

교통과 지역의 특성에 따른 대설의 실시간 피해 위험도 분석 연구⁺

(A Study on the Real-Time Risk Analysis of Heavy-Snow according to the Characteristics of Traffic and Area)

하 광 립^{1)*}, 정 용 철²⁾, 유 진 영³⁾, 이 준 희⁴⁾

(KwangRim Ha, YongCheol Jung, JinYoung Yoo, and JunHee Lee)

요 약 본 연구에서 대설의 직접, 간접적인 피해에 영향받는 요소들에 대해 지역적 특성을 반영해 위험도를 분석하는 알고리즘을 제시한다. 229개의 지역별로 대설피해의 영향을 받는 요소들을 영향변수로 선정하고 피해액과의 관계를 통해 민감도라는 개념을 도출한다. 기상 상태(적설량, 습도, 기온)와 민감도를 독립 변수로 설정하고 독립 변수의 변화에 따라 도출된 위험도를 종속변수로 설정해 머신러닝(XGBoost) 알고리즘을 이용한 대설피해 위험도 예측 모델을 개발했다.

핵심주제어: 위험도, 대설민감도, 지역 민감도, 교통 민감도

Abstract In this study, we present an algorithm that analyzes the risk by reflecting regional characteristics for factors affected by direct and indirect damage from heavy-snow. Factors affected by heavy-snow damage by 29 regions are selected as influencing variables, and the concept of sensitivity is derived through the relationship with the amount of damage. A snow damage risk prediction model was developed using a machine learning (XGBoost) algorithm by setting weather conditions (snow cover, humidity, temperature) and sensitivity as independent variables, and setting the risk derived according to changes in the independent variables as dependent variables.

Keywords: Hazard, Heavy-snow Sensitivity, Local Sensitivity, Traffic Sensitivity

1. 서 론

1.1 연구의 배경과 목적

* Corresponding Author: kr.ha@cslee.co.kr

+ 본 연구는 행정안전부 재난 안전 취약핵심역량 도약기술개발 사업(2020-MOIS33-006)의 지원을 받아 수행되었음.

Manuscript received October 14, 2022 / revised December 06, 2022 / accepted December 21, 2022

1) (주)씨에스리 AI엔지니어링사업부, 제1저자, 교신저자

2) (주)씨에스리 데이터엔지니어링팀, 제2저자

3) (주)씨에스리 데이터엔지니어링팀, 제3저자

4) (주)씨에스리 데이터엔지니어링팀, 제4저자

최근 이상 기후로 인해 자연재해의 피해가 증가하고 있다. 2020년도 재해 연보에 따르면 대설은 풍수해 다음으로 피해가 큰 재난이며, 겨울철 대표적인 재난으로 손꼽히고 있다. 대표적인 대설 재난으로 2014년 2월 17일에는 경주의 마우나 오션 리조트 체육관이 지붕에 쌓인 눈으로 인해 붕괴하며 약 150명의 사상자를 발생시

키는 피해가 있었고, 2021년 3.1절 연후 마지막 날 강원도 영동지방에 88cm의 눈이 내려 이틀 간 53건의 교통사고 발생으로 인해 1명이 숨지고 94명이 다치는 피해가 있었다. 이와 같은 대설로 인한 피해가 점차 심각해지고 있어 행정안전부의 재해 연보를 통해 전 세계적으로 큰 피해가 발생하는 대설과 관련된 다양한 국내·외 사례를 파악했다.

대표적인 국외 사례로 러시아 모스크바 지역에 2019년 1월 말 최심적설이 44cm인 기록적인 폭설이 내렸다. 이는 68년 만의 최고의 폭설로도 곳곳이 마비되고 수십 편의 항공기가 결항되었다. 여기서 최심적설이란 전부터 내려서 녹지 않고 쌓인 눈을 포함해 가장 두껍게 쌓였을 때의 눈의 깊이를 말한다. 2월 중순에는 적설을 기준으로 140년 만의 폭설이 발생했으며, 같은 해 오스트리아의 경우 1월에 적설량이 최대 451cm가 오면서 11명이 사망하고 1명이 실종되었으며 관광객 1만 2천 명이 고립되는 인명피해가 있었다. 이탈리아에서는 폭설로 인한 열차 탈선과 눈사태로 인해 4명이 사망하는 큰 피해가 있었다.

이란의 북부 지역에서는 2020년에 폭설 및 눈사태로 인해 7명이 사망하고 78명이 부상을 입었으며, 알보르즈산(Alborz)은 강풍을 동반한 폭설로 인한 산사태가 일어나 12명이 사망하고 14명이 부상을 입었다.

미국의 경우 2015년 2월 16일부터 시작된 눈폭풍으로 30명이 사망하고 약 33억 달러의 경제 손해액이 발생했다. 이 사고로 항공기 1,500여 편이 결항되었고 3,000여 가구가 정전되었으며, 일부 지역에서는 야근 통행 금지령이 내려지는 등 인근지역 경제가 일시적으로 마비되었다. 2019년 4월에 시카고에는 58년 만에 최심적설 20.3cm의 폭설이 내리면서 4,800여 대의 항공편이 결항되었다. 2020년 12월에는 북동부에서 겨울 폭풍 Nor'easter(노리스트어)가 발생하여 일부 지역이 30cm 이상 눈이 쌓이고 약 28만 가구에서 정전 피해가 있었고 87km/h의 강한 돌풍과 눈보라의 발생으로 15~36cm의 적설량을 기록했으며 이로 인한 교통사고로 2명이 사망하고 6명이 부상을 입는 인명피해가 있었다. 그러나

미국의 연방재난청은 재난이 발생하면 피해 예비평가를 수행하여 10% 내외의 오차범위 정도로만 피해를 추정하고 있다. (Oh, 2017)

우리나라도 대설의 피해에서 자유로울 수 없었다. 2011년부터 2020년도까지 최근 10년간 대설로 인한 피해액은 약 1,574억 원에 달한다. 그러나 대설로 인한 교통 혼잡 피해를 포함한다면 피해 규모는 더 크다.

