대형 재난으로 이어지기 때문에 각별한 주의가 필요

하다. 이를 위해 해양경찰청은 주요 무역항에 해상교통관제센터(VTS 센터)를 설치 운영함으로써 선박 교통안전과 효율성을 확보하고, 해양환경을 보호하기 위해 노력하고 있다.

이에 해상교통관제사는 AIS(Automatic Identification System), 레이더, 기상 센서 등의 첨단 장비를 이용하여 관제구역을 통항하는 선박의 동정을 관찰하고, 이들의 관계가 어떻게 변화할 것인지를 예측하여 필요한 정보를 제공하는 관제 업무를 수행하고 있다(Korea Coast Guard, 2023). 관제구역은 원활한 관제 업무를 위해 더 작은 섹터로 분할하기도 하며, 각 구역별로 1명 혹은 2명의 관제사가 관제를 담당하고 있다.

그러나 최근 교통량이 증가함에 따라 관제구역이 넓어지고 있으며, 특히 교통량이 폭주하는 경우, 관제 업무에 부하가 발생하게 되어 인적 오류가 발생하기도 한다(Moreno, 2022).

* First Author : ojyong@kriso.re.kr, 042-866-3648

† Corresponding Author : hjk@kriso.re.kr, 042-866-3649

이 경우 관제가 필요한 선박에 정보를 적시에 제공하지 못하는 관제 공백이 발생하게 되며, 자칫 해양 사고로 이어질 수도 있다.

이렇듯 해상교통관제사는 관제 구역의 교통 상황을 정확히 파악하여 관제가 필요한 시점과 제공되어야 하는 정보를 빠르게 판단해야 하므로, 많은 배경지식과 관제 노하우가 요구된다. 이러한 관제 업무는 관제사의 경험에 의존할 수밖에 없으며, 직무 능력에 따라 개인차가 생기기도 한다. (Lee et al., 2016).

이에 해상교통관제사의 업무 부하를 줄이고, 객관화된 관제 정보를 제공할 수 있는 기술의 개발이 필요하며, 본 논문에서는 관제 구역 내의 이상 운항 선박을 자동으로 식별하는 방법을 제안하고, 실험역 데이터를 이용한 실험을 통해 그 활용 가능성을 고찰하고자 한다.

2. 선행 연구 분석

선박의 이상 운항 상황(navigational anomaly)을 자동으로 식별하기 위한 가장 단순한 방법은 이상 운항 상황을 규칙으로 정의하여 식별하는 방법이다. 예를 들어, 해당 해역에서의 제한 속도를 미리 정의하고, 이를 초과하는 선박은 이상 운항 상태로 식별할 수 있다. 그러나 제한 속도와 같이 단순하게 규칙을 정의할 수 있는 경우도 있지만, 규칙으로 정의하기 어려운 경우가 훨씬 더 많으며, 실제 해역에서의 발생하는 모든 운항 상황을 규칙으로 정의하는 것은 불가능에 가깝다.

최근에는 다양한 인공지능 기법 기반의 이상 운항 식별에 관한 연구가 많이 진행되고 있다. 실험역의 항적 데이터에는 이상 운항 데이터가 거의 포함되어 있지 않기 때문에, 학습용 데이터를 확보하는 것이 쉽지 않다. 더욱이 데이터를 확보하더라도 모든 항적을 수작업으로 분류하고 이를 정상(normal) 혹은 이상(abnormal) 데이터로 분류하기에는 많은 어려움이 따른다.

이와 같은 이유로 이상 운항 식별 분야에서는 비지도 학습(unsupervised learning) 방법이 주로 사용된다. 비지도 학습 방법은 분류되지 않은 학습 데이터로부터 패턴과 데이터 간의 상관관계를 찾아내는 데이터 분석 방법으로, 확률 모델을 기반으로 하는 KDE(Kernel Density Estimation), GMM(Gaussian Mixture Model) 방법과 데이터의 특징에 따라 분류하는 군집화(clustering) 알고리즘, 오토인코더(auto-encoder)와 같은 신경망(artificial neural network)을 이용한 방법이 이에 속한다. Fig. 1은 비지도 학습 방법을 기반으로 하는 이상 탐지 방법의 분류를 나타낸다.

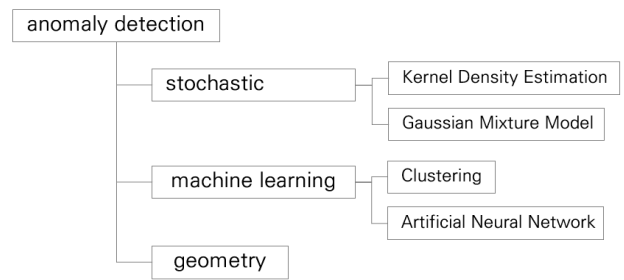


Fig. 1. Classification of the anomaly detection approaches based on unsupervised learning method.

일반적으로 선박의 이상 운항을 탐지하기 위해 대용량의 항적 데이터를 이용하여 표준 항로를 추정하고, 이를 기준으로 항로의 이탈을 식별하는 방법이 주로 사용된다(Wang et al., 2014; Zhen et al., 2017). 이 방법들은 대상 해역에서의 표준 항로 생성이 탐지 성능에 큰 영향을 미치기 때문에 보다 정확한 표준 항로를 생성하기 위해 다양한 방법들이 시도되고 있다. 그러나 이러한 방법들은 복잡한 운항 패턴을 가진 해역의 경우 항로를 표준화하는데 한계가 있어 활용에 제약이 따른다. 또한, 대표적인 인공 신경망 기반 비지도 학습 방법인 오토인코더를 이용하여 대상 해역 전체의 선박 운항 패턴을 모델링한 후, 이상 운항을 식별하는 연구가 진행되기도 하였다(Oh and Kim, 2018).

