토지주택연구
Land and Housing Review
pISSN: 2093-8829, eISSN: 2234-1765
Land and Housing Review 2025, 16(4):147-162 | https://doi.org/10.5804/LHR.2025.16.4.147

공동구의 확률적 성능등급 예측을 위한 베이지안 네트워크 모델*

A Bayesian Network Model for Probabilistic Performance Grade Prediction of Utility Tunnels

오원준** · 조중연*** · 이용준****
Wonjoon Oh** · Choongyeun Cho*** · Youngjun Lee****

Abstract

This study proposes a performance prediction model based on a Bayesian network to more precisely predict the comprehensive performance grade of the utility tunnel, thereby supporting maintenance decision-making. The current comprehensive performance grade system is limited to a one-time evaluation based on the weighted average score at the time of inspection, making it challenging to estimate performance deterioration over time or reflect causal relationships between complex factors. To address this, this study selected six key variables, including facility configuration, facility aging, structural defect index, accident history, climate impact index, and management cycle adequacy, with the causal relationships between variables structured into a DAG format. From 2015 to 2024, 121 comprehensive performance evaluation datasets from 39 utility tunnels were collected and preprocessed, divided into learning (96 cases) and verification (25 cases), and a Conditional Probability Table (CPT) was created. The model was trained using a data-driven learning algorithm, and the verification results showed high prediction performance with an accuracy of 0.880, a Macro F1 of 0.871, and a Weighted F1 of 0.902. The prediction for grades was quite accurate, with the misclassification cases limited to adjacent grades (i.e., only neighboring grade categories, such as A↔B or B↔C, were confused). Currently, utility tunnels are graded B or higher, and data for grades C through E is insufficient, limiting verification of predictive power for mid- and lower grades. This study extended the quantitative evaluation results into a probabilistic model to enhance the applicability of utility tunnel performance assessment. Future research should focus on ensuring balanced data distribution and expanding the model application to other types of infrastructure, such as bridges, tunnels, and dams, thereby strengthening its generalizability and reliability.

Keywords: Utility Tunnel, Comprehensive Performance Grade, Bayesian Network, F1 Score, Confusion Matrix

1. 서 론

1.1 연구의 배경

도시 기반시설은 공공의 안전과 일상생활의 연속성을 확보하기 위한 핵심 요소이며, 이 중 공동구는 전력, 통신, 열 수송, 수도 등의 다양한 기반시설을 한 구조물 내에 수용하는 복합 시설로서, 도시기능 유지에 필수적인 역할을 수행하고 있다. 특히 도심지

*본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었음(과제번호 RS-2023-00245334).
**유니콘스(주) 부장(주저자: wonjoon_oh@hanmail.net)
***유니콘스(주) 대표이사
****한국토지주택공사 토지주택연구원 연구원(교신저자: yjlee@lh.or.kr)
Received: August 19, 2025 / Revised: September 23, 2025 / Accepted: November 6, 2025

내 지중화된 공동구는 지반 내 설치 특성상 사고 발생 시 대규모 피해로 이어질 가능성이 높아, 이에 대한 지속적이고 정량적인 성능평가와 유지관리가 요구된다(오원준 외, 2019, 2020; 국토교통부, 2017). 공동구가 중요한 복합시설임에도 불구하고 교량, 터널 등 다른 인프라에에 비해 베이지안 네트워크를 활용한 성능등급 예측 연구는 거의 이루어지지 않았으며, 이러한 연구 공백을 보완하기 위해 본 연구를 수행하였다.

국내에서는 2018년 「시설물의 안전 및 유지관리 관련 특별법」의 개정 이후, 공동구에 대한 정기적인 성능평가가 의무화되었으며, 이에 따라 구조적 안전성뿐 아니라 설비, 환경, 운영 측면에 대한 종합적 평가가 시행되고 있다. 「시설물의 안전 및 유지관리에 관한 특별법」 제21조 및 같은 법 시행령 제17조에 따라 제정한 「시설물의 안전 및 유지관리 실시 등에 관한 지침」의 시행하고 있으며, 점검/진단 결과에 따라 종합평가 및 안전등급(이하 '종합성능등급')을 산정한다(국토안전관리원, 2021; 국토교통부, 2018).

1.2 연구의 필요성

현재의 종합성능등급은 항목별 점수의 가중평균에 기반한 일회성 진단 결과로, 시간의 흐름에 따른 성능저하 예측이나, 향후 유지보수 시기의 결정, 예산 배분과 같은 실질적 의사결정 과정에 활용하기에는 한계가 존재한다. 또한 복합적 원인(예: 기후, 사고 이력 등)에 의해 성능이 변동되는 공동구의 특성을 반영하지 못하고 있다. 이에 따라, 성능평가 결과를 다양한 변수 간 인과관계와 불확실성을 반영한 통계 기반 모델로 확장할 필요성이 제기된다. 이러한 한계를 극복하기 위해, 최근 시설물 평가 분야에서는 확률기반 인과 모델의 적용이 주목받고 있으며, 그중 하나인 베이지안 네트워크(Bayesian Network)는 조건부 확률 기반의 인과 모델로서, 유지관리 계획 수립에 효과적으로 활용될 수 있다.

1.3 연구 목적

본 연구는 공동구의 종합성능등급 평가에 있어, 기존 점수 누적 방식의 한계를 극복하고자 베이지안 네트워크 기반 모델을 적용하였다. 종합성능등급외에 수용시설 구성, 설비 노후도 등 주요 인자를 변수로 설정하여 공동구의 성능저하 확률을 정량적으로 추정할 수 있는 베이지안 네트워크 모델을 개발하였다. 또한, 다양한 상태 변수 간의 인과적 연관성과 불확실성(확률적 추론)을 정량적으로 반영함으로써, 신뢰성 있는 종합성능등급 예측체계를 구축하는 것을 목적으로 연구를 진행하였다.

2. 이론적 배경

2.1 공동구 현황 및 종합성능등급 제도

2.1.1 공동구 현황

현재 공동구는 39개소(총연장 170.7㎞)가 운영중이며, 제2종 시설물로 관리되고 있다. 국내 공동구는 전국 주요 도시와 산업 거점을 중심으로 설치·운영되고 있으며, 지역별 규모와 수용시설 구성에 차이가 있다(국토안전관리원, 2025).

2.1.2 종합성능등급의 개요

종합성능평가는 공동구의 주요 구성요소에 대한 상태와 기능을 평가하여, 통합적인 종합성능등급을 산정하는 제도로, 평가 항목은 구조, 설비, 환경, 운영 등으로 구분된다(국토교통부, 2018). 종합성능등급은 A(우수), B(양호), C(보통), D(불량), E(위험)의 5등급으로 산정되며, 세부 항목의 가중치 합산 및 기준 점수 구간에 따라 분류된다(Table 1).