2015년 11월의 경우 폭설로 인한 교통사고 건수가 이틀 동안 291건이 접수되었고 교통사고로 인한 차량정체도 이어졌다.

2016년 발생한 대설은 제주공항이 2일 동안 폐쇄되고, 농가 등 사유 시설물에 총 185억 원에 해당하는 피해를 줬다. 특히 제주도에 발생한 피해는 1923년 제주 기상관측 이후 최저기온인 영하 5.8℃를 기록하였으며, 적설량은 51.3cm 이상을 기록하였다.

2017년도 1월 서울특별시에는 대설로 인해 생긴 빙판길을 우려해 대중교통 이용량이 급격하게 증가하면서 버스 연착이 잇따랐고 지하철 1호선의 고장으로 운행이 30여 분 지연되었다. 교통사고도 평소에 두 배 가까이 늘어 교통사고 건수가 9,992건으로 평균보다 88.8%가 많았다. 12월 오전 10시엔 버스전용차로가 없었고 평소에도 정체가 심해 눈으로 인해 가다 서기를 반복하며 2시간이 넘게 올림픽 대로에 갇혀있었고 서강대교에서는 삼중 추돌사고로 도로가 마비되어 3시간째 버스나 승용차에 갇혀있는 사고도 있었다. 건설작업이 이루어지지 않은 지역에서는 쌓인 눈이 얼어붙어 차량이 미끄러지기도 하고 언덕길이 많은 용산구 마을버스는 아침 운행을 중단하며 극심한 교통 피해로 더 많은 사회경제비용이 발생했다.

또한, 2018년도 1월부터 3월까지 2개월 동안 제주도는 대설피해에 농업재해를 더해 약 150억 원 상당의 피해가 발생한 것으로 집계됐다. 이에 따라 기존에 대설피해가 자주 발생하지 않던 지역까지 대설에 따른 인명 및 경제적인 피해가 발생하여, 대설피해에 대한 전국적인 대설피해저감에 관한 연구가 요구되고 있다. 그러나 현재 우리나라에는 상대적으로 풍수해에 관한 연구가 많고, 대설의 직접 피해나 간접피해에 관

한 연구는 거의 수행되고 있지 않다.

대설의 피해는 크게 적설에 의한 직접 피해와 교통과 관련된 간접피해로 구분할 수 있다. 직접 피해는 눈이 많이 쌓여서 일어나는 적설 피해와 쌓인 눈의 압력으로 일어나는 설압 피해, 경사면을 미끄러지면서 일어나는 눈사태와 송전선이나 가설물에 부착되어 발생하는 착설 등의 피해를 의미하고, 간접피해는 결빙 등으로 인도로 마비 및 교통 혼잡도로 인해 발생하는 피해를 의미한다. 직접 피해의 경우 산지와 농가 인구가 많은 지역에 피해 정도가 크며, 간접피해의 경우는 서울특별시, 경기도와 같은 인구밀도가 높은 지역에 피해가 크다. 비닐하우스, 인삼재배, 빈집 등이 적설의 피해에 취약하며 고비용의 경작시설에 피해로 인해 복구 비용이 많이 들어 재산 피해를 가중한다. 또한, 대중교통과 승용차 등 도로교통에도 영향을 끼쳐 차량정체 및 통행시간 증가와 같은 사회적 비용을 발생시킨다.

특히, 기상재해로서 대설에 관한 연구는 지역별 재해 유형과 피해 특성 등에 따라 다양하다.

Kwon, et al.(2016)은 1994년부터 2013년까지의 재해 연보 자료를 활용하여 지역별 대설피해 현황 및 사례를 분석하고 시설물의 방재 취약성을 분석하여 시설물의 보완 대책과 시설물 피해 최소화 방안을 연구했다. 또한, Kim, et al.(2018)은 다중 회귀모형을 이용하여 대설 재난의 경제적 피해액과 강설량, 강설일, 인구밀도, 비도시지역 비율 및 수도권 더미 변수 등 간의 연관성을 확인하여 경제 효과 연구를 진행하였고, Moon and Kim(2018)은 대설의 경제적 피해를 교통 수요모형과 불능투입산출모형[(대설로 인한 교통감소량/정상시의 교통량)]과 적설량 시나리오로 대설로 인한 교통량 감소가 지역경제에 미치는 영향을 연구하였다.

그러므로 대설피해에 관한 연구는 대설을 유발한 자연환경뿐만 아니라 지역별 대설피해 특성을 고려하여 분석할 필요가 있다. 그러나 이상 기후는 자연재해의 강도 또는 피해 규모의 예측을 점점 더 어렵게 만들고 있다. 선행 연구에서는 이러한 피해에 대한 간접피해나 직접 피해에 관한 연구는 있지만, 229개 지역을 기준으

로 두 피해를 모두 반영한 연구는 거의 없기에 본 연구를 진행했다.

또한, 대설의 경우 지역의 특성에 따라 직접 피해와 간접피해의 위험 정도가 달라 고려할 사항이 많다. 그러나 현재 관심·주의·경계·심각 4단계의 위기 경보 기준은 정량적으로 모호하다. 관심 단계의 경우 대설 빈발 시기, 주의는 대설 예비특보 또는 대설주의보가 발령되고 대설에 의한 대규모 재난이 발생할 가능성이 나타날 때, 경계는 대설경보가 발령되고 대설에 의한 대규모 재난이 발생할 가능성이 농후할 때, 그리고 심각한 경우는 대설경보가 발령되고 대설에 의한 대규모 재난이 발생할 가능성이 확실할 때가 판단 기준으로 되어있다.