한편, 학습 데이터의 확률 모델을 추정하고, 이를 통해 이상 운항 상태를 식별하는 방법이 제안되기도 했다(Laxhammar et al., 2009; Smith et al., 2014). 이 방법은 대상 해역을 일정 간격의 격자로 분할하고, 각 격자에 포함되는 항적 데이터의 확률 분포를 GMM 혹은 KDE 알고리즘을 이용하여 추정한 후, 새로 입력되는 데이터와의 비교를 통해 이상 운항 여부를 결정한다. Laxhammar et al.(2009)는 출발지와 목적지, 선종 등의 선박 운항 특성을 반영하지 않고 균등하게 분할된 격자를 사용했기 때문에 식별 성능이 낮아질 수도 있다고 언급하였다.

이 밖에도 선박의 항적을 운동학(kinematics) 알고리즘을 이용하여 분석하고, 이를 통해 선박의 이상 운항을 탐지하는 방법이 제안되기도 하였다(Guo et al., 2021).

앞서 언급한 바와 같이, 선박의 운항 상황은 매우 다양하고 복잡하기 때문에 이상 운항 식별을 위한 모델을 단일 모델로 생성하는 경우, 학습이 어렵거나 식별 성능이 저하되는 문제가 발생하게 된다. 또한, 각각의 모델은 식별 가능한 이상 운항의 유형이 미리 정해져 있으며, 정의되지 않은 유형의 이상 운항은 탐지되지 않기도 한다.

본 논문에서는 이러한 문제점을 해결하기 위해 관제 구역을 운항하는 선박의 교통 특성을 반영한 교통 네트워크를 생성하고, 이를 기반으로 하는 이상 운항 식별 방법을 제안한다.

3. 이상 운항 식별

3.1 개요

본 논문에서는 관제 구역에서 정상적으로 운항하지 않아 관제가 필요한 선박을 이상 운항 선박으로 정의한다. 정상 상태는 과거 항적 데이터를 기준으로 자주 나타나는 운항 패턴을 의미하며, 이와는 반대로 거의 발생하지 않거나 낮은 확률로 관찰되는 운항 패턴을 이상 운항 상태로 정한다.

한편, 항내 영역은 터미널, 부두, 정박지 등의 부대시설을 사용하기 위한 선박들로 매우 복잡하고 다양한 형태의 교통 특성을 가지고 있다. 이에 원활한 항내 교통 관리를 위해 제한 속도, 안전 항로, 제한 구역 등을 포함하는 항만시설 운영 규정을 정하여 이를 준수하도록 하고 있다(Ministry of Ocean and Fisheries, 2023). 이와 같은 항내 운항 규정에 어긋나는 운항 상황도 이상 상태로 정의할 수 있다.

Fig. 2는 항내에서 발생 가능한 선박의 이상 운항 상태의 예시를 나타내며, 그 특징에 따라 크게 3종류로 분류할 수 있다.

규칙 기반 이상 운항 상태는 과속과 제한 구역 진입 등 항내 운항 규정에 따라 식별이 가능한 이상 상태이다. 위치 기반 이상 운항 상태는 항로 이탈, 항로상 정지, 항로 횡단 등 해당 위치에서 자주 관찰되지 않는 이상 상태이며, 맥락 기반 이상 운항 상태는 전체적인 운항 경로상의 이상 상태이다.

규칙 기반 이상 운항 상태는 식별이 필요한 규정을 정량적인 규칙으로 모델을 생성할 수 있지만, 위치 및 맥락 기반 이상 운항 상태는 대상 해역을 분할하고, 분할된 영역의 정상 항적에 대한 모델링이 선행되어야 한다. 이때, 격자 형태로 해역을 분할하게 되면, 여러 패턴의 항적이 동시에 포함될 수 있으며, 이 경우 모델을 학습하기 어렵고 식별 성능이 저하되는 문제가 있다.

이에 본 논문에서는 항적 데이터를 이용하여 교통 네트워크를 구성한 후, 노드 정보를 기준으로 영역을 분할하였다. 이를 통해 각 영역은 서로 유사한 교통 특성을 가지도록 분할되며, 교통 맥락을 고려한 선박 운항 특성을 모델링할 수 있게 된다.

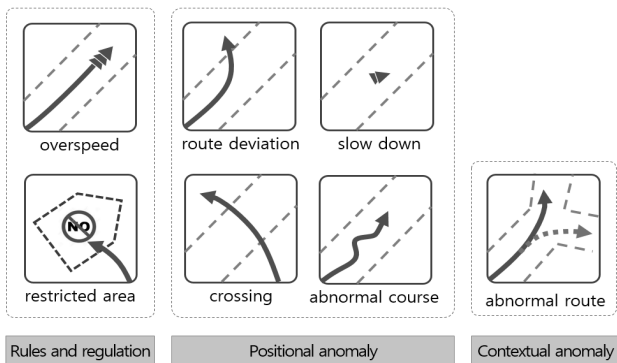


Fig. 2. Examples of navigational anomaly in harbour area.

