

베이지안 네트워크를 활용한 군 장교 진급예측 모델 연구

장용진^{1*}, 정대현²

¹국방대학교 국방관리학과, ²공군본부 인사참모부

Military Officer Promotion Prediction Model Using Bayesian Network

Yongjin Jang^{1*}, Daehyun Jung²

¹Graduate School of National Defense Management, Korea National Defense University

²Republic of Korea Air Force Headquarters, Personnel Staff

요약 본 연구는 베이지안 네트워크에 기반하여, 진급 예측 모델을 제시한다. 조직에서 진급은 인사관리에 핵심적인 역할을 수행한다. 조직에서 원하는 인재를 선발하기 위해 다양한 방식의 평가방법을 사용하여 진급자를 선발하고 있다. 군에서 원하는 인재상에 부합하는 인원을 선발하기 위해서 여러 요소에 대한 공정한 평가 시행만큼이나, 각 요소가 실제 진급심사 결과에 반영이 되는가를 확인하는 것 또한 중요한일이다. 진급 선발 시 요소들의 중요도 반영을 위해 요소별로 선발 점수 배정에 차등을 두는 방법이 일반적으로 활용되고 있다. 하지만, 실제 진급 선발 대상자들의 각 평가항목의 분별력이 떨어진다면 해당 요소가 진급에 영향을 미칠 영향은 확연히 줄어들 수밖에 없다. 본 연구에서는 나이브 베이즈(Naive Bayes) 모델을 활용하여, 실제로 어떠한 항목이 강한 영향력을 갖는지 확인하였다. 또한, 현재는 평판 점수가 참고자료를 사용되고 있는데, 평판이 진급 평가항목으로써도 충분한 가치가 있다는 것을 발견하였다. 본 연구를 통하여 실제 진급에 큰 영향을 미치는 요소를 파악할 수 있으며 이를 통하여 승진 관련 정책 수립 시 중요 참고 사항으로 활용될 수 있을 것으로 기대된다.

Abstract This paper proposes a promotion prediction model based on Bayesian networks. Promotion within an organization plays a crucial role in human resource management, as it helps select the desired talents. Various evaluation methods are used to select candidates for promotion. Ensuring a fair evaluation of multiple factors to select individuals who align with the desired talent profile is as crucial as verifying whether each factor is reflected in the actual promotion assessment results. A differential scoring allocation is commonly used to reflect the importance of factors in promotion selection. On the other hand, the impact of those factors on promotion diminishes significantly if the discrimination ability of each evaluation score for promotion candidates is low. This study used the Naive Bayes model to identify factors with significant influence. Moreover, the reputation scores, presently used as reference materials, carry sufficient value as criteria for promotion evaluation. Through this research, it becomes possible to discover the factors genuinely impacting promotions, offering valuable insights for formulating promotion-related policies.

Keywords : Military Officer, Promotion, Human Resource, Bayesian Network, Machine Learning

*Corresponding Author : Yongjin Jang(Korea National Defense Univ.)

email: knowhere53@naver.com

Received February 28, 2024

Accepted May 3, 2024

Revised April 3, 2024

Published May 31, 2024

1. 서론

인사관리에 있어 진급은 인적자원의 기본적인 평가 수단이다. 특히 군 조직은 상하 계급이 뚜렷한 조직으로 진급이 갖는 의미는 일반적인 조직보다 더 크다고 볼 수 있다[1]. 군 조직은 그동안 진급 체계 개편을 통하여 조직에서 중요하게 생각하는 가치를 존중하고, 요구되는 능력을 갖춘 인재를 진급시키기 위해 노력해 왔다. 일례로 군에서는 매년 체력검정을 통하여 장병들의 체력수준을 평가하고 있으며, 진급평가 항목으로 배정되어 있다. 이는 일반적인 조직에서는 없는 특수한 경우라고 할 수 있다. 체력을 평가하는 이유는 군 임무 수행을 위하여 요구되는 충분한 신체적인 능력을 갖춘 사람을 군인으로서 바람직한 인재상으로 보기 때문이라고 할 수 있다.