따라서 본 연구에서는 대설피해와 관련된 재해 연보를 분석하여 대설피해를 유발하는 적설량을 기준으로 선정하고, 주로 농가 인구가 많은 지역에 직접 피해가 발생하고, 유동 인구가 많은 지역에 간접피해가 발생하는 점을 이해하여 대설피해에 영향받는 요소들을 선정한 후 시·군·구의 특성에 맞게 위험도를 1부터 10까지의 수준으로 정량화했다.

1.2 연구방법

1.2.1 대설과 적설

본 연구를 이해하기 위해서는 대설과 적설에 대해 정의해야 한다. 먼저 대설이란 짧은 시간에 집중적으로 눈이 내려 인명 및 재산 피해를 유발하는 재난을 뜻한다.

적설은 크게 적설과 신적설(新積雪)로 구분된다. 적설은 기간에 상관없이 눈을 치우지 않은 상태에서 실제로 지면에 쌓여있는 깊이를 뜻하며, 신적설은 새로 쌓인 눈의 깊이만을 의미한다. 적설에 의한 발생한 피해를 뜻하는 재난을 대설이라고 한다.

1.2.2 대설민감도(지역민감도와 교통민감도)

본 연구에서는 대설과 관련이 있는 지역의 특성을 대설민감도라고 정의했다. 민감도의 사전적 의미는 임의의 수준 자극(또는 변수 변화)에 따라 반응(또는 응답 결과)하는 컴포넌트, 모델

또는 시뮬레이션의 능력을 뜻한다. (국방과학기술용어사전) 그러므로 본 연구에서 적설에 의한 직접 피해의 분석으로 도출한 민감도를 지역 민감도로, 교통에 대한 간접피해의 분석으로 도출한 민감도를 교통 민감도라고 정의한다. (Kim et al., 2015) 재난에 따른 피해가 발생하는 지역이 컴포넌트 또는 모델에 해당한다. Fig. 1과 같이 대설과 대설에 의해 발생한 피해의 상관성을 통해 도출한 지역적 특성을 정의하여 활용한다. 두 가지의 민감도를 더해 0과1 사이의 범위로 Scaling 한 값을 대설민감도라고 제안하며 229개의 시·군·구에 대해 대설피해에 취약한 정도에 대해 수치적으로 표현하였다.

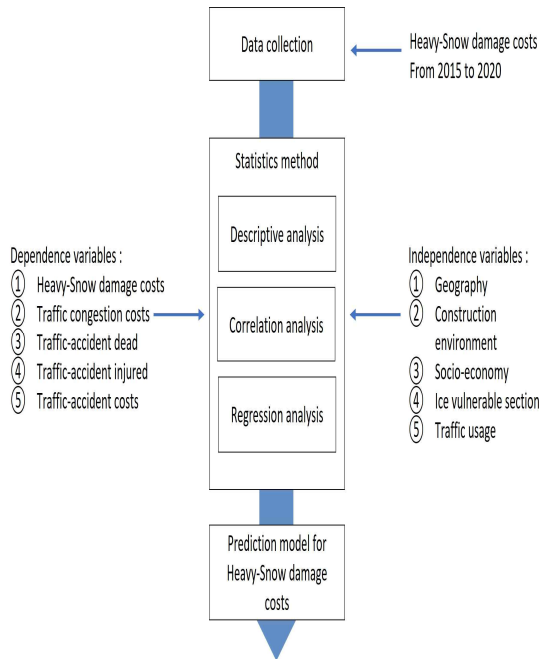


Fig. 1 Sensitivity Process

1.2.3 머신러닝

XGBoost 머신러닝을 이용해 모델 학습을 진행했다. XGBoost란 다양한 파라미터를 조정해 최적화된 모델을 만들 수 있는 머신러닝으로 약한 예측 모형들의 학습에서 오차에 가중치를 두고 순차적으로 다음 학습 모델에 반영하여 강한 예측이나 분류 모델을 만드는 앙상블 기법에서 부스팅(Boosting)에 해당하는 알고리즘이다. 병렬처리로 학습이나 분류 속도가 빠르고 조기 종료, 규제화의 적용으로 과적합이 발생할 가능성

이 낮은 특징이 있어 본 연구에서는 XGBoost의 분류기능인 Classification 기능을 사용한다.

2. 위험도 데이터 구축

2.1 영향변수 선정

2.1.1 종속변수

종속변수란 독립 변수의 영향을 받아 변화하는 변수를 의미한다. 즉, 독립 변수로 설명되는 변수를 뜻하며 종속변수에 해당하는 값을 예측값이라고도 부른다. 본 연구에서는 지역적 특성에 의해 피해 정도를 수치화한 위험도의 도출이 목적이므로 지역 민감도, 교통 민감도가 반영된 대설민감도와 기상 데이터 (적설, 기온, 습도)를 독립 변수로 설정하고 두 독립 변수를 이용하여 산출된 위험도를 종속변수로 설정하였다. 여기서 종속변수로 설정한 위험도의 범위는 일반적인 수준으로 인식할 수 있는 1부터 10까지로 하였다.

2.1.2 독립변수

독립변수란 다른 변수에 영향을 받지 않고 독립적으로 어떠한 결과에 영향을 주는 원인이 되는 변수를 의미한다.

대설로 인해 피해를 발생시키는 요소들을 XGBoost 알고리즘의 독립 변수로 사용하기 위해 영향변수로 선정했으며, 피해액과 영향변수들 사이의 상관관계 분석을 통해 지역 민감도와 교통 민감도를 도출하였다.