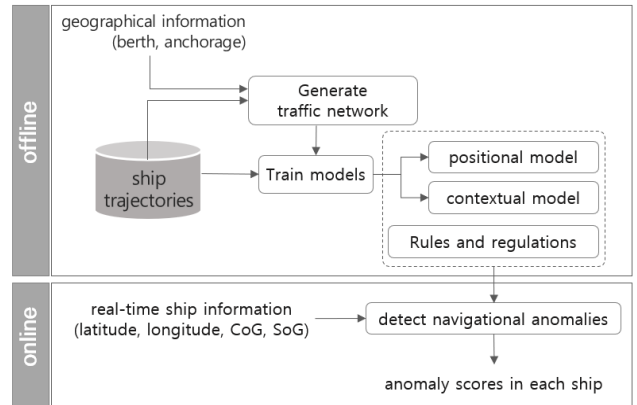


Fig. 3. Procedure of navigational anomaly detection.

Fig. 3은 이상 운항 식별 절차를 나타낸다. 오프라인 단계에서 대용량의 항적 데이터와 항만의 지리 정보를 이용하여 교통 네트워크를 생성한 후, 위치 및 맥락 기반 모델을 사전에 학습한다. 온라인 단계에서는 학습된 운항 특성 모델과 실시간으로 입력되는 선박 정보를 비교하여 각 선박에 대한 이상 운항 상태를 식별한다.

3.2 교통 네트워크 생성

선박 운항 특성을 모델링하기 위한 선행 절차로 교통 네트워크를 생성한다. 교통 네트워크는 노드와 방향성 에지로 구성된 그래프 네트워크이며, 출발지, 목적지, 운항 경로, 운항 빈도 등의 선박 교통 특성을 정량적으로 표현할 수 있는 특징이 있다(Oh and Kim, 2020). 교통 네트워크 생성은 총 6 단계로 구성되며, 각 단계별 세부 내용은 다음과 같다.

STEP 1 항적 데이터 추출

데이터베이스로부터 탐색 영역, 시간 범위 등을 입력 조건으로 항적 데이터를 추출한다. 항적 데이터는 RADAR와 AIS의 통합 물표이며, 각 데이터는 물표 생성 일시, 위도, 경도, 속도, 침로, 물표 ID 정보를 포함한다.

STEP 2 항적 단순화

추출된 항적 데이터를 물표 ID 별로 분류한 후, 항적 단순화 단계를 거친다. 이를 통해 연속된 점 형태로 수신된 항적 데이터 중 침로가 변경되는 변침점(waypoint) 정보를 추출할 수 있으며, 이를 통해 선박의 운항 특성을 파악할 수 있다. 본 논문에서는 항적 단순화를 위해 Ramer-Douglas-Peucker(RDP) 알고리즘을 적용하였다(Ramer, 1972).

STEP 3 항적 군집화

항적 단순화 단계를 거친 항적 데이터는 군집화 단계를 거쳐 교통 네트워크의 노드 후보군을 생성한다. 본 논문에서

서는 군집화를 위해 밀도 기반 군집화 알고리즘인 DBSCAN (Density-Based Spatial Clustering of Applications with Noise)을 사용하였다(Ester et al., 1996).

STEP 4 네트워크 노드 생성

군집화 단계를 통해 생성된 노드 후보군과 부두, 정박지, 출입점 등 항만의 지리 정보를 추가하여 최종적으로 네트워크 노드를 결정한다. 이때 위치가 중복되는 노드 포인트를 삭제하거나, 유사한 위치의 노드를 병합하는 등 네트워크 노드 최적화가 수행된다.

STEP 5 영역 분할

생성된 네트워크 노드를 기준으로 보로노이 다이어그램(voronoi diagram) 알고리즘을 적용하여 대상 해역을 분할한다.

STEP 6 네트워크 에지 생성

선박별로 구분된 항적 데이터를 시간 순서로 정렬한 후, 분할된 네트워크 노드 영역에 할당하여 노드 영역 시퀀스로 변환한다. 이렇게 변환된 노드 영역 시퀀스는 노드 영역 간 이동 정보를 의미하며, 이를 이용하여 네트워크 노드를 연결하고, 출발 및 도착 노드 정보인 네트워크 에지 정보를 생성한다.

3.3 위치 기반 운항 특성 모델

위치 기반 운항 특성 모델링은 분할된 영역에서 선박이 어떤 경로와 속도, 침로를 가지고 이동하는지에 대한 확률 모델을 생성하는 작업이다. 항적 데이터를 영역별로 분류한 후, 커널 밀도 추정 방법(KDE, Kernel Density Estimation)을 이용하여 확률 분포를 추정한다.

KDE는 커널 함수의 조합을 이용하여 전체 확률 모델을 추정하는 방법이며, 복잡한 데이터에 대한 연속적인 확률 밀도 함수를 얻을 수 있는 장점이 있다. 본 논문에서는 가우시안(gaussian) 커널 함수를 사용하였으며, 항적 데이터는 위도, 경도, 침로, 속도를 최소-최대 정규화를 수행한 후 모델을 추정하였다.