현재 공동구의 약 36%는 30년 이상으로 노후화되었으며, A등급 74%, B등급 26%로 관리되고 있는 것으로 조사되었다(Table 1).

Table 1. Comprehensive Performance Grade by Years of Use (As of December 31, 2024, Unit: Number of Locations)

Division	Less than 10 Years	Between 10 and 20 Years	Between 20 and 30 Years	More than 30 Years	Total
Total	10 (25.6%)	8 (20.5%)	7 (17.9%)	14 (35.9%)	39 (100%)
Grade A	10 (34.5%)	8 (27.6%)	7 (24.1%)	4 (13.8%)	29 (100%)
Grade B	0	0	0	10 (100.0%)	10 (100%)
Grade C	0	0	0	0	0
Grade D	0	0	0	0	0
Grade E	0	0	0	0	0

2.1.3 한계점 및 활용 제약

현행 종합성능평가 결과는 정량적 점수 기반이기는 하나, 결과 활용의 정형화 부족, 일회성 평가(점검 주기: 1년~6년), 복합 변수에 대한 인과관계 미반영의 한계점을 가지고 있다. 따라서 이러한 평가결과를 통계적 모델과 연계하여 성능저하 예측 및 유지관리 판단의 기반자료로 활용하는 연구가 요구된다.

2.2 베이지안 네트워크 이론

2.2.1 개요 및 정의

베이지안 네트워크는 확률적 인과관계를 방향성 비순환 그래프(Directed Acyclic Graph, DAG) 형태로 나타내는 확률기반 그래픽 모델이다. DAG는 변수(노드)와 변수 간 인과적 종속관계(간선)를 체계적으로 표현하여, 복잡한 시스템에서 발생하는 조건부 확률 관계를 시각적으로 구조화할 수 있다. DAG는 단순 점수 합산 방식과 달리, 변수 간 직·간접 인과관계를 조건부 확률 형태로 분석할 수 있다는 장점을 가진다. 본 연구에서는 DAG를 활용하여 공동구 성능평가를 정적인 점수 산정에서 동적인 확률추론 체계로 확장하고자 한다. 베이지안 네트워크(Bayesian Network, BN)를 구성하는 요소는 노드, 간선, 조건부 확률 테이블(Conditional Probability Table, CPT)로 구분할 수 있다(Table 2; Needham et al., 2007).

2.2.2 베이지안 정리

베이지안 네트워크는 베이즈 정리를 기반으로 확률 추론을 수행한다.

$$P(H|E)=\frac{P(E|H)\cdot P(H)}{P(E)} \quad (1)$$

여기서, H는 가설 (예: 성능저하 발생 여부), E는 증거

Table 2. Components of the Bayesian Network

Components	Details
Node	• Also commonly referred to as a variable or random variable • A unit representing status in a network (e.g., "Equipment age = good")
Edge	• Generally referred to as a directed arc or arc, it represents a conditional dependency • It defines a causal or probabilistic dependency between parent and child nodes
CPT	• More formally expressed as a Conditional Probability Distribution (CPD) • A table that organizes the probabilities of child nodes based on the state of their parent nodes

(예: 균열, 침수, 감시설비 고장 등), P(H | E)는 증거 E가 주어졌을 때의 H의 사후확률을 의미한다. 베이지안 이론은 사전확률(prior information)을 관측된 증거와 결합하여 사후확률(posterior information)을 구체적으로 이해하기 위한 방법을 제공한다. 식 (1)은 단일 사건의 확률 추정에 그치지 않고 다변량의 인과관계로 확장되며, 네트워크 구조를 통해 복잡한 변수들 간의 연쇄적인 조건부 확률 추론을 가능하게 한다(Chan and Darwiche, 2012).

2.3 기존 문헌에 대한 고찰

2.3.1 인프라 분야의 적용 사례

최근 인프라 자산의 상태 추정과 유지관리 의사결정을 지원하기 위해 베이지안 네트워크를 적용한 다양한 연구가 수행되고 있다. 기반시설 분야에서는 구성요소 상태의 불확실성을 고려하여 검사 시점과 보수 시기를 계획하는 의사결정 모델이 제안되었으며(Zhang and Marsh, 2021), 복잡한 토목·구조물 시스템의 신뢰성 분석에 BN을 활용하고, 대규모 인프라 시스템을 베이지안 네트워크로 모델링할 때 발생하는 계산 복잡성을 줄이기 위해, 데이터 업데이트인 순차적 학습과 압축 기법인 변수 축소 및 구조 단순화를 적용하여 확장성을 확보하는 방안을 제시하였다(강재영·김종진, 2024; 김태원·이정형, 2025; Tien, 2014).

교량 분야에서는 동적 베이지안 네트워크(DBN)를 이용하여 생애주기비용(LCC)의 불확실성을 모델링하고 예측하는 연구가 이루어졌으며(Vagdatli et al., 2024), FTA(Fault Tree Analysis)를 대체하는 새로운 절차로서 신념 네트워크(Belief Network)를 활용한 손상 모델링 방법이 제시되었다(Attoh-Okine and Bowers, 2006).

터널 분야에서는 중국 대련 지하철 해저터널을 대상으로 13개의 리스크 요인을 BN으로 통합하여 실시간 건강위험도를 예측하는 모델이 개발되었다. 건강위험도란 시설물의 구조적 건전성과 운영환경을 종합적으로 고려하여 안전사고나 기능마비 발생 가능성을 정량적으로 표현한 지표를 의미한다(Ni et al., 2024). 도로 분야에서는 지반 변위 모니터링을 위해 측면 인클리노미터 데이터를 수집하고, 이를 BN 기반 필터로 분석하여 이상 탐지 및 예측을 수행한 사례가 보고되었다(Green and Jaspan, 2023). 수자원 분야에서는 미국 내 흙댐을 대상으로 기계학습(ML) 알고리즘을 통해 자동 BN 모델을 생성하고, 이후 전문가 지식을 반영해 모델을 수정·보완하는 방법이 제안되었다(Tang et al., 2022).

2.3.2 선행연구 분석 및 본 연구의 차별성

현재 공동구에 대한 베이지안 모델 적용은 아직 활발히 연구되지 않고 있으며, 종합성능등급과 연계된 위험도 예측 모델은 부족한 실정이다. 국내·외에서는 공동구나 기반시설을 대상으로 한 종합성능등급 또는 유지관리 계획 수립 연구가 일부 진행된 바 있으나, 대부분이 수리적 열화 모델(예: Markov Chain, Weibull 분석 등)이나 전문가 점수 기반 다기준 의사결정(MCDM: Multi-Criteria Decision Making, 예: AHP, Fuzzy) 방식에 치우쳐 있다.