지역 민감도의 피해액은 재해 연보 상의 피해액을 사용하였다. 재해 연보는 1년간 발생한 재해를 기간별, 시도별, 원인별 등으로 구분하여 이재민을 포함한 건물 피해, 농경지 피해, 공공 시설 피해 등 총 10개의 항목으로 제시하고 있다. 피해액은 한국은행의 2020년 물가 환산 지수를 이용하여 2020년 기준으로 계산하였고 시·군·구 별로 2015년부터 2020년까지 총 6년간의 피해액을 수집했다. 교통 민감도의 피해액은 교통 사고분석 시스템(TAAS)의 눈에 의한 교통 사고 사망자 수와 부상자 수의 데이터, 그리고

도로교통공단의 ‘도로교통 사고 비용 추계와 평가’에서 교통사고 사망자 1인당 순 평균 비용과 부상자 1인당 순 평균 비용을 사용했다. 또한, 국가교통 데이터 오픈 마켓을 통해 2018년도 각 시·군·구의 교통혼잡비용도 사용하였다. 여기서 교통혼잡비용이란 교통 혼잡에 의하여 증가하는 사회적 비용을 뜻하며, 도로의 경우 교통량이 어느 한계를 넘는 도로에서 추가되는 한 대의 차량으로 인하여 증가하는 전체 주행 비용과 시간 비용의 증가를 의미한다.

교통 민감도 피해액의 경우 교통사고 사망자 또는 부상자 수에 각 1인당 순 평균 비용을 곱한 뒤 교통혼잡비용을 더해 피해액을 산출했다. (Eq.(1)) 2019년도와 2020년도는 COVID-19로 인해 교통상황이 특수한 상황이기에 2018년도를 기준으로 했으며, 영향변수 데이터들 또한, 2018년도 기준으로 데이터를 수집하였다.

$$TDC = AD*DAC + AI*IAC + TC \quad (1)$$

TDC = Traffic Damage Costs (교통 피해액)

AD = Traffic Accidental Death (교통사고 사망자)

DAC = Death-toll Average Costs(교통사고 사망자 1인당 순 평균 비용)

AI = Traffic Injured (교통사고 부상자)

IAC = Injured Average Costs (교통사고 부상자 1인당 순 평균 비용)

TC = Traffic-Congestion Costs (교통혼잡 비용)

지역 민감도는 선행 문헌을 기반으로, 교통

민감도는 선행 문헌과 행정안전부의 결빙 취약 구간 배점표의 항목들로 영향변수를 선정했다. 지역 민감도의 경우 Table 1과 같이 건설환경요인, 지리적 요인, 사회경제적 요인으로 구분 지었다.

건설환경요인으로는 노후 건축물, 고층 건물, 빈집, 옥상녹화, 교량 수 등 건물이 대설로 인해 영향을 받거나 영향을 끼치는 요소들로 선정했다. 노후 건축물과 빈집은 지붕에 눈이 쌓이면 하중을 견디지 못하고 붕괴 위험이 커져 행정안전부에서 적설 취약 구조물로 구분했다.

지리적 요인으로는 대설피해를 비닐하우스, 인삼재배 먼적, 과수원 등 재배 시설로 선정하였다. 인삼재배 해가림시설은 다른 기상재해에 비해 폭설 피해가 9.5년에 1회로 가장 높고 피해 내용도 심각하여 구조물이 붕괴되거나 반파 이상의 피해 받은 경우가 70% 정도였다. (Cheon, 2017) 또한, 고소득 작물로 재배하는 가구 수가 점차 증가하는 추세이므로 과수원과 목장 용지 등과 같은 동결 현상으로 인해 언 피해가 많은 요소 또한 영향변수로 선정하였다.

사회경제요인으로는 농가 가구, 사업체 수, 수급권자 수, 65세 인구수, GRDP(Gross Regional Domestic Product) 등을 선정하였고, 수급권자와 노인 인구수가 많을수록 대설피해 예방이 어렵고, 1인당 총소득 즉 GRDP가 높을수록 대설피해 예방 인구가 많다는 연구 결과를 기반으로 영향변수를 선정하였다.

교통 민감도의 경우 Table 2와 같이 결빙 취약 구간 배점표와 선행 연구를 기반으로 영향변수를 선정했다. 국토교통부에 따르면 결빙 취약

Table 1 Region-Sensitivity Independent Variable

Construction Environmental	Geographical	Social Economy
Old-building	Vinyl greenhouse	GRDP
High-rise building	Ginseng houses	Aging population
Empty house	Orchard	Qualified recipient
Rooftop garden	Ranch land	Company
Bridge	Forest area	Farming population
	Field	Population

은 시속 50km 기준 빙판길 제동 길이가 승용차의 경우 약 4배 이상, 화물차와 버스는 약 7배 이상 길어지며 빙판길 곡선 구간은 시속 40km가 넘으면 사실상 제어가 불가능하다고 한다. 이에 따라 겨울철 도로교통사고 예방을 위해 결빙 취약 구간을 별도로 지정했다. 행정안전부의 결빙 취약 구간의 배점표 목록을 통해 터널 수, 지하차도 수, 입체교차로 수, 급경사지 수를 영향변수로 선정했고, 선형 문헌 기반 오르막길, 대중교통 이용자 수, 자동차 등록 대수, 운수회사 종사자 수, 버스 추정 교통량, 승용차 추정 교통량, 화물차 추정 교통량 등을 수집했다. (Lee and Chung, 2018) 적설량이 높을수록 오르막길에서 차량 미끄러짐 현상으로 인한 교통체증이 증가하며 교통체증이 증가로 인한 대중교통 이용량이 높아짐에 따라 대중교통 이용자 수도 영향변수로 선정했다. (Moon and Kim, 2018)

Table 2 Traffic-Sensitivity Independent Variable

Freezing Vulnerable Section	Traffic Jam
Tunnel	Public Transform User
Underpass	Transportation Company
Overpass	Traffic Estimation
Steep Slope-land	Vehicle Registration Residual Freezing Section

2.2 민감도 도출

2.2.1 변수 선택과 상관분석 진행

수집한 영향변수들을 독립 변수로 선정하기 위해 다중회귀식의 변수 선택법과 상관분석을 수행했다.