다양한 평가항목에 대한 중요도를 반영하기 위해 활용되는 기본적인 방법은 진급심사에 평가 요소에 대한 점수의 비율을 조절하는 것이다. 하지만, 평가방법에 따라 변별력이 떨어지는 항목은 점수의 비중이 높다고 하더라도 실질적인 당락을 결정짓지 못하는 경우가 발생한다. 따라서 본 연구에서는 실질적인 영향성을 분석하기 위해, 공군의 실제 진급 데이터를 활용하여 진급예측을 할 수 있는 모델을 베이지안 네트워크 방법론을 활용하고자 한다.

진급은 인사관리 분야에 한 분야로 연구되어 왔으며, 최병순, 문영세(2006)의 연구에서는 육군 장교의 인사관리제도에 대한 개선점을 제시하면서, 직업군인에 진급관리 제도 개선 방향을 다루고 있다[1]. 구용희(2014)는 군 인사관리가 외부환경에 따라 변화하였으며, 조직에서의 형평성보다 효용성을 중시하는 방향으로 발전해 왔다고 보았다[2]. 진급이 조직에 미치는 영향이 크고, 고 계급자의 진급은 조직의 최고 경영자의 관심 사항이기도 한 만큼 진급 제도에 관한 관심을 꾸준히 지속해왔다고 말할 수 있다. 하지만 지금까지 연구는 문헌연구 등을 바탕으로 개선 방향을 제시하는 연구들이 대부분을 이루고 있으며, 정량적인 접근을 한 연구는 찾기 쉽지 않았다. 최근 AI를 활용한 인재 선발 및 평가가 주목을 받고 있는데, AI 분석의 기초는 데이터에 기반한 판단인 만큼 진급 관련해서 한 연구에서는 정량적인 접근이 필요한 시점이다. 따라서 본 연구에서 접근한 나이브 베이즈 모델 등의 통계적 학습을 통한 연구들이 필요한 시기라고 할 수 있다.

2. 데이터 및 모델링

2.1 공군 장교 진급 데이터

본 연구의 연구대상인 진급 모델 연구를 위하여 공군 장교의 진급 데이터를 활용하였다. 수집 기간은 2019년부터 2023년 사이이며, 중령 진급 대상자 2,013명의 진급 평가 결과를 사용하였다.

공군 장교 진급 평가항목은 표 1과 같이 근무 평정, 보직 점수, 상점과 훈장, 교육, 추천 점수, 처벌 점수, 보안 처벌 점수, 체력검정, 핵심역량 평가 점수로 구성된다. 각 항목과 평가결과(합격은 1, 불합격은 0)에 대한 기술통계는 Table 1과 같으며, 표 하단의 평판 점수는 심사관의 참고사항으로 제공되는 점수로 평가점수에 반영되지 않는다.

Table 1. Descriptive Statistics of Variables

Variable	Mean	SD	Min	Max
Work Performance	27.6	0.91	17.4	30
Position	9.86	0.55	0	10
Merit	4.76	0.83	0	5
Education	8.33	1.16	0	10
Recommendation	19.33	0.89	0	20
Punishment	-0.07	0.50	-7	0
Security Score	-0.003	0.04	-1	0
Physical Fitness	4.63	0.22	3.8	5
Capability 1	3.05	1.10	1	5
Capability 2	3.02	1.11	1	5
Capability 3	3.02	1.11	1	5
Selection Status	0.43	0.49	0 (Fail)	1 (Pass)
Reputation of Superior*	16.47	2.89	6.19	25
Reputation of Peer*	14.78	2.24	10.35	24.36
Reputation of Subordinate*	16.51	2.58	1.75	25

*Reputation is excluded from evaluation score

평가항목 배점은 근무 평정, 추천 점수, 핵심역량 점수가 높는데, 배점이 큰 항목의 Box plot을 그려보면, Fig. 1과 같다. 근무 평정과 추천이 배점이 크지만, 변화의 폭은 핵심역량 평가가 더 크게 나타나, 핵심역량이 타 항목 보다 미치는 영향이 더 클 가능성이 높다.