본 연구는 이러한 배경을 바탕으로, 공동구에 적합한 베이지안 네트워크 모델을 구성하였다. 종합성능평가 결과를 실질적 출력 변수로 활용한 정량 모델 시도하였으며, 변수(구조결함, 사고 이력 등) 간 인과관계를 반영하여 베이지안 네트워크의 조건부 확률 기반 추론을 활용하여 종합성능등급을 예측하는 모델을 제안하고자 한다. 또한, 정확도, 정밀도, 재현율, F1 Score 등의 성능지표를 기반으로 모델을 검증하고, 실무적 적용 가능성을 평가하고자 한다. 공동구에 대한 적용은 아직 초기 단계이며, 종합성능등급과 같은 체계적인 입력 변수와 연결한 사례는 본 연구의 필요성과 차별성이라고 할 수 있다.

Table 3. Research Methodology and Procedures

Order	Item	Details
First	Variable Selection	• Variable review using existing literature: Classification of variables and categories through literature review • Final variable selection: Definition of roles, variables, and state values
Second	Constructing a DAG	• Creating a directed relationship graph between variables • Designing a Bayesian network model: Defining and designing a relationship structure diagram between variables
Third	Data Collection	• Data collection for model analysis (literature review, etc.)
Fourth	Data Classification	• Training data vs Validation data
Fifth	Analysis	• Model training: Training is performed based on actual data.
Sixth	CPT Construction	• Define the probability distribution for each node • Create a conditional probability table (CPT)
Seventh	Model Validation	• Model Validation: Evaluating prediction accuracy using validation data • Methods: Accuracy, Precision, Recall, F1-score, etc.

3. 연구 방법론

3.1 연구 방법 및 절차

본 연구는 공동구의 종합성능평가 결과 데이터를 기반으로 베이지안 네트워크 모델 도출 후 검증하고자 하며, 이를 위해 아래와 같이 연구 절차를 수행하였다(Table 3). 모델에 사용할 변수 선정 후 DAG 작성을 수행하며, 모델 수립을 위한 자료 수집 후 학습/검증 데이터로 분류한다. 그리고, 학습 데이터를 활용하여 CPT 작성 후 검증을 수행하여 모델의 정확도를 평가하도록 하였다.

3.2 변수 도출 및 분류

변수 선정을 위해 국토교통부 “시설물의 안전 및 유지관리에 관한 특별법” 시행지침(국가법령정보센터, 2025), 국토안전관리원(2021)의 기반시설 관리체계 연구보고서, 국내외 공동구 및 기반시설 관련 논문(Zhang and Marsh, 2021; Tien, 2014)을 참고하였다. 또한, 베이지안 네트워크 설계 시 변수 간 중복성 및 관련성을 확인하였으며, 데이터 확보 가능성, 측정 용이성, 인과 구조상 중요도를 기준으로 최종 변수를 선정하였다. 마지막으로, 변수 역할, 세부내용, 상태 값에 대하여 정의하였다(Fig. 1).

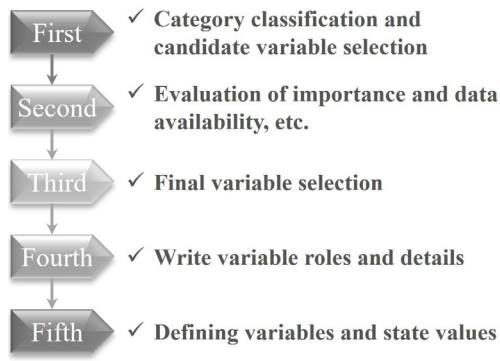

Fig. 1. Process for Deriving Variables

공동구의 성능에 영향을 미치는 변수는 기 수행된 연구, 문헌 고찰 등을 기반으로 공동구의 안전성과 성능에 영향을 미치는 요인을 크게 5개 카테고리로 분류하였다. 이 분류는 시설 구성의 복잡성, 설비 노후화, 구조 안전성, 운영 관리 체계, 외부 환경 요인으로 공동구의 리스크 요인을 포괄적으로 반영할 수 있도록 구성하였다. 5개 카테고리에서 총 20여 개

Table 4. Classification of Categories and Review of Candidate Variables

Category	Candidate Variables	Final Variable
Facility Composition	• Number and complexity of reception facilities (power, communications, gas, water pipes, etc.) • Stability of the collaboration system between reception facilities • Level of separation between facilities • Whether pipelines are redundant	• Facility Composition
Equipment Condition and Aging	• Equipment aging (installation age, residual lifespan) • Reliability of drainage, ventilation, and fire prevention equipment • Power supply redundancy and availability of emergency power • Adequacy of electrical grounding and insulation	• Equipment Aging
Structural Safety	• Frequency of structural cracking and settlement • Rebar corrosion rate and cladding damage • Seismic performance level • Frequency of defect grades (C and D) determined as a result of inspection	• Structural Defect Index
Operation & Management Level	• Compliance with regular inspection cycles and records • Management personnel and skill levels • Emergency maintenance response system and recovery times • Complaint handling rates and up-to-date safety management manuals	• Accident History • Management Cycle Appropriateness
External Environmental and Disaster Impacts	• Increased rainfall and snowfall due to climate change • Potential for groundwater inflow and changes in water level • History of damage from external disasters (earthquakes, floods) • Corrosiveness of surrounding soil and risk of ground subsidence	• Climate Impact Index

의 후보 변수를 발굴하였으며, 데이터 확보 가능성, 변수 간 상관성 및 중요도를 평가하여 최종적으로 6개의 주요 변수를 선정하였다(Table 4).

모델의 결과변수는 종합성능등급이며, 종합성능등급은 이들 입력 변수의 조건부 확률 조합을 통해 베이지안 네트워크 기반으로 도출된다. 본 연구에서는 공동구의 종합성능등급을 예측하기 위해 총 7개 변수(입력 6개, 결과 1개)를 고려한 베이지안 네트워크 모델을 구성하였다(Table 5). 입력 변수로는 수용시설 구성, 설비 노후도, 구조결함지수, 사고이력, 기후영향지수, 관리주기 적정성을 설정하였으며, 이들 변수의 조건부 조합을 기반으로 종합성능등급을 확률적으로 도출하였다. 이 중 종합성능등급은 출력/목표 노드(변수)이며, 나머지는 입력 노드(변수)(input variable)로서 상호 간 조건부 의존관계를 가진다.

6개의 입력 변수를 기반으로 종합성능등급을 예측하기 위한 베이지안 네트워크를 구성하였으며, 각 입력 변수(노드)의 상태는 2~3단계로 분류된다. 이에 따라 전체 CPT는 6개 입력변수의 상태(2×2×3×3×3×2) 조합에 따라 총 216개 경우로 구성된다. 이는 각 변수의 다양한 상태 조합을 반영하여, 단일 조건이 아닌 대규모 시나리오 기반의 성능등급 추론이 가능함을 의미한다. 입력 노드는 공동구의 설비 노후도, 사고이력 등으로 구성되며, 이들 간의 조건부 관계를 통해 최종 종합성능등급을 예측하게 된다(Table 6).