먼저 다중회귀식의 변수 선택법이란 최적의 회귀방정식 선택에 도움을 주는 방법으로 다중

공선성으로 인해 과적합이 발생하지 않기 위해 사용한다. 변수 선택법에는 전진 선택법과 후진 선택법, 단계적 선택법이 존재하며, 전진 선택법은 높은 영향력을 가진 변수를 하나씩 추가하는 방법이고, 후진 소거법은 모든 변수를 포함한 모델에서 영향력이 가장 적은 변수를 제거하는 방법이다. 그리고 단계적 선택법은 전진 선택법과 후진 소거법을 혼합한 방법이다. 본 연구에서는 영향변수를 최대한 적용하기 위해 변수 선택법의 전진 선택법과 후진 소거법을 통해 의미 있는 독립 변수를 선정하였다. 변수 선택법을 통해 전진 선택법으로 도출된 8개의 변수와 후진 소거법으로 도출된 7개의 변수를 대상으로 상관분석도 진행했다.

각 영향변수를 Python에서 제공하는 sklearn 라이브러리의 minmax 함수를 이용해 조정된 뒤 0과 1 사이의 범위로 scaling을 진행한 뒤에 Pearson 함수를 이용해 상관분석을 진행했다. 상관성이 가장 높은 10개의 영향변수 데이터에 상관계수를 곱해 민감도를 도출했다.

여기서 MinMaxScaler란 스케일을 조정하는 정규화 함수로, 모든 데이터가 본래의 값을 잃지 않고 0과 1 사이의 값을 갖도록 하는 함수이다.

또한, 상관분석이란 연속형 변수로 측정된 두 변수 간의 선형적 관계를 분석하는 기법이다. 연속형 변수는 산술 평균을 계산할 수 있는 숫자 형의 데이터이며, 선형적 관계란 흔히 말하는 비례식이 성립되는 관계를 말한다. 예를 들어 A 변수가 증가함에 따라 B 변수도 증가하는지 혹은 감소하는지를 분석하는 것이다. 상관분석에는 두 변수 사이의 선형적인 관계 정도를 나타내기 위해 상관계수를 사용한다.

Pearson 상관계수란 두 변수 간의 선형 상관관계를 표현하는 수치다. Cauchy-Schwarz 부등식에 의해 +1과 -1 사이의 값을 가진다. +1은 완벽한 양의 선형 상관관계, 0은 선형 상관관계가 없음, -1은 완벽한 음의 선형 상관관계를 의미한다. 수학적으로는 전체 편차 내에서 예측치와 평균 간의 차이가 차지하는 비율을 뜻한다.

2.2.2 지역민감도

지역 민감도는 아래 Table 3과 같이 농가 가구 수, 산림면적, 목장 용지, 빈 다세대주택, 인삼재배 면적, 논 이용량, 비닐하우스 수, 과수원 면적, 밭 면적을 양의 상관 계수로 GRDP를 음의 상관 계수로 상위 10개를 선정했다. (Eq.(2))

$$RS = FP*0.3 + FA*0.39 + EH*0.43 + GH*0.44 + RP*0.4 + RL*0.39 + OC*0.61 + VG*0.46 + FD*0.58 - GRDP*0.11 \quad (2)$$

- RS : Region Sensitivity (지역민감도)
- FP : Forest Area (산림면적)
- EH : Empty House (빈집)
- GH : Ginseng Houses (인삼재배면적)
- RP : Rice Paddy (논 면적)
- RL : Ranch Land (목장용지)
- OH : Orchard (과수원)
- VG : Vinyl Greenhouse (비닐하우스 수)
- FD : Field (밭 면적)
- GRDP : Gross Regional Domestic Product (지역 내 총생산)

Table 3 Region-Sensitivity Correlation Coefficient

Independent Variable	p-value	Correlation Coefficient
Farming Population	1.741e-35	0.3
Forest Area	8.014e-24	0.39
Empty House	6.814e-16	0.43
Ginseng Houses	2.982e-10	0.44
Rice Paddy	1.186e-18	0.4
Ranch Land	0.0002	0.39
Orchard	1.512e-11	0.61
Vinyl Greenhouse	0.0217	0.46
Field	4.418e-16	0.58
GRDP	1.495e-33	-0.11

지역 민감도의 경우 Table 4와 같이 제주특별자치도 서귀포시가 1로 가장 높은 민감도를 보이며 그다음은 제주시가 0.92로 높았다. 전라북

도 고창군의 경우가 0.41로 3위를 차지했으며 Table 5와 같이 서울특별시가 가장 낮은 수치를 보였다.