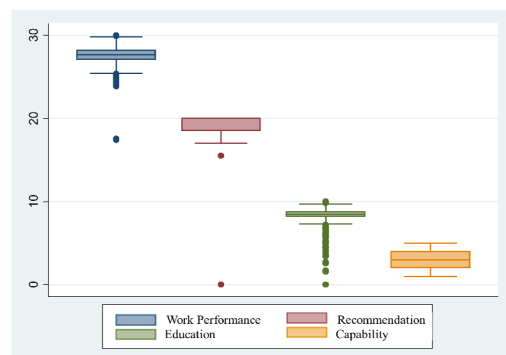


Fig. 1. Boxplot of Key Variables

2.2 베이지안 네트워크 모델 개요

본 연구의 대상인 진급 평가 요소들의 중요도 분석을 위해 활용할 수 있는 모델 중 널리 사용되는 형태는 선형 모델이다. 독립변수가 다수인 다중 선형회귀 모델에서 종속변수의 비선형성이 증가하면 오차가 커지는 문제가 있어, 최근 기계학습을 통해 오차를 줄이는 노력이 지속되고 있다. 그 중 신경망(neural network), 가우시안 프로세스(Gaussian process) 등이 기계학습에 널리 활용되는 것으로 알려져 있다[3]. 베이지안 네트워크는 토마스 베이즈(Thomas Bayes)가 제안한 베이즈 정리를 기반으로 한 것으로 데이터가 충분하지 않을 경우 유용하기 활용될 수 있는 모델이다[4].




Fig. 2. Example of Bayesian network model

Fig. 2는 베이지안 네트워크의 예시이다. 그림과 같이 베이지안 네트워크는 노드(Node)와 엣지(Edge)로 구성된 방향성 비순환 그래프(Directed Acyclic Graph, DAG) 모델이다. 여기서 타원은 노드(Node)를 나타내고, 화살표는 엣지(Edge)를 의미한다. 각 노드는 확률변수로 엣지로 연결되는 경우 연관성을 가지며, 연결되지 않은 노드들은 서로 조건부 독립이다. 아래 그림을 보면 화살표가 X노드에서 Z노드로 향하는 것으로 볼 수 있는데 여기서 X는 Z의 부모 노드이고, Z는 X의 자식 노드라고 한다. 즉, 부모 노드는 다른 노드에 영향을 미치는 노드를 의미하며, 자식 노드는 부모 노드로부터 영향을 받는 노드를 의미한다.

베이지안 네트워크는 이러한 노드와 엣지를 활용하여 특정 노드에 대한 조건부 확률을 구할 수 있다. 노드들을 조건부 독립이 될 수 있도록 원인과 결과를 연결시키고 인과관계에 따라 베이지안 네트워크를 구성하면 조건부 독립 가정에 적합한 네트워크가 형성되는데, 이를 통해 특정 노드에 대한 조건부 확률을 계산할 수 있다.




Fig. 3. Example of Markov Blanket model

Fig. 3은 다양한 요소들을 반영하여 베이지안 네트워크를 구성한 예시이다. Fig. 3처럼 복잡한 베이지안 네트워크 구조를 분석하기 위해서는 마코프 블랭킷(Markov Blanket)과 조건부 확률의 연쇄법칙(Chain Rule for Conditional Probability) 등에 대한 추가적인 이해가 필요하다. 마코프 블랭킷은 특정 노드의 확률 계산시 해당 노드에 직접적 영향을 미치는 노드들의 집합을 의미하는데, 마코프 블랭킷은 부모 노드, 자식 노드 및 자식 노드의 또 다른 부모 노드들을 포함하며 V자 연결 구조(V-structure)를 보인다. 마코프 블랭킷은 복잡한 확률적 의존성을 단순화하는데 중요한 역할을 하며 부모, 자식 노드 및 자식 노드의 다른 부모 노드 사이에서 노드 간 독립, 종속 등 영향성 관계를 명확히 하고 불필요한 부분을 제거하여 추론 및 확률 계산을 용이하게 할 수 있다[5].