Table 5. Variable Roles and Descriptions

Variable Name	Type	Details
Facility Composition	Input Variable	• The combination of power, communications, heat transport, water supply, and other facilities within a utility tunnel. Increased complexity places additional burdens on facilities and structures. • The complexity and management difficulty vary depending on the type of infrastructure included within the utility tunnel.
Equipment Aging	Input Variable	• The age of mechanical equipment, including ventilation, lighting, drainage, and instrumentation. This is indirectly affected by the configuration of the facility. • The age and condition of equipment, such as power, communications, and heat transport.
Structural Defect Index	Input Variable	• Physical condition of major structures in the utility tunnel • Reflects structural defects such as cracks, leaks, and deterioration
Accident History	Input Variable	• Frequency of past accidents. The older the equipment, the greater the likelihood of failure. • Number of past accidents, such as fires, flooding, and short circuits.
Climate Impact Index	Input Variable	• Vulnerability to external climate risks • Regional climate conditions (rainfall, flood risk, etc.) that affect structural integrity and the probability of defects.
Management Cycle Appropriateness	Input Variable	• Whether inspections and maintenance are performed regularly. This affects the structural and equipment maintenance status. • Inspection frequency: Number of regular inspections, frequency of maintenance activities.
Comprehensive Performance Grade	Output Variable	• Decision based on the comprehensive evaluation results inferred by the Bayesian model based on the combination of the six variables mentioned above. • Final evaluation results are graded A to E.

Table 6. Definitions of Variables and State Values

Variable Name	Type	Number of states	State Type	Details
Facility Composition	Input Node	2	More than three, No more than three	Types of facilities within the utility tunnel
Equipment Aging	Input Node	2	Aged, Good	Ventilation, lighting , and control equipment status
Structural Defect Index	Input Node	3	Low, Medium, High	Inner walls, cracks, and water leaks, etc.
Accident History	Input Node	3	None, One time, Two or more times	Fire, flooding, and malfunctioning detection devices, etc.
Climate Impact Index	Input Node	3	Low, Medium, High	Possibility of rainwater inflow, history of flooding
Management Cycle Appropriateness	Input Node	2	Inadequate, Adequate	Completion of legal inspection cycles
Comprehensive Performance Grade	Output Node (Target Node)	5	A, B, C, D, E (Predictor variable)	Comprehensive performance grade evaluation criteria

3.3 베이지안 네트워크 구조 설계

본 연구에서 사용된 베이지안 네트워크 구조는 6개의 입력 노드로부터 종합성능등급을 예측하는 단일 출력 구조를 가지며, 이는 DAG 형태로 표현할 수 있다(Zheng et al., 2018; Hyttinen et al., 2018). DAG는 CPT의 수치가 조정되더라도 변수 간 인과관계 구조가 동일한 이상 네트워크의 구조 자체는 변하지 않는다. 또한, 각 노드는 출력 노드인 종합성능등급과 조건부 확률 기반의 인과관계를 가지며, Fig. 2는 도출된 베이지안 네트워크의 구조를 나타

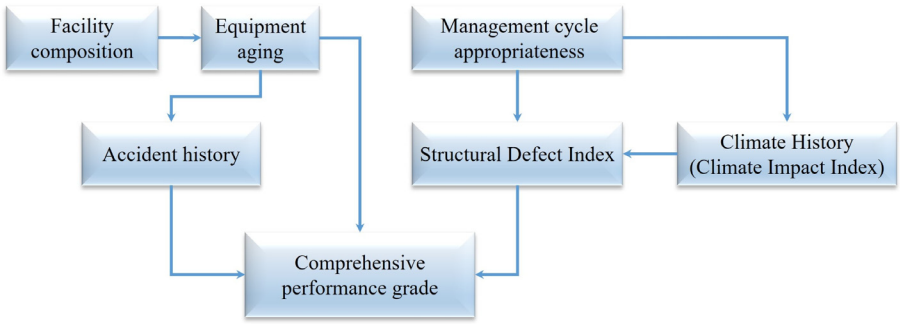

Fig. 2. DAG Structure for Predicting Comprehensive Performance Grades

Table 7. Relational Structure and Logical Connectivity

Direction of Links between Nodes	Logic
Facility Composition ⇒ Equipment Aging	High variety and density of utility facilities (e.g., power, district heating, telecommunications) increase operational load and maintenance complexity, thereby accelerating the aging of ventilation, monitoring, and other auxiliary systems
Equipment Aging ⇒ Accident History	Equipment aging increases failure rates, thereby elevating the probability of incidents such as fires, flooding, and instrumentation malfunctions
Accident History ⇒ Comprehensive Performance Grade	Accident history is a major direct factor contributing to the downgrade of the comprehensive performance grade, with consecutive incidents often resulting in a grade of D or lower
Structural Defect Index ⇒ Comprehensive Performance Grade	Structural defect index carries the highest weight within the structural category, and issues such as cracking or leakage are highly likely to result in a comprehensive performance grade of C or lower
Climate Impact Index ⇒ Structural Defect Index	Regions with high rainfall or elevated groundwater levels contribute to the structural defect index through factors such as wall infiltration, moisture accumulation, and deterioration of insulation performance
Management Cycle Appropriateness ⇒ Structural Defect Index, Management Cycle Appropriateness ⇒ Climate Impact Index	Failure to conduct regular inspection and maintenance prevents the early detection of structural damage, leading to its progression, while omission of drainage system inspections directly amplifies the climate impact index
Equipment Aging ⇒ Comprehensive Performance Grade	The equipment category is directly weighted in the comprehensive performance grade, with functional deterioration of ventilation, monitoring, and lighting systems typically resulting in below-average grades

낸다.

각 입력 변수는 공동구의 물리적 상태, 위험이력, 유지관리 체계 등을 반영하며, 이들 요소는 종합성능등급에 조건부 확률 형태로 영향을 미친다. 이 구조를 DAG 형태로 시각화(Fig. 2) 하였으며, 모든 인과관계는 입력 → 출력 방향의 단방향 흐름을 따른다. Table 7은 각 노드 간 연결 방향과 그 인과 논리적 근거에 대한 설명이다. 입력 노드가 출력 노드인 '종합성능등급'에 직간접 영향을 미치며, 설비 노후도는 사고이력에 영향을 주고, 관리주기 적정성은 구조결함 및 기후영향에 영향을 주는 구조이다. 공동구 종합성능평가에서 도출된 입력 변수들을 DAG 구조에 배치하여, 각 변수의 인과관계와 흐름을 종합성능등급 산정 과정에 반영하였다. 이를 통해 종합성능등급은 단순 가중합이 아니라 DAG에 기반한 조건부 확률 추론 과정을 거쳐 결정되도록 하였다.

3.4 모델 학습

3.4.1 학습 데이터 구성

학습 데이터는 기반시설 관련 시스템의 기본정보, 상세정보, 정밀안전점검/진단 보고서 등을 활용하여 전처리 과정을 수행하였다.