한편, 선박의 운항 특성은 시간대에 따라 서로 다른 특징을 가지고 있기 때문에, 시간대 별(1시간 단위)로 구분하여 운항 특성 모델을 생성한다. 즉, 교통 네트워크의 노드 수를 T_N 으로 가정하면, $T_N \times 24$ 개의 위치 기반 모델이 오프라인 단계에서 미리 생성된다.

온라인 단계에서는 실시간으로 입력되는 선박 정보와 학습된 위치 기반 모델을 비교하여 이상치(anomaly score)를 계산한다. 이상치는 학습된 모델의 정상적인 밀도 범위에 있다고 판단되는 확률을 의미하며, 값이 작을수록 모델과는 다른 데이터 즉, 이상 상태임을 의미한다. 식(1)은 위치 기반 모델의 이상치 계산식이다.

$$pScore_i = 1 - \frac{sim_{R(i),h}}{max\{sim_{R(T_j),h}\}} \quad (1)$$

$i = \{latitude, longitude, CoG, SoG\}$

$h = hour$

$T_j = j^{th} \text{ positional data of trajectory}$

$R(i) = \text{region index of } i$

$sim_{R(i),h} = \text{similarity score of KDE model } R(i) \text{ at time } h$

3.4 맥락 기반 운항 특성 모델

항만 영역은 주요 항로를 포함하여 선박이 주로 다니는 운항 경로가 존재하며, 맥락 기반 운항 특성 모델은 이러한 운항 경로에 대한 확률 모델이다. Fig. 4와 같이 교통 네트워크를 기반으로 대상 해역을 분할하고, 선박의 이동 항적은 분할된 영역의 연속적인 집합인 영역 시퀀스 형태로 표현될 수 있다. 이러한 영역 시퀀스 변환 과정을 대용량의 항적 데이터에 적용한 후, 각 영역의 천이(regional transition) 확률을 계산하여 모델을 학습하게 된다. 학습된 모델은 영역 간 이동 확률 정보를 포함하고 있으며, 이를 이용하여 상대적으로 낮은 빈도를 가진 운항 경로를 식별할 수 있게 된다. 한편, 항만을 정기적으로 운항하는 선박의 운항 경로는 거의 유사하기 때문에, 이를 선박별로 맥락 모델을 생성하여 이상 운항 식별에 적용하였다. 식(2)은 맥락 기반 모델의 이상치 계산식이다.

$$cScore_i = 1 - \frac{1}{N} \sum p_{R(i-1), R(i)} \quad (2)$$

$i = \{latitude, longitude, CoG, SoG\}$

$R(i) = \text{region index of } i$

$p_{R(i-1), R(i)} = \text{probability of transfer from } R(i-1) \text{ to } R(i)$

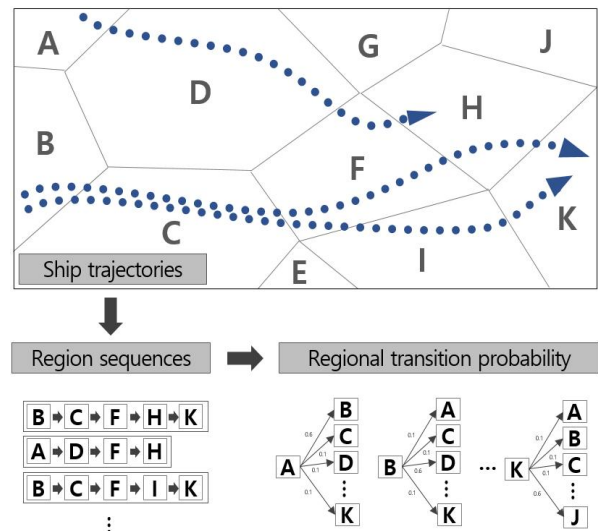


Fig. 4. Concept of contextual model generation.

3.5 규칙 기반 모델

항내 운항 규정에는 선박 교통의 안전과 질서 유지를 목적으로 안전 항로, 운항 속도 제한, 운항 제한 구역 등을 정하여 이를 준수하도록 하고 있다(Ministry of Ocean and Fisheries, 2023). 이러한 항내 운항 규칙을 어기는 선박은 이상 운항 선박으로 판단할 수 있으며, 이는 정규화 된 규칙 형태로 표현이 가능하다. 규칙 기반 모델의 이상치는 식(3)과 같이 각 규칙의 이상치를 합산하여 계산될 수 있다.

$$rScore_i = \sum_N w_n \cdot score_i^{r_n} \quad (3)$$

$i = \{latitude, longitude, CoG, SoG\}$

$N = \text{number of rules}$

$score_i^{r_n} = \text{anomaly score of } n^{th} \text{ rule}$

$w = \text{weight of rule score}$

3.6 이상 운항 식별

본 논문에서 이상 운항은 선박의 운항 특성 모델인 위치 기반 모델과 맥락 기반 모델, 그리고 규칙 기반 모델의 이상치 계산 결과를 모두 통합하여 식별된다. 규칙 기반 모델의 식별 결과를 높은 우선순위로 처리하며, 각 모델의 이상치가 중첩으로 통합 이상치가 계산된다. 식(4)은 이상 운항 식별 모델의 통합 이상치 계산식이며, 계산된 통합 이상치가 특정 임계치보다 크면 이상 운항 상태로 식별된다.

$$tScore_i = \begin{cases} rScore_i, & \text{if } rScore_i > \text{threshold} \\ w_1 \cdot pScore_i + w_2 \cdot cScore_i, & \text{otherwise.} \end{cases} \quad (4)$$

$i = \{latitude, longitude, CoG, SoG\}$

$w_1, w_2 = \text{weights of anomaly score}$

해양경찰청은 해상교통의 관제 업무를 관찰, 정보제공, 조인 및 권고, 지시의 단계로 정의하고 있으며(Korea Coast Guard, 2019), 본 논문에서는 이를 반영하여 정상(normal), 주의(caution), 경고(warning)의 3단계로 통합 이상치를 구분하였다.