조건부 확률의 연쇄법칙을 통해 복잡한 확률 구조를 간단한 조건부 확률의 곱으로 분해할 수 있다. 연쇄법칙을 활용하면 확률 계산을 단순화하고 확률적인 추론을 쉽게 만들 수 있다. 또한, 네트워크 전체의 구조를 이해하기 쉽다는 장점이 있다. 이러한 조건부 확률의 연쇄법칙은 Eq. (1)과 같이 나타낼 수 있다.

$$P(x_1, x_2, \dots, x_n) = P(x_1)P(x_2 | x_1)P(x_3 | x_1, x_2) \dots P(x_n | x_1, x_2, \dots, x_{n-1}) \quad (1)$$

조건부 독립이라는 가정하에 베이즈 정리, 연쇄법칙과 곱셈규칙을 적용하면 Eq. (2)와 같이 단순화 할 수 있다 [6].

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{parent}(x_i)) \quad (2)$$

2.3 진급 예측 모델

베이지안 네트워크를 통하여 진급 모형을 설정하는 본 연구에서는 나이브 베이즈(Naive Bayes) 모델을 사용하였다. 진급 평가가 각각의 항목이 직접 평가 점수에 독립적으로 반영되므로, 나이브 베이즈 모델이 가장 현실을 잘 반영한 모델이라고 할 수 있다.




Fig. 4. Basic Model

Fig. 4는 각 항목의 배점에 따라 평가하는 방식을 나이브 베이즈 모델로 구성한 것이다. 노드 Z는 진급결과를 의미하고 노드 D부터 Q까지는 진급에 고려되는 주요 평가항목을 나타낸다.

Fig. 4에서 각각의 엣지가 평가결과에서 각 평가항목으로 이어지므로, 진급결과가 각 평가항목에 영향을 미치는 모델이다. 직관적인 방향성과 반대라고 생각할 수 있지만 각 항목은 평가 결과에 센서 역할을 하기 때문에 Fig. 4와 같이 구성하였다. 즉, 각 평가항목이 주어질 때 진급결과 노드에서 진급 추천 또는 비추천의 확률을 알 수 있도록 고안한 것이다.

노드 Z는 부모노드가 없으므로 간단히 연속 혹은 이산적인 확률분포로 표현된다. 일반적으로 이산적인 확률 분포가 선호되므로 연속변수의 이산화 과정을 추가하였다. 각각의 항목을 구성하는 노드는 조건부확률분포(Conditional Probability Distribution)를 갖고, 분포의 크기는 부모 노드의 상태의 수(m)와 자식 노드 상태의 수(n) 곱(m×n)이 된다.




Fig. 5. Reputation Added Model

본 연구에서는 기본 모델에서, 평판 변수를 추가한 모델을 Fig. 5와 같이 제시하였다.

현재 평판 점수는 평가점수에 반영되지 않는다. 평가 항목에 반영된 근무 평정과 평판을 비교하면, 근무평정

이 직속상관의 평가만을 대변하는 것에 반해, 평판은 다양한 참여자가 평가한 점수이므로 객관성이 더 높다고 할 수 있다. 즉, 평판 점수를 활용하였을 때 보다 정확하게 진급을 예측할 가능성이 높다고 할 수 있다. 따라서, 평판을 추가할 필요성을 검증하기위해 평판이 추가된 모델을 추가로 구성하였다. 평판은 상급자, 동기생, 하급자 평가로 구성되어있으며, Fig. 5에 마지막 부분에 주황색으로 표시된 부분이 평판을 측정하는 3개의 변수이다.