Table 4 Region-Sensitivity High Rank

Country	City	Region Sensitivity
Jeju-do	Seogwipo-si	1
Jeju-do	Jeju-si	0.92
Jeollabuk-do	Gochang-gun	0.41
Chungcheongbuk-do	Cheongju-si	0.39
Chungcheongnam-do	Geomsan-gun	0.35
Gyeongsangbuk-do	Andong-si	0.33
Jeollanam-do	Haenam-gun	0.32
Gyeonggi-do	Yangpeong-gun	0.31

Table 5 Region-Sensitivity Low Rank

Country	City	Region Sensitivity
Seoul	Jung-gu	0
Seoul	Gangnam-gu	0.01
Seoul	Jongro-gu	0.01
Seoul	Youngdengpo-gu	0.01
Seoul	Yongsan-gu	0.18
Seoul	Dongzak-gu	0.19
Seoul	Dobong-gu	0.02
Seoul	Gangseo-gu	0.02

2020년도 기준 서귀포시의 경우 농가 인구가 1만 7,995가구이며 제주시의 경우 1만 3,554가구가 있다. 기사에 따르면 제주도 주민의 경우 ‘땅이 없어서 농사를 짓지 못한다.’는 인터뷰 결과가 있을 정도로 대부분이 농업에 종사한다. 이에 반해 서울특별시 중구의 경우 농가 가구가 281로 농업에 종사하는 종사자 수가 적고, 비닐하우스나 과수원의 수가 적다. 또한 산림면적의 경우 제주시와 서귀포가 가장 넓고, 비닐하우스의 경우 서귀포시가 가장 많고 제주시는

5번째로 많았다.

특히, 음의 상관 계수인 GRDP의 경우 경기도 화성시, 서울특별시 강남구, 중구의 순으로 높게 나타났다. 또한, Fig. 2와 같이 도시화된 지역의 민감도가 낮았으며, 지역 민감도는 농업에 높은 양의 상관성을 보이기 때문에 Table 4와 Table 5과 같은 지역의 민감도 결과를 나타냈다.

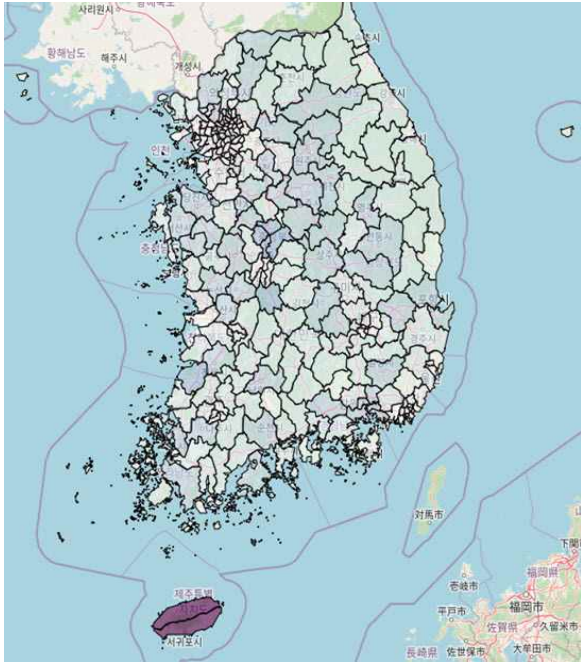


Fig. 2 Region-Sensitivity

2.2.3 교통민감도

교통 민감도의 경우 Table 6과 같이 시내버스 이용자 수, 버스회사 종사자 수, 화물회사 종사자 수, 자동차 등록 대수, 버스 추정 교통량, 승용차 추정 교통량, 교량 수, 지하차도 수가 상관계수가 높은 상위 8개의 결과로 도출되었다. (Eq.(3))

$$\begin{aligned}
 TS = & CU*0.29 + BW*0.55 + FW*0.3 \\
 & + NC*0.61 + EB*0.46 + EC*0.33 \\
 & + BG*0.26 + UP*0.38 \quad (3)
 \end{aligned}$$

TS : Traffic Sensitivity (교통민감도)
 CU : City Bus User (시내버스 이용자 수)
 BW : Bus Worker (버스회사 종사자 수)

FW : Freight Worker (화물회사 종사자 수)
 NC : The Number of Cars Registered (자동차 등록 대수)
 EB : Estimated Bus-Traffic (버스 추정 교통량)
 EC : Estimated Car-Traffic (승용차 추정 교통량)
 BG : Bridge (교량 수)
 UP : Underpass (지하차도 수)

교통 민감도의 경우 Table 7과 같이 인구밀도와 유동 인구가 많은 수도권 지역들이 민감도 지수가 높게 나왔다. 경기도 수원시의 교통 민감도가 1로 가장 높으며, 경기도 성남시 경상남도 창원시, 경기도 화성시, 고양시 등의 순으로 유동 인구나 인구밀도가 높은 지역의 민감도가 높게 도출되었다. 또한, Table 8과 같이 수도권 이터라도 인구밀도가 낮거나 다른 지역에 비해 도시화가 이루어지지 않은 인천광역시 옹진군, 경상북도 울릉군, 전라남도 진도군, 충청북도 증평군, 전라남도 신안군의 순으로 가장 낮은 수치를 보였다.

실제로 수원시의 경우 경부고속도로와 용인 서울고속도로, 영동고속도로, 평택-파주 고속도로가 지나며 서해안 고속도로와도 가까워 교통량이 많고 고속도로와의 접근성이 매우 좋아 교통량이 많고 시내버스 이용자 수와 화물회사 종

Table 6 Traffic-Sensitivity Correlation Coefficient

Independent Variable	p-value	Correlation Coefficient
City-Bus User	8.826e-35	0.29
Bus Worker	7.103e-33	0.55
Freight Worker	1.223e-26	0.3
The Number of Cars Registered	1.241e-20	0.61
Estimated Bus-Traffic	6.471e-18	0.46
Estimated Car-Traffic	8.122e-05	0.33
Bridge	5.841e-06	0.26
Underpass	3.859e-06	0.38

사자 수가 229개의 시·군·구 중 가장 많았다. 성남시는 성남대로를 따라 분당선이 지어질 정도로 성남대로의 이용량이 매우 많다. 성남대로는 오리역에서 가천대학교까지 성남시의 핵심지역을 이어주고 서울 방향으로도 이어져 있어 통행량이 많았다. 화성시는 6개의 고속도로와 2개의 고속화도로, 5개의 국도가 지나며 출퇴근 인구의 증가 대비 대중교통의 확충이 이루어지지 않아 문제가 되고 있고 그와 맞게 버스 교통량이 가장 많았다. 창원시의 경우 경상남도 중부의 중심도시라 지나가는 국도가 많으며, 4개의 고속도로가 위치하고 부산신항이 있어 화물차량들의 이용량이 많고 229개의 시군구 중 자동차 등록 대 수가 가장 많았다.