한편, 이상치의 각 단계별 임계치 설정은 모델의 성능을 결정하는 중요한 작업이며, 대상 해역에서의 관제 특징을 반영해야 한다. 본 논문에서는 주의 단계와 경고 단계에서 이루어진 실제 관제 교신 사례들을 참고하여 실제와 최대한 유사하게 식별되도록 주의 단계의 경계치를 0.6으로 설정하였으며, 경고 단계의 임계치는 그 중 상위 50%를 포함하도록 설정하였다. Fig. 5는 통합 이상치의 단계 구분을 나타낸다.




Fig. 5. Degree of navigational anomaly.

4. 실험 결과 및 고찰

4.1 실험 개요

본 논문에서 제안된 이상 운항 식별 방법을 검증하고자 실험역 데이터를 적용한 실험을 수행하고 그 결과를 분석하였다.

실험 대상 항만인 대산항은 국내 주요 무역항 중 한 곳으로 근처 해역에는 인천항, 평택항, 대산항을 이용하는 선박들이 입항 대기 장소로 이용하는 ‘장안서 대기 정박지’가 운영되고 있어서 복잡한 선박 교통 특성을 가지고 있다. 본 논문에서는 Fig. 6과 같이 대산항 관제 구역과 장안서 관제 구역을 포함하는 해역에서 식별 실험을 수행하였다.

실험에 사용된 항적 데이터는 관제 빅데이터 체계(BEAD)로부터 추출되었다. BEAD는 AIS, RADAR, VHF 등 해상교통 관제센터에서 수집되는 관제 데이터를 실시간으로 수집하고 분석할 수 있는 빅데이터 체계이며, 현재 대산항 해상교통관제센터에 설치되어 시범 운영 중이다. 본 실험에서 사용된 데이터는 약 6개월 동안(2022년 1월부터 2022년 6월까지) 수집된 AIS 및 RADAR 통합 물표 데이터이며, 이를 통해 생성된 교통 네트워크는 Fig. 6과 같다. 네트워크는 총 137개의 노드와 186개의 에지로 구성되며, 에지의 방향과 두께는 각각 노드 간 선박 교통의 방향과 빈도를 나타낸다.

식별 실험은 구현된 이상 운항 식별 모델에 실시간 수집된 데이터를 적용하여 수행하였으며, 실험 대상은 대상 해역에서 2노트 이상으로 운항 중인 선박으로 한정하였다. 선속의 기준은 항적 데이터로부터 임의로 추출된 정박 중이거나 접안 중인 선박의 속도 데이터를 분석하여 결정하였다.

한편, 실험에서 식별된 이상 운항 사례를 통해 모듈의 동작을 확인하였으며, 전문가 집단의 평가를 통해 그 결과를 검증하였다.




Fig. 6. Experimental area and traffic network of DAESAN Port.

4.2 실험 결과 및 분석

실험에서는 항만 영역에서 발생할 수 있는 다양한 이상 운항 패턴들이 식별되었으며, 식별된 주요 이상 운항의 사례는 Fig. 8과 같다.

Fig. 8의 (a)는 정박 중이던 선박이 접안을 위해 이동하는 중 항로를 인지하지 못하고 잘못된 경로로 운항하는 이상 운항 상황이다. 실제로 관제사는 경로 이상을 판단한 시점에 VHF 교신을 통해 해당 선박에게 이상 경로를 확인하였으며, 항해사에게 주의 운항을 당부했다. 자동식별의 결과도 유사한 시점에 경고 상태로 분류되어 정상적으로 이상 운항이 식별됨을 확인할 수 있었다.

Fig. 8의 (b)는 경로 이상을 탐지한 사례이다. 해당 선박은 정기적으로 대산항을 운항하는 선박이며, 매 항차마다 유사한 경로로 운항한다. 그러나 식별 시점에서 운항 중인 경로는 이전 경로와는 차이가 있어서 이상 운항 선박으로 식별된 사례이다.

Fig. 8의 (c)는 항로상에서 이상 운항 패턴을 보이는 상황이다. 해당 선박은 항로상에서 반복적인 이동 패턴으로 운항하는 이상 운항 식별 사례이며, 이는 조업 중인 어선으로 추정된다.

Fig. 8의 (d)는 항로 이탈 사례이며, 해당 선박이 항로를 벗어 나기 전에 이상 상황에 대한 경고가 발생하였고, (e)와 (f)에서와 같은 항로 횡단도 상황도 미리 식별할 수 있음을 확인하였다.

이처럼 이상 운항을 구체적으로 분류하거나 미리 정의하지 않았음에도 불구하고 대상 해역의 선박 운항 특성과의 비교를 통해 이상 운항 선박을 자동으로 식별할 수 있었다.