3. 결과 및 토의

3.1 민감도분석 결과

민감도는 지니(GeNIe) 프로그램의 영향력 강도(Strength of Influence) 기능을 사용하였다. 영향력 강도는 각각의 연결된 선의 굵기로 표현된다. 영향력 강도는 노드의 조건부 확률 분포가 최종 상태에서부터 받는 영향력 나타내는 것으로, 영향력의 강도는 각 평가 항목들의 조건부 확률 분포 간의 거리를 기준으로 계산된다[7].

본 모델의 민감도분석 결과는 Fig. 6과 같다. 굵기가 굵을수록 영향력성 강도가 강하다는 것을 의미한다. 해당 결과는 지니의 분석 중 EM(Expectation Maximization) 알고리즘을 사용한 결과이다.




Fig. 6. Results of Sensitivity Analysis

그림에서 굵게 표시된 항목은, 특기, 진급 년도, 임관 년도, 근무평정, 상점, 추천 점수, 평판(상.하) 점수이다. 해당 항목이 진급에 큰 영향을 미치는 것으로 나타났다.

먼저 특기를 살펴보면, 진급 대상자와 선발자의 비율이 특기별로 달라지는데, 선발자의 비율이 높은 특기의 경우 다른 특기보다 진급률이 크게 높아지는 경향이 있다. 두 번째, 진급년도와 임관년도 또한 영향성이 있는 것으로 나타났다. 세 번째, 추천 점수는 소속부대의 추천 점수로 영향성이 큰 것으로 나타났다. 네 번째, 상급자 하급자의 평판 또한 진급 예측도를 높이는데 기여도가 큰 것으로 나타났다. 이러한 항목이 진급 예측률에 영향이 크다.

주목할 부분은, 평판이 현재 평가에 활용되지 않은 항목에도 예측도를 크게 높이는데 기여한다는 점이다. 따라서, 평판이 잠재적인 평가 항목으로 가치가 높다고 판단할 수 있는 근거로 볼 수 있다.

3.2 교정 및 타당성분석

민감도 분석에 활용된 EM 알고리즘은 각 평가항목 노드의 사전분포는 각 상태별로 동일한 확률을 갖는 다항 분포(Polynomial Distribution)로 가정하고, 실제 데이터의 예측치를 활용하여 각각의 확률을 업데이트하는 과정을 거친다.




Fig. 7. Calibrated CPT for Z=1 promotion)

Fig. 7은 진급자로 예측된 경우(Z=1)인 경우 주요 항목 중 일부의 분포를 나타낸 것이다. 진급한 사람의 각 항목 분포가 3~5점 사이에 나타난 것으로 볼 때, 점수가 높은 사람이 진급할 가능성이 높게 나타난 것을 볼 수 있으므로, 본 예측 모델의 타당성이 있는 것으로 확인되었다.

Table 2. Comparison of Prediction Accuracy

Basic model		Predicted	
		True	False
Actual	True	207	104
	False	79	242
Reputation Added Model		Predicted	
		True	False
Actual	True	248	63
	False	59	262

K-fold Cross Validation을 사용하여 모델의 타당성을 분석하였다. Table 2는 진급확률이 0.5 이상이면 진급했다고 판단할 경우 평판을 포함한 모델과 그렇지 않은 모델의 정확도를 비교한 결과이다.

평판을 제외한 모델의 정확도는 0.796(503/632)이고, 평판을 추가한 결과는 0.807(510/632)이 나와 평판을 추가하였을 때 정확도가 더 상승한 것을 알 수 있다.

평판을 추가한 모델과 추가하지 않은 모델에 대한 정확도 차이를 더욱 자세히 확인하기 위하여 ROC 곡선(Receiver Operating Characteristic Curve)을 확인하였다.