1) 자료 출처: 시설물통합정보관리시스템(2025), 점검진단평가관리시스템(2025), 기반시설관리시스템(2025), 국가건설기준센터(2025), 지자체 정보공개포털(2025) 등
2) 기간 및 범위: 2015~2024년, 총 39개 공동구,

Table 8. Model Development Data Set

Division	Facility Composition	Equipment Aging	Structural Defect Index	Accident History	Climate Impact Index	Management Cycle Appropriateness	Comprehensive Performance Grade
UT-T-01	More than Three	Good	High	None	Medium	Adequate	A
UT-T-02	More than Three	Good	High	Two or More Times	Medium	Adequate	B
UT-T-03	More than Three	Aged	Medium	Two or More Times	Low	Inadequate	B
UT-T-04	More than Three	Good	Low	Two or More Times	Medium	Adequate	A
UT-T-05	No More than Three	Aged	Low	Two or More Times	Medium	Adequate	A
		:				:	
UT-T-92	No More than Three	Good	Medium	None	High	Adequate	A
UT-T-93	No More than Three	Aged	High	One Time	High	Inadequate	B
UT-T-94	More than Three	Good	Low	Two or More Times	Low	Adequate	A
UT-T-95	More than Three	Aged	Low	One Time	Low	Adequate	A
UT-T-96	No More than Three	Good	High	None	Low	Inadequate	A

Note: UT: Utility Tunnel, T: Training

121건의 평가 사례

3) 전처리: 결측치 보정, 범주형 정규화, 상태 값 통일

본 연구에서는 총 121건의 데이터를 기반으로 베이지안 네트워크 모델 학습과 검증을 수행하기 위하여 전체 데이터를 학습:검증=0.8:0.2로 분할하여 연구를 수행하였다. 학습 데이터(96건)는 조건부 확률 기반 구조 학습에 사용되었으며(Table 8), 검증 데이터(25건)는 종합성능등급 예측 정확도 및 정밀도 평가에 활용하였다.

3.4.2 학습 방식

본 연구에서 언급하는 '학습'은 기계학습(machine learning)의 맥락에서, 수집된 성능평가 데이터를 이용하여 베이지안 네트워크의 CPT를 추정하는 과정을 의미한다.

DAG는 변수 간의 인과 구조를 정성적으로 정의하는 역할에 그치지만, CPT를 적용하면 각 상태 조합에 따른 조건부 확률이 수치적으로 부여되어 정량적 추론이 가능하다. 이를 통해 단순 가중치 합산 방식으로는 표현하기 어려운 변수 간 상호작용을 반영할 수 있으며, 성능등급 예측의 정밀도 또한 향상된다. Table 9은 CPT 적용 여부에 따른 차이를 비교하여, CPT 도입의 개선 효과를 정리한 것이다.

CPT는 베이지안 네트워크에서 가장 핵심적인 구성요소 중 하나이며, 그 설정의 논리적·통계적 근거는 3가지 방식으로 정당화할 수 있습니다. 전문가 지식 기반 설정(Expert Elicitation), 시뮬레이션 기반 설정 (Scenario-based Simulation), 과거 사례/문헌 기반 통계 설정 (Empirical Estimation from Literature) 중 본 연구에서는 2015~2024년간 수행된 공동구 종합성능평가 자료 121건을 활용한 과거 사례/문헌 기반 통계 설정을 적용하였으며, 모델 학습은 CPT 기반 베이지안 네트워크 구조를 바탕으로 진행하였다.

과거 사례/문헌 기반 통계 설정, 즉 데이터 기반 학습 방식은 실제 수집된 이력 데이터를 기반으로 각 상태 조합에 해당하는 사례 수를 집계한 후, 등급별 빈도수를 상대적 비율로 환산하여 조건부확률로 반영한다. 즉, 입력 조건이 동일한 사례군 내에서 각 등급이 얼마나 자주 나타났는지를 확률적으로 반영한 방식이다. 이 과정에서 다차원 빈도 테이블 구성 및 라플라스 스무딩 처리 등을 통해 데이터 희소성 문제를 완화할 수 있다. 이러한 데이터 희소성 문제를 보완하기 위해, 관측된 조합에 대해서만 조건부 확률을 경험적 비율로 추정하였으며, 관측되지 않은

Table 9. Comparison of Bayesian Network with and without CPT

Aspect	Without CPT (Only DAG)	With CPT (DAG + CPT)
Model Nature	Defines qualitative structure only	Provides quantitative inference capability
Variable Relations	Only directional links between nodes	Conditional probability distributions based on parent–child relationships
Inference Method	Identifies influence directions qualitatively	Estimates specific probabilities of performance grades under given conditions
Prediction Accuracy	Assumes variable independence → lower precision	Reflects inter-variable dependencies → improved precision
Practical Applicability	Limited to structural explanation	Supports decision-making (e.g., maintenance timing, resource allocation)

Table 10. Details for Deriving the CPT

Division	Details
Learning Method	• Data-driven learning: Refinement of the CPT using training samples. • Fixed-structure learning (Fixed DAG): Variable dependency structure fixed based on a pre-derived diagram
Learning Algorithm (Technique)	• [P(X|Parents(X))] representation applied to all nodes. • Maximum Likelihood Estimation (MLE)
Tools Used	• Manual construction of the CPT using Python or Excel

조합에 대해서는 균등분포 기반의 초기값을 사용하였다. 이는 기존 베이지안 네트워크 기반 평가 및 시설 진단 연구에서 일반적으로 사용되는 절충 방식이다(Scutari, 2017).

본 연구에서 CPT 도출을 위한 학습 방식, 알고리즘, Tool에 대한 사항은 Table 10와 같다. 학습은 DAG 및 데이터에 기반하였으며, 알고리즘은 조건부 확률 및 MLE를 활용하였다(Dempster et al., 1977; Douc et al., 2011). Tool은 Excel 및 Python을 사용하여 최종 CPT를 구축하였다.

Table 8의 학습 데이터를 기반으로 도출된 데이터 기반 CPT는 Table 11과 같다. 각 변수의 조건에 대하여 조합의 수는 216개이며, 각 조합에 대하여 등급별 확률을 도출하였다. 조합별 등급 확률이 가장 높은 등급이 최종 선정되며, 각 변수에 따라 선정되는 조합에서 A등급 147개, B 등급 62개, C 등급 7개로 결과가 도출되었다.

3.4.3 모델 검증 방법

학습 데이터로 도출된 CPT의 검증은 '4. 사례 적용 및 결과 분석'에서 수행 예정이며, 본 절에서는 모델 검증 방법에 대한 세부 사항이다.