그러나 이상 운항으로 식별된 사례들 중 관제사에 따라서는 이상 운항이라고 판단하지 않는 경우가 있을 수 있으며, 그 반대의 경우도 존재한다. 이는 이상 운항 선박의 식별이 관제사의 경험과 주관에 의해 판단되기 때문이며, 이로 인해 관제 결과에 개인차가 발생하기도 한다. 또한, 이상 운항은 대상 선박의 상황만을 고려하여 결정되는 것이 아니라, 교통 상황에 대한 복합적인 판단이 필요하기 때문에 테스트 데이터를 이용한 실험으로는 식별 성능을 검증하기 어렵다.

따라서, 본 실험에서는 실험 기간(3일) 동안 전문가 집단이 식별 결과를 모니터링 한 후, 각 이상 상황에 대한 전반적인 평가를 수행하여 모듈의 성능을 검증하였다.

실험에 참여한 전문가 집단은 현재 대상 해역(대산항 VTS)에서의 관제 경험이 있는 20명의 현직 관제사로 구성되어 있다. 평가에서는 주요 이상 운항 유형에 대한 식별 결과의 정확성을 조사하였으며, 이상 운항 유형은 항로 횡단, 과속, 정기 선박의 이상 경로, 항로 이탈, 기타 이상 운항으로 분류하였다. Fig. 7은 평가 결과를 도식화한 결과이다.

평가 결과, 과속 및 항로 횡단 상황의 식별은 70% 이상의 응답자가 긍정적인 응답을 보였으며, 정기 선박의 이상 경로 상황과 항로 이탈 상황에 대한 식별은 60% 이상의 응답자가




Fig. 7. Evaluation of anomaly detection results.

긍정적으로 평가하였다. 반면, 기타 이상 운항 상황의 식별 결과는 절반 이상의 응답자가 부정적인 의견을 제출하였다.

상대적으로 낮은 평가를 받은 정기 선박의 경로 이상 식별은 주로 장안서 해역에서 이상 운항으로 식별되는 경우가 많았다. 장안서 해역을 통과하는 선박은 주로 인천항이나 평택항 등으로 이동하는 선박이며, 이 경우 정기 선박이라고 하더라도 운항 경로나 목적지가 일정하지 않은 특징이 있어서 경로 이상 선박으로 식별되는 오류가 발생한 것으로 판단된다. 이러한 상황은 선박의 운항 경로 정보만으로는 식별되기 어려우며, 항만 및 부두의 상황 등을 복합적으로 고려하여 판단되어야 할 것이다.

또한, 기타 이상 상황으로 분류된 선박 대다수가 어선이었으며, 조업 활동으로 인한 운항 패턴이 이상 상황으로 식별되어 정확도가 낮게 평가된 것으로 파악되었다. 응답자에 따라 관제 대상이 아닌 어선은 식별 대상에서 제외해야 한다는 의견도 있었지만, 항로상의 조업 활동 및 항로 횡단 상황이 관제 대상 선박의 운항에 영향을 줄 수 있기 때문에 식별 대상에 포함되어야 한다는 의견도 있었다. 이에, 식별 대상 해역을 제한하거나 선종에 따라 선택적으로 식별 결과를 출력하는 기능이 추가되어야 할 것으로 판단된다.

한편, 구현된 식별 모듈은 모든 운항 중인 선박을 대상으로 하기 때문에 교통량에 따라 처리 시간이 달라지며, 최대 교통량인 약 200척의 선박이 운항하는 상황에서도 400ms 이내의 처리 속도를 보였다. BEAD로부터 수신되는 선박의 위치 정보가 1초 주기로 갱신되기 때문에 이상 운항 식별 프로세스 또한 1초 이내에 수행되어야 하며, 이러한 점을 고려할 때 식별 모듈의 처리 성능은 현장 적용에 무리가 없을 것으로 판단된다. Table 1은 실험에 사용된 시스템의 주요 사양이다.

Table 1. Specification of server system

Item	Specification
CPU	Intel Xeon Silver 4210 * 2
RAM	256GB
OS	Ubuntu Linux 18.04