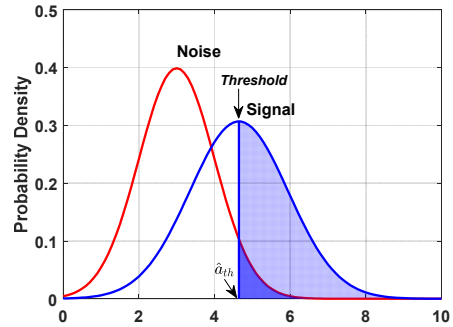


Fig. 8. Concept of ROC Curve

ROC 곡선은 성공과 실패의 판정(Threshold) 유의수준에 따른 정확도를 보여주는 그래프로, Fig. 8은 ROC 곡선의 개념을 나타낸다. 시스템이 연속적인 출력 값을 갖을 때, 신호와 잡음을 제대로 구분하는 하거나 그렇지 않은 경우는 총 4가지로 구분된다. 참인 경우는 신호가 판정치를 넘을 때 신호로 판정하거나, 판정치 미만의 잡음을 잡음으로 판정하는 경우이다. 오류인 경우는 판정치를 넘지 못하는 잡음을 신호로 잘못 판정하는 경우와 판정치를 넘는 신호를 잡음으로 잘못 판정하는 경우이다. 4개의 비율은 판정치를 어떻게 설정하느냐에 따라 달라진다.

Fig. 8에서 보듯이 오류를 줄이기 위해 판정치를 높이면 신호를 탐지할 확률이 감소한다. 반면 문턱치를 낮추면 오류의 확률이 증가한다. 특히, 거짓을 참으로 판정하는 경우를 1종 오류(False Positive)라고 하는데, 1종 오류는 분류기(Classifier)의 신뢰성을 크게 떨어뜨린다.

Fig. 9는 두 모델의 1종 오류에 대한 민감도 분석 결과이다. 파란선은 평판을 포함한 모델이며, 붉은선은 평판을 포함하지 않은 현행 모델이다. 모든 상황에서 파란선의 민감도가 높은 것을 확인할 수 있다. 이는 평판을 포함한 모델이 정확도가 더 높다는 것을 나타내므로, 평판을 포함한 모델이 현행 모델보다 우월하다고 말할 수 있다.




Fig. 9. Comparison of ROC curves with and without nodes representing reputation

3.3 토의

본 연구는 장교 진급 데이터를 기반으로 중요한 평가 요소와, 평판을 추가한 모델을 제시하였다. 연구 결과에서 확인할 수 있는 것은 첫 번째, 현재 진급심사의 배점은 근무평정이 가장 높지만, 실질적으로 평가에 가장 큰 영향을 미치는 요소는 심사위원의 평가이며, 그 밖에 특 기구분 또한 큰 영향력을 갖는다.

두 번째는, 현재 참고사항으로만 활용되는 평판점수가 평가항목으로 포함될 경우 진급예측 정확도가 상승한다는 점으로 미루어 볼 때, 다양한 인원이 평가한 평판점수를 평가항목으로 활용하는 것이 진급 심사에 긍정적인 영향을 줄 수 있다고 할 수 있다. 단, 주의해야 하는 점은 동급자 평가는 같은 진급 경쟁자가 포함될 수 있어 오히려 신뢰도를 떨어뜨릴 수 있으므로, 상/하급자의 평판만 활용하는 것이 적절하다고 할 수 있다.

4. 결론

본 연구는 장교 진급 실제 데이터를 활용하여, 베이저안 네트워크 분석 방법으로 평가항목에 대한 중요도를 분석하였다. 평가항목에 대한 중요도를 연구한 결과 개인의 평가 점수 중에는 근무평정, 추천 점수, 상점, 평판이 진급에 중요한 요인으로 분석되었다. 점수 배점이 상대적으로 낮은 상점이 진급에 중요한 요인으로 나타나, 현재 진급 항목의 배점과 실제 진급에 영향을 주는 요인이 상이한 점이 있다는 것을 확인할 수 있다.

또한, 현행 방식에서 평판 점수가 심사위원의 참고사항으로만 사용되는데, 평판을 평가항목으로 사용하는 것

이 진급 예측도를 높이는 것으로 나타나, 평판이 진급 평가항목으로 가치가 있다는 점을 발견하였다.