예측 모델의 성능을 종합적으로 검증(평가)하기 위하여 혼동행렬(Confusion Matrix)을 활용하였다. 혼동행렬은 실제값(Actual)과 예측값(Predicted)을 비교하여, 맞춘 경우/틀린 경우를 등급별로 보여주는 표이다. 행(Row)은 실제 종합성능등급을 열(Column)은 예측된 종합성능등급을 나타낸다. 또한, 모델의 예측 성능은 실제 평가등급과의 비교를 통해 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1-Score 지표로 검증하였다. 검증을 위하여 혼동행렬을 선정한 이유는 단순히 전체 예측 정확도뿐만 아니라, 등급별 예측 신뢰성과 오류 유형을 정량적으로 평가하기 위함이다(Chicco and Jurman, 2020).

F1 Score는 정밀도와 재현율의 조화 평균으로, 본 연구에서는 다등급 예측 상황에서 클래스 간 균형성과 예측력의 조화를 확인하기 위해 Macro F1 및 Weighted F1 지표를 병행하여 분석하였다(Lee et al., 2024). 이는 단순 정확도보다 더 신뢰성 있는 판단 기준으로 활용되며, 특히 데이터 불균형 조건에서 효과적이다.

F1 score의 분석 결과와 관련하여 F1 해석가이드(Futurense, 2025)에서는 F1이 0.8보다 높을 경우 '균형 잡힌 성능을 갖춘 강력한 모델'이라고 하였으며, Encord(Encord, 2025)에서는 F1이 0.8~0.9인 경우 Good, F1> 0.9인 경우 Very good이라고 언급하고 있다.

학습 데이터(96건)에서도 검증 방법을 활용하여 정확도 및 정밀도 지표를 산정하였으나, 이는 모델이 이미 학습한 데이터에 관한 결과로 과적합 가능성을 내포하고 있다. 따라서 본 논문에서는 모델의 일반화 성능을 평가하기 위해, 별도로 분리된 검증 데이터(25건)를 기준으로 검증 결과를 제시하고자 한다.

Table 11. Data-Driven Probabilistic Model

Division	Facility Composition	Equipment Aging	Structural Defect Index	Accident History	Climate Impact Index	Climate Impact Index	Grade Probability				
							A	B	C	D	E
1	No More than Three	Aged	Low	None	Low	Inadequate	88.5%	10.9%	0.6%	0.0%	0.0%
2	No More than Three	Aged	Low	None	Low	Adequate	93.1%	6.7%	0.2%	0.0%	0.0%
3	No More than Three	Aged	Low	None	Medium	Inadequate	77.5%	20.0%	2.5%	0.1%	0.0%
4	No More than Three	Aged	Low	None	Medium	Adequate	86.0%	12.9%	1.0%	0.0%	0.0%
5	No More than Three	Aged	Low	None	High	Inadequate	71.6%	24.6%	3.5%	0.2%	0.1%
6	No More than Three	Aged	Low	None	High	Adequate	82.0%	16.5%	1.5%	0.1%	0.0%
7	No More than Three	Aged	Low	One Time	Low	Inadequate	76.8%	21.0%	2.1%	0.1%	0.0%
8	No More than Three	Aged	Low	One Time	Low	Adequate	85.5%	13.6%	0.9%	0.0%	0.0%
9	No More than Three	Aged	Low	One Time	Medium	Inadequate	58.6%	33.6%	7.5%	0.2%	0.1%
10	No More than Three	Aged	Low	One Time	Medium	Adequate	72.3%	24.2%	3.5%	0.1%	0.0%
		:							:		
207	More than Three	Good	High	One Time	Medium	Inadequate	27.5%	44.1%	24.7%	1.9%	1.7%
208	More than Three	Good	High	One Time	Medium	Adequate	43.4%	40.7%	14.7%	0.8%	0.5%
209	More than Three	Good	High	One Time	High	Inadequate	19.4%	41.5%	26.2%	4.5%	8.5%
210	More than Three	Good	High	One Time	High	Adequate	34.7%	43.3%	17.5%	2.0%	2.5%
211	More than Three	Good	High	Two or More Times	Low	Inadequate	32.6%	44.9%	18.9%	1.7%	1.9%
212	More than Three	Good	High	Two or More Times	Low	Adequate	49.0%	39.3%	10.6%	0.7%	0.5%
213	More than Three	Good	High	Two or More Times	Medium	Inadequate	13.7%	39.7%	37.1%	3.8%	5.7%
214	More than Three	Good	High	Two or More Times	Medium	Adequate	26.1%	43.9%	26.4%	1.8%	1.8%
215	More than Three	Good	High	Two or More Times	High	Inadequate	7.9%	35.3%	41.8%	7.3%	7.7%
216	More than Three	Good	High	Two or More Times	High	Adequate	18.2%	41.0%	27.7%	4.2%	8.8%

Table 12. Dataset for Case-Study Application

Division	Facility Composition	Equipment Aging	Structural Defect Index	Accident History	Climate Impact Index	Management Cycle Appropriateness	Comprehensive Performance Grade
UT-V-01	No More than Three	Good	Medium	Two or More Times	Low	Adequate	A
UT-V-02	More than Three	Aged	High	None	Low	Inadequate	A
UT-V-03	No More than Three	Aged	High	None	Low	Inadequate	A
UT-V-04	More than Three	Aged	Low	Two or More Times	Medium	Inadequate	B
UT-V-05	No More than Three	Good	Low	One Time	Low	Adequate	A
		:				:	
UT-V-21	More than Three	Aged	High	Two or More Times	Low	Inadequate	B
UT-V-22	More than Three	Good	Low	One Time	High	Adequate	A
UT-V-23	More than Three	Aged	High	One Time	High	Adequate	B
UT-V-24	More than Three	Aged	Low	One Time	Low	Inadequate	A
UT-V-25	No More than Three	Aged	Low	One Time	High	Inadequate	A

Note: UT: Utility Tunnel, V: Validation

4. 사례 적용 및 결과 분석

4.1 데이터 구성

3.4.1의 학습 데이터 구성 시 121건의 평가 사례 중 확률 모델 학습에 96건(80%)을 사용하였으며, 나머지 25건(20%)을 검증에 적용하기 위해 사용하였다(Table 12). 자료 출처, 기간 및 범위, 전처리에 대한 모든 사항은 동일하여 생략하였다.