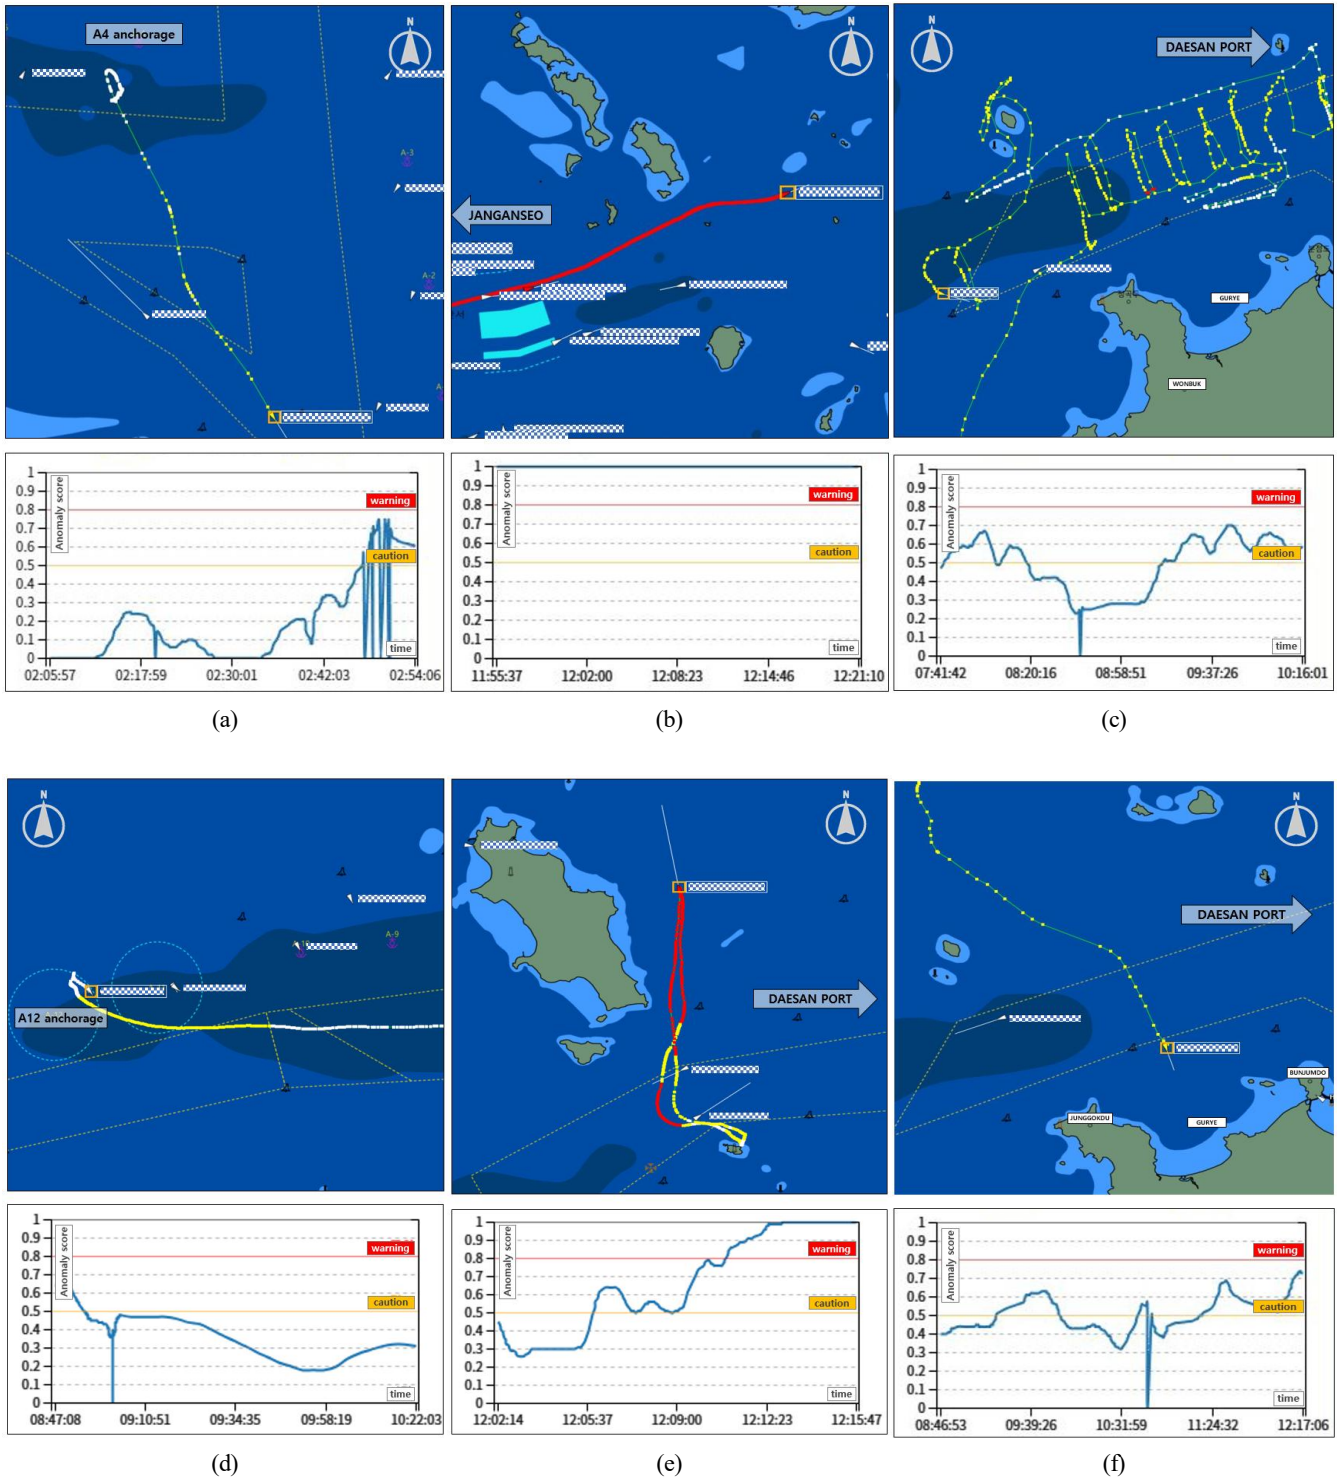


Fig. 8. Examples of anomaly detection result in DAESAN harbour, (a) abnormal course and crossing, (b) abnormal route, (c) abnormal course, (d) route deviation, (e) crossing and abnormal course, (f) crossing.