반면 교통 민감도가 낮은 인천광역시 옹진군의 경우 인천광역시에 포함되어 있지만 다른 인천광역시와 다르게 시내버스가 아닌 각 면에 있는 공영버스운영위원회에서 관리하는 공영버스가 다닌다. 27대의 공영버스가 있지만 그중 6대는 학교 방학 중엔 운행하지 않을 정도로 이동량이 많지 않으며 지하철도가 없고 교량이 4개로 교통 민감도 수치가 낮다. 경상북도 울릉군의 경우 해안 일주도로를 따라 운행하는 대중교통과 관광객들이 이용하는 전세버스가 주요 교통수단이며 옹진군과 마찬가지로 지하철도가 없고 화물회사가 없다. 전라남도 진도군은 섬이 많고 철도와 고속도로는 없으며 1개의 국도만 있어 교통량이 매우 적고 2015년에 국도가 2차

선에서 4차선으로 확장 개통되어 교통 체증이 줄었으며 세월호 사고로 인해 관광 수요도 많이 줄어 교통량이 적다. 충청북도 증평군의 경우 본토와 멀리 떨어져 있는 울릉군 다음으로 면적이 가장 작은 군으로, 충청북도에서 유일하게 타 시도와 겹치지 않는 지자체로 고속도로가 없고 시내버스 이용자 수가 수원시와 약 100배 차

Table 8 Traffic-Sensitivity Low Rank

Country	City	Traffic Sensitivity
Incheon	Ongjin-gun	0
Gyeongsangbuk-do	Ulleung-gun	0.001
Jeollanam-do	Jindo-gun	0.01
Chungcheongbuk-do	Jeungpyeong-gun	0.01
Jeollanam-do	Sinan-gun	0.01
Gangwon-do	Yanggu-gun	0.01
Jeollanam-do	Wando-gun	0.01
Gangwon-do	Hwacheon-gun	0.01

Table 7 Traffic-Sensitivity High Rank

Country	City	Traffic Sensitivity
Gyeonggi-do	Suwon-si	1
Gyeonggi-do	Seongnam-si	0.86
Gyeongsangnam-do	Changwon-si	0.79
Gyeonggi-do	Hwaseong-si	0.7
Gyeonggi-do	Goyang-si	0.69
Gyeonggi-do	Yongin-si	0.66
Chungcheongbuk-do	Cheongju-si	0.61
Seoul	Songpa-pu	0.58

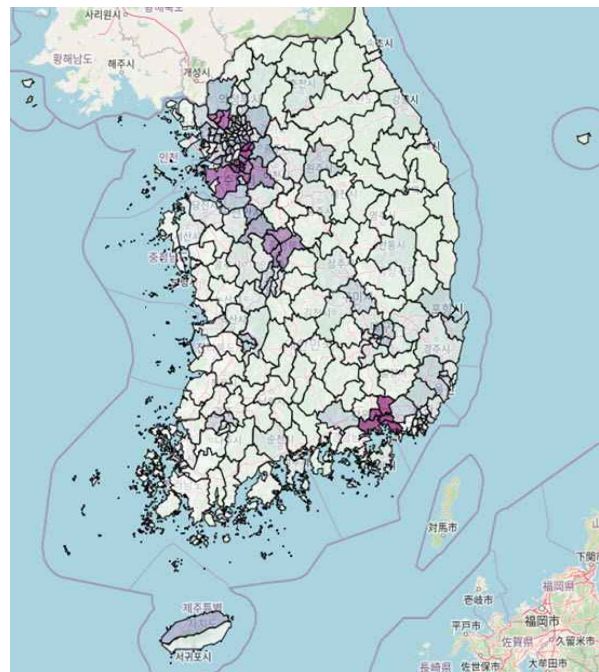


Fig. 3 Traffic-Sensitivity

이가 난다. 이러한 결과를 바탕으로 Fig. 3과 같이 유동 인구가 많고 인구 밀집 지역의 교통 민감도가 높게 도출되고 인구밀도가 낮고 도시화가 덜 이루어진 지역은 교통 민감도가 낮게 도출되었다는 것을 볼 수 있다.

2.2.4 대설민감도

대설민감도의 경우 지역 민감도와 교통 민감도를 더해 MinMaxScaler를 통해 0과 1 사이의 범위로 도출한 값을 의미한다.

2015년도부터 2020년도 사이의 적설에 의한 피해액과 눈에 의한 교통사고 관련 피해액을 비교했을 때 재해 연보 상의 적설 피해액은 약 1조 2천억 원, 교통에 관련된 눈에 의한 교통사고 피해액은 약 9천억 원으로 적설 피해액과 교통사고 피해액의 비율이 1:1로 비슷한 수준을 나타냈다. 따라서 대설민감도에 적설과 대설의 가중치를 1:1의 비율로 적용해서 대설민감도를 도출했으며, 대설민감도는 지역 민감도와 교통민감도 두 민감도의 특성을 다 담고 있어 적설과 교통에 모두 취약한 지역이 잘 나타난다.