4.2 베이지안 모델 예측 결과

4.2.1 종합성능등급 예측 결과

검증 데이터(25건)에 대한 혼동행렬 분석 결과, 등급 A와 B에 해당하는 사례가 주를 이루었으며, D등급과 E등급은 도출되지 않았다(Fig. 3). 실제 A등급 중 16건은 A′로 정확히 예측되었으며, B′로 잘못 분류된 사례는 2건이었다. B등급의 경우 6건이 B′로

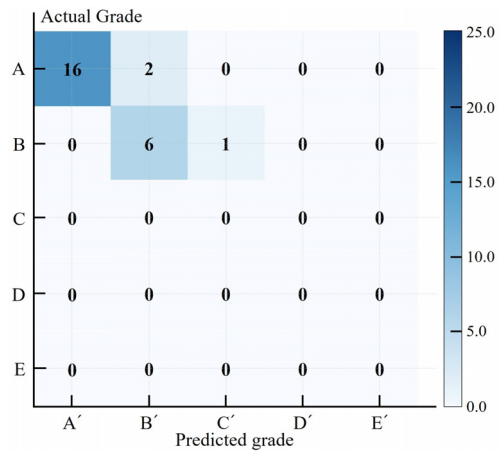

Fig. 3. Confusion Matrix Based on Validation Data

Table 13. Precision, Recall, and F1 Score by Grade

Grade	Precision	Recall	F1 Score
A	1.000	0.889	0.941
B	0.750	0.857	0.800
C	-	-	-
D	-	-	-
E	-	-	-

정확히 예측되었고, C′로 1건 잘못 분류되었다. 전체적으로 볼 때, 예측 모델은 A와 B 등급에 대해 높은 정확도를 보였으며, 오 분류 사례 또한 인접 등급 간에서 제한적으로 발생하였다. 이는 모델이 등급 간 경계를 비교적 명확히 학습하고 있음을 시사한다.

Fig. 3은 제안된 베이지안 모델의 혼동행렬을 보여주며, Table 13은 혼동행렬에서 계산된 정밀도, 재현율, F1 Score에 대한 사항이다. 정밀도, 재현율, F1 점수에서 A등급이 B등급보다 모두 높았으며, 제안된 모델은 정확도 점수 0.880, Macro F1 점수 0.871, Weighted F1 점수 0.902로 나타났다. 본 모델의 F1 Score는 0.871로, 일반적인 분류 모델 평가 기준에 비추어 볼 때 실무 적용 가능성이 높은 수준으로 평가된다. 특히 정밀도(0.875)와 재현율(0.873) 사이에 균형이 유지되어 F1 Score가 안정적으로 나타났으며, 이는 클래스 간 성능 편차 없이 모델의 예측력이 균형 있게 발휘된 결과로 해석된다.

결론적으로 본 모델은 상위 등급(A, B)에 대한 예측 성능은 우수하나, 본 연구에서 활용된 데이터셋의 규모와 다양성이 제한적이어서 일반화 가능성을 확보하기 위해서 추가 검증이 필요하다. 현재 공동구 39개의 성능이 모두 B등급 이상이므로 재현성 확보에도 제약이 있으며, 향후에는 다양한 등급을 포함한 자료를 확보하여 검증이 필요하다. 또한 제안된 입력변수는 출력변수와의 다중공선성 검토를 선행한 뒤 선정함으로써 모델의 안정성과 해석력을 더욱 강화할 수 있을 것이다.

5. 결론 및 향후 연구

본 연구는 공동구의 종합성능평가 결과를 활용하여 베이지안 네트워크 기반의 성능 예측 및 유지관리 의사결정 지원 모델을 제안하고, 실제 사례에 적용하여 그 실효성을 검증하였다. 주요 연구 내용을 요약하면 다음과 같다.

1) 공동구의 구조, 설비, 환경, 운영 등 종합성능평가 항목을 기반으로 주요 영향을 미치는 변수(구조 결함지수, 설비 노후도 등)를 도출하고, 이를 베이지안 네트워크 모델의 입력 변수로 설정하였다.
2) 변수 간의 인과관계를 데이터 기반 분석을 통해 구조화하고, 전체 데이터(121개) 중 학습 데이터(96개)를 기반으로 CPT을 구성하여 모델을 구축하였다.
3) 잔여 데이터(25개)에 대하여 검증을 수행한 결과, 베이지안 네트워크 모델은 높은 예측 성능과 실용적인 해석력을 보임으로써 유지관리 의사결정에 효과적으로 활용될 수 있음을 입증하였다.

공동구는 도시 기반시설 중 사고 발생 시 파급효과가 큰 핵심 인프라이며, 이에 대한 체계적인 성능평가 및 예측기반 유지관리가 필수적이다. 본 연구는 정량적 등급 정보를 정교한 확률 모델로 전환하는 출발점을 제공하였다.

현재 공동구 종합성능등급이 현재 모두 B등급 이상 이어서 중/하위 등급(C~E)에 대한 예측력은 판단이 어려웠다. 따라서 향후 정확한 등급 분류를 위해서는 데이터 분포의 균형 확보가 필요하며, 특히 중/하위 등급에 관한 학습사례를 위하여 타 시설물에 확대가 요구된다. 또한 본 연구에서 활용된 데이터셋의 규모와 다양성이 제한적이어서 일반화 가능성을 확보하기 위해 추가적인 검증이 필요하다. 제안된 입력변수 역시 출력변수와의 다중공선성 검토

를 선행한 뒤 선정함으로써 모델의 안정성과 해석력을 더욱 강화할 수 있을 것이다. 향후 지속적인 데이터 축적과 기술 발전을 통해 본 모델의 실현성과 적용성을 더욱 확대해 나갈 수 있을 것으로 판단된다.