따라서, 추후 장교 진급심사 시 평판을 평가항목에 포함하는 방안을 제시하고자 한다. 평판 점수는 다양한 참여자가 평가한 항목으로 상급자의 평가에만 의존하는 근무평정보다 객관성이 높다고 할 수 있다. 다만, 결과에서 보듯이 잠재적 경쟁자가 평가하는 동급자 평가는 객관성 유지가 어렵기 때문에 제외하고, 상/하급자의 평판 점수를 평가 항목에 포함시키는 것이 바람직하다.

본 연구의 한계점으로 진급 평가 점수만을 연구 대상으로 하였기 때문에 점수화 되지 못한 외부요인에 대한 영향성은 확인하지 못하였다는 한계가 있다.

앞으로 인사도 AI가 추천하는 시기가 다가오고 있다. AI 시스템을 도입하더라도 충분한 데이터와 정확도 높은 학습모델이 적용되어야 AI가 신뢰성있는 결과값을 내놓을 수 있다.

본 연구는 그동안 정성적인 연구가 주를 이루었던 진급연구를 정량적으로 접근했다는 점에서 의의가 있다고 할 수 있다. 연구결과에서 중요도가 높은 요소와 배점이 높은 요소가 일치하지 않는다는 결과가 나왔으므로, 배점에 대한 비중변화나, 평가방법 개선에 본 연구 결과를 활용할 수 있을 것이다. 또한, 평판점수를 평가 항목에 포함시켜 우수한 인재를 선발하는 진급심사의 신뢰성을 높이는 것이 필요하다.

References

- [1] B. S. Choi & Y. S. Moon. "Policy Alternatives Analysis on Army Officer Personnel Management System", Korean policy sciences review, Vol.10, No.1, pp.51-78, 2006.
- [2] Y. H. Koo. *A study on the Transition of Personnel Management System of ROK Armed Forces*, Doctoral dissertation, Mokwon University, Korea, 2014.
- [3] Rasmussen, C. E. and Williams, C. K. I. *Gaussian Processes for Machine Learning*, The MIT Press, Cambridge, MA, 2007.
DOI: <https://doi.org/10.1007/s00163-010-0086-1>
- [4] Aeri Kim, & Dooyoul Lee "Bayesian Network Based Situational Awareness and Course of Action Decision-Making Support Model", Journal of the Military Operations Research Society of Korea (MORS-K), Vol.48, No.1, pp.131-141, 2022.
- [5] D. Margaritis. *Learning Bayesian Network Model Structure from Data*, Doctoral dissertation, School of Computer Science, Carnegie Mellon University, Pittsburgh, PA, USA, 2003.

- [6] Sucar, L. E., Bielza, C., Morales, E. F., Hernandez-Leal, P., Zaragoza, J. H., & Larranaga, P., "Multi-label classification with Bayesian network-based chain classifiers", Pattern Recognition Letters, Vol.41, pp.14-22, 2014. DOI: <https://doi.org/10.1016/i.patrec.2013.11.007>
- [7] Bayesfusion, LLC. GiNIE Modeler Programmer's Manual, 2023, Available From <https://support.bayesfusion.com/docs/GeNIE> (accessed Feb. 14, 2024)

장 용 진(Yongjin Jang)

[정회원]



- 2015년 2월 : 아주대학교 일반대학원 NCW학과 (공학석사)
- 2022년 2월 : 고려대학교 일반대학원 경영학과 (경영학박사)
- 2022년 1월 ~ 2022년 9월 : 국방대 국가안보문제연구소 연구원
- 2022년 9월 ~ 현재 : 국방대학교 국방관리학과 교수

<관심분야>

경영전략, 방위산업

정 대 현(Daehyeon Jeong)

[정회원]



- 2024년 3월 ~ 현재 : 고려사이버대학교 융합정보대학원 석사 중
- 2022년 12월 ~ 현재 : 공군본부 인사참모부

<관심분야>

인력관리, 경영전략