5. 결론

본 논문에서는 교통 네트워크를 기반으로 하는 이상 운항 선박 식별 모델을 제안하였다. 제안하는 모델은 항적 데이터를 이용하여 대상 해역에 최적화된 식별 모델을 구축하고 학습할 수 있으며, 식별을 위한 지도 학습 과정 대신 대용량 데이터를 이용한 비지도 학습 방법으로 정상 상태를 학습하여 이상 운항 상황을 미리 분류하거나 정의하지 않아도 식별이 가능한 특징이 있다. 구현된 식별 모델은 대산항 VTS의 실해역 데이터를 적용하여 실험을 수행하였으며, 실험을 통해 항내에서 발생할 수 있는 다양한 이상 운항 상황이 자동으로 식별됨을 확인하였다. 식별된 결과는 전문가 집단의 평가를 통해 검증하였으며, 이를 통해 식별 대상 선박의 범위, 식별 결과의 표시 방법 등 현장 적용을 위한 다양한 요구 사항들을 도출할 수 있었다. 한편, 식별 결과와 실제 관제 결과와의 격차를 줄이기 위해서는 관제 특성 및 항만의 교통 특성을 고려한 식별 모델의 조정 작업이 필요하며, 반복적인 조정 작업을 통해 대상 해역에 최적화 되어야 할 것으로 판단된다. 일반적으로 인공지능 모델의 성능을 객관적으로 검증하기 위해서는 표준화된 테스트 데이터 세트가 사용된다. 이에 해상교통관제 분야에서도 성능을 검증할 수 있는 테스트 데이터 세트가 구축되어 연구에 활용될 수 있어야 하며, 이와 함께 관제 분야의 특성을 고려한 검증 체계가 마련되어야 할 것으로 사료된다.

끝으로 본 연구가 해상교통 관제 분야에 인공지능 기법을 적용하는 연구의 기반이 되기를 바라며, 보다 안전하고 효율적인 해상교통 환경의 구축에 기여할 수 있기를 기대한다.

후 기

본 논문은 해양경찰청의 “해상교통정보 빅데이터 구축 및 안전예보 시스템 기술 개발” 과제의 지원을 받아 수행되었습니다(해양경찰청 20190496 (IRIS RS-2019-KS191295)).

References

- [1] Ester, M., H. P. Kriegel, J. Sander, and X. Xu(1996), A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise, In Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining, pp. 226-231.
- [2] Moreno, F. C., J. R. Gonzalez, J. S. Muro, and J. A. G. Maza (2022), Relationship between human factors and a safe performance of vessel traffic service operators: A systematic qualitative-based review in maritime safety, *Safety Science*, Vol. 155, 105892.
- [3] Guo, S., J. Mou, L. Chen, and P. Chen(2021), An Anomaly Detection Method for AIS Trajectory Based on Kinematic Interpolation, *Journal of Marine Science and Engineering*, 609.
- [4] Korea Coast Guard(2023), <http://www.kcg.go.kr/kgc/vts>.
- [5] Korea Coast Guard(2019), Vessel Traffic Services Act, Article 18.
- [6] Laxhammar, R., G. Falkman, and E. Sviestins(2009), Anomaly detection in sea traffic-A comparison of the gaussian mixture model and the kernel density estimator, 12th international conference on information fusion, pp. 756-763.
- [7] Lee, J. S., J. H. Kim, and E. K. Jang(2016), Analysis of VTS Operators' Situational Awareness Based on In-Field Observation and Subjective Rating Methods, *Journal of Korean Navigation and Port Research*, Vol. 40 No. 6, pp. 375-384.
- [8] Ministry of Government Legislation(2023), Act on the investigation of and inquiry into marine accidents.
- [9] Ministry of Ocean and Fisheries(2023), Act on the arrival and departure of ships.
- [10] Oh, J. Y. and H. J. Kim(2018), Detection of Ship Movement Anomaly using AIS Data: A Study, *Journal of Korean Navigation and Port Research*, Vol. 42, No. 4, pp. 277-282.
- [11] Oh, J. Y. and H. J. Kim(2020), Spatiotemporal Analysis of Vessel Trajectory Data using Network Analysis, *Journal of the Korean Society of Marine Environment & Safety Research Paper*, Vol. 26, No. 7, pp. 759-766.
- [12] Ramer, U.(1972), An iterative procedure for the polygonal approximation of plane curves, *Computer Graphics and Image Processing*, Vol. 1, No. 3, pp. 244-256.
- [13] Smith, J., I. Nouretdinov, R. Craddock, C. Offer, and Gammerman(2014), A Anomaly Detection of Trajectories with Kernel Density Estimation by Conformal Prediction, In *Artificial Intelligence Applications and Innovations* pp. 271-280.
- [14] Wang, X., X. Liu, B. Liu, E. N. de Souza, and S. Matwin (2014), Vessel route anomaly detection with Hadoop MapReduce, *Proceedings of the IEEE International Conference on Big Data*, Washington, DC, USA, pp. 25-30.
- [15] Zhen, R., Y. Jin, Q. Hu, Z. Shao, and N. Nikitakos(2017), Maritime Anomaly Detection within Coastal Waters Based on Vessel Trajectory Clustering and Naïve Bayes Classifier, *Journal of Navigation* Vol. 70, No. 3 pp. 648-670.

Received : 2023. 10. 17.

Revised : 2023. 11. 06.

Accepted : 2023. 12. 29.