참고문헌

1. 강재영·김종진(2024), "도시계획시설 용량 산정을 위한 확률적 수요 예측에 관한 연구", 「토지주택연구」, 15(1): 135~146.
2. 국토교통부(2017), 「사회기반시설의 성능중심 관리 운영을 위한 한국형 성능등급 산정기술 개발 최종보고서」, 세종: 국토교통부.
3. 국토교통부(2018.5.18), "시설물의 안전 및 유지관리에 관한 특별법 시행규칙".
4. 국토안전관리원(2021), 「기반시설 관리를 위한 세부 업무 체계 및 기준 마련 연구용역」, 원주.
5. 국토안전관리원(2025), 「2024년 국토안전 통계연보」, 원주.
6. 김태원·이정형(2025), "인공신경망 모델에 따른 재실시간 중 실내 $PM_{2.5}$ 예측성능 비교", 「토지주택연구」, 16(1): 127~139.
7. 오원준·나귀태·조중연·이민재(2019), "기존시가지의 규모(면적)에 따른 공동구 설치 타당성에 관한 연구", 「대한토목학회논문집」, 39(6): 903~911.
8. 오원준·조중연·이민재(2020), "공동구 기본계획 기준수립을 위한 절차 및 적용사례에 대한 연구", 「한국건설관리학회 논문집」, 21(4): 100~107.
9. Attoh-Okine, N. O. and S. Bowers (2006), "A Bayesian Belief Network Model of Bridge Deterioration", *Proceedings of the Institution of Civil Engineers: Bridge Engineering*, 159(2): 69~76.
10. Chan, H. and A. Darwiche (2012), "Reasoning about Bayesian Network Classifiers", *Proceedings of the 28th Conference on Uncertainty in Artificial Intelligence (UAI 2012)*, San Francisco, CA, 107~115.
11. Chicco, D. and G. Jurman (2020), "The Advantages of the Matthews Correlation Coefficient (MCC) over F1 Score and Accuracy in Binary Classification Evaluation", *BMC Genomics*, 21(1): 6.
12. Dempster, A. P., N. M. Laird and D. B. Rubin (1977), "Maximum Likelihood from Incomplete Data via the EM Algorithm", *Journal of the Royal Statistical Society: Series B (Methodological)*, 39(1): 1~38.
13. Douc, R., E. Moulines, J. Olsson and R. van Handel (2011), "Consistency of the Maximum Likelihood Estimator for General Hidden Markov Models", *The Annals of Statistics*, 39(1): 474~513.
14. Green, D. K. E. and A. Jaspan (2023), "Applied Bayesian Structural Health Monitoring: Inclinometer Data Anomaly Detection and Forecasting", *Proceedings in Applied Mathematics and Mechanics*, 23(4): e202300145.
15. Hyttinen, A., J. Pensar, J. Kontinen and J. Corander (2018), "Structure Learning for Bayesian Networks over Labeled DAGs", *Proceedings of the 9th International Conference on Probabilistic Graphical Models (PGM 2018)*, 72: 157~168.
16. Lee, M. C. H., J. Braet and J. Springael (2024), "Performance Metrics for Multilabel Emotion Classification: Comparing Micro, Macro, and Weighted F1-Scores", *Applied Sciences*, 14(21): 9863.
17. Needham, C. J., J. R. Bradford, A. J. Bulpitt and D. R. Westhead (2007), "A Primer on Learning in Bayesian Networks for Computational Biology", *PLoS Computational Biology*, 3(8): 1409~1416.
18. Ni, H., X. Li, J. Huang and S. Zhou (2024), "Health Risk Prediction of Operational Subsea Tunnel Structure Based on Bayesian Network", *Buildings*, 14(5): 1475.
19. Scutari, M. (2017), "Beyond Uniform Priors in Bayesian Network Structure Learning", *arXiv preprint*, arXiv:1704.04103.
20. Tang, X., A. Chen and J. He (2022), "A Modelling Approach Based on Bayesian Networks for Dam Risk Analysis: Integration of Machine Learning Algorithm and Domain Knowledge", *International Journal of Disaster Risk Reduction*, 71: 102789.
21. Tien, I. (2014), "Bayesian Network Methods for Modeling and Reliability Assessment of Infrastructure Systems", Ph.D. Dissertation, University of California, Berkeley, Civil and Environmental Engineering.

22. Vagdatli, T., K. Petroutsatou, P. Panetsos, Z. Barmpa and N. Fragkakis (2024), "Probabilistic Pre-Estimation of Life-Cycle Costs of Road Bridges Using Dynamic Bayesian Networks", *Structure and Infrastructure Engineering*, 20(8): 2414971.
23. Zhang, H. and D. W. R. Marsh (2021), "Managing Infrastructure Asset: Bayesian Networks for Inspection and Maintenance Decisions Reasoning and Planning", *Reliability Engineering & System Safety*, 207: 107~121.
24. Zheng, X., B. Aragam, P. Ravikumar and E. P. Xing (2018), "DAGs with No Tears: Continuous Optimization for Structure Learning", *Advances in Neural Information Processing Systems (NeurIPS 2018)*, 31: 9472~9483.
25. Encord, "F1 Score in Machine Learning", Encord Blog, Accessed June 21, 2025. https://www.encord.com.
26. Futurense, "F1 Score in Machine Learning: All You Need to Know in 2025", Futurense Academy, Accessed May 30, 2025. https://www.futurense.com.
27. 국가건설기준센터(KCSC), "KDS 29 공동구 설계기준 개정(안)", 국가건설기준센터 홈페이지, 2025.6.12 읽음. https://www.kcsc.re.kr.
28. 국가법령정보센터(NLIC), "시설물의 안전 및 유지관리에 관한 특별법 시행규칙", 국가법령정보센터, 2025.5.18 읽음. https://www.law.go.kr.
29. 기반시설관리시스템(Inframanage), "도시기반시설 15종 통합관리체계 구축 보도자료", Inframanage, 2025.7.5 읽음. https://www.inframanage.go.kr.
30. 시설물통합정보관리시스템(FMS), "시설물통합정보관리시스템 소개", FMS, 2025.5.28 읽음. https://www.fms.or.kr.
31. 점검진단평가관리시스템(IREMS), "공공시설물 안전관리 정보조회 서비스", 국토안전관리원/공공데이터포털, 2025.6.21 읽음. https://www.data.go.kr/data/15046035/openapi.do.
32. 지자체 정보공개포털(Open Government Korea), "지자체 기반시설 정보공개 서비스", 공공서비스포털, 2025.6.30 읽음. https://www.open.go.kr.

요 약

본 연구는 공동구의 종합성능등급을 보다 정밀하게 예측하고 유지관리 의사결정을 지원하기 위해 베이지안 네트워크(Bayesian Network) 기반의 성능예측 모델을 제안하였다. 현행 종합성능등급 제도는 점검 시점의 가중평균 점수에 의한 일회성 평가에 그쳐, 시간 경과에 따른 성능저하 추정이나 복합 요인 간 인과관계를 반영하기 어렵다는 한계가 있다. 이를 보완하기 위해 본 연구에서는 수용시설 구성, 설비 노후도, 구조결함지수, 사고이력, 기후영향지수, 관리주기 적정성 등 6개의 핵심 변수를 선정하고, 변수 간 인과관계를 DAG 형태로 구조화하였다. 2015~2024년간 39개 공동구의 121건 종합성능평가 데이터를 수집·전처리하여 학습용(96건)과 검증용(25건)으로 구분하고, 각 노드의 조건부 확률 분포를 나타내는 조건부확률표(CPT)를 생성하여 모델 학습에 활용하였다. 모델 학습은 데이터 기반 학습 알고리즘 방식을 활용하였으며, 검증 결과 정확도 0.880, Macro F1 0.871, Weighted F1 0.902로 높은 예측 성능을 보였으며, 오 분류 사례는 인접 등급(예: A↔B, B↔C) 간에서만 제한적으로 발생하였다. 등급에 대한 예측 정확도가 높았으며, 오 분류 사례도 인접 등급에서 제한적으로 발생하였다. 현재 공동구는 모두 B등급 이상으로 C~E 등급 데이터가 부족하여 중·하위 등급에 대한 예측력은 검증이 제한되었다. 본 연구는 정량적 평가 결과를 확률 모델로 확장하여 공동구 성능평가 활용성을 높였으며, 향후 연구에서는 데이터 분포의 균형성을 확보하고, 교량·터널·댐 등 다른 기반시설로 적용을 확대함으로써 범용성과 신뢰성을 강화할 수 있을 것이다.

주제어: 공동구, 종합성능등급, 베이지안 네트워크, F1 score, 혼동행렬