Table 9과 Table 10의 민감도 결과를 보면 대설민감도는 제주특별자치도 제주시, 서귀포시, 경상남도 창원시, 경기도 수원시, 충청북도 청주시 등의 순으로 높게 도출되었고 경상북도 울릉군, 충청북도 계룡시, 인천광역시 옹진군, 동구, 충청북도 증평군의 순으로 낮게 도출되었다.

제주시와 서귀포시의 경우 관광객으로 인해

교통량도 많고 한라산이 있어 산림면적이 넓다. 또한, 호남지방통계청 2020년 호남·제주 농림어업총조사 현황 및 분석 결과에 따르면 전국에서 시군구 기준 농가 가구 수가 가장 많은 지역은 제주시라는 결과가 있다. 경상남도 창원시의 경우 지역 민감도가 229개 시군구 기준에서 13번째로 높고 교통 민감도도 2번째로 높아 대설민감도 또한 높은 결과를 보였다. Fig. 4는 대설민

Table 10 Heavy-Snow Low Rank

Country	City	Heavy-Snow Sensitivity
Gyeongsangbuk-do	Ulleung-gun	0
Chungcheongnam-do	Gyeryong-si	0.01
Incheon	Ongjin-gun	0.01
Incheon	Dong-gu	0.02
Chungcheongbuk-do	Jeungpyeong-gun	0.03
Gangwon-do	Sokcho-si	0.03
Gyeonggi-do	Dongducheon-si	0.04
Busan	Seo-gu	0.04

Table 9 Heavy-Snow High Rank

Country	City	Heavy-Snow Sensitivity
Jeju-do	Jeju-si	1
Jeju-do	Seogwipo-si	0.77
Gyeongsangnam-do	Changwon-si	0.75
Gyeonggi-do	Suwon-si	0.74
Chungcheongbuk-do	Cheongju-si	0.69
Gyeonggi-do	Goyang-si	0.63
Gyeonggi-do	Hwaseong-si	0.61
Gyeonggi-do	Seongnam-si	0.6

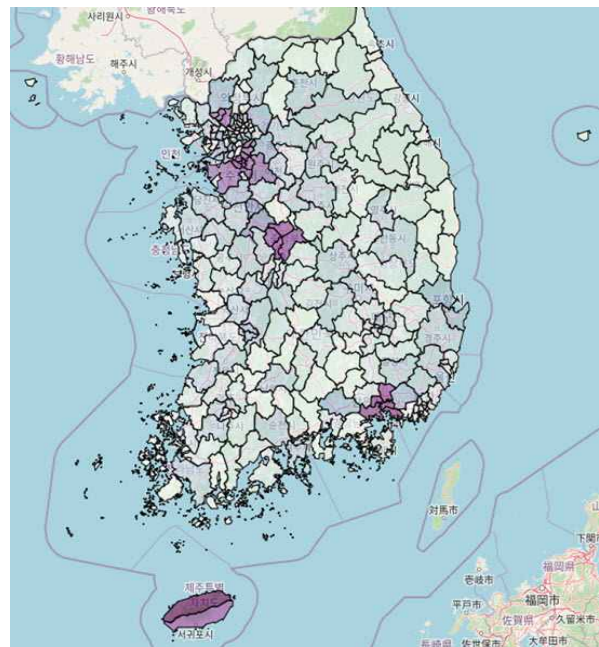


Fig. 4 Heavy-Snow Sensitivity

감도를 시각화한 결과로, 인접 지역이더라도 민감도가 다르고 어느 지역이 높은지 시각적으로 알 수 있다.

2.3 기상데이터 선정

현재 대설의 위험도의 기준을 기상청의 경보 기준에 따라 정하는 경우가 많다. 기상청에서는 24시간 신적설이 5cm 이상 예상될 때 대설주의보를, 20cm 이상 예상될 때 대설경보를 발령한다. 다만 산지는 신적설이 30cm 이상 예상될 때 대설경보를 발령한다. 그러나 신적설이 높더라도 기온에 따라, 습도에 따라 적설량이 달라지기 때문에 본 연구에서는 신적설이 아닌 적설을 기상 데이터로 선정했다. 습기를 머금은 눈인 습설의 경우 건조한 눈인 건설에 비해 단위 중량이 약 7배 더 크다는 연구 결과가 있으며, 눈의 결정이 별 모양에 가까울수록 무거운 함박눈 형태가 발생하는데 기온 영하 5℃ 이상 이거나 습도가 이상에서 나타난다.

본 연구에서는 이 결과를 기반으로 대설피해를 유발하는 기상 요소로 적설, 기온, 습도 자료를 선정하였다. 기상 데이터의 경우 기상청의 종관기상관측(ASOS, Automated Synoptic Observing System) 데이터를 이용하였고, 91개의 지점을 방재성능 목표에 따라 2015년부터 2020년까지의 대설피해 기간의 기상 데이터를 229개의 시·군·구의 기준에 맞추어 수집했다.

2.4 학습 데이터셋(레이블링)

위험도를 도출하기 위해 적설량에 따른 피해

액의 증감을 기준으로 대설민감도와 기상 데이터의 점수화를 진행했다. Fig. 5는 2018년도 기준 합천군의 적설량과 피해액 비교 그래프이다. 적설량이 5.3cm일 때 피해액이 약 9억 9천만 원이었고, 적설량이 5.5cm일 때 피해액이 약 10억 원이었다. Fig. 6은 거창군의 적설량과 피해액의 비교 결과로, 적설량이 1.07cm일 때 피해액이 약 7천만 원이었으며, 적설량이 9.3cm일 때 피해액이 약 6억 4천만 원으로 적설량이 약 9배 증가하면 피해액도 9배 증가하는 것을 확인할 수 있었다. 이 관계를 토대로 대설민감도와 기상 데이터의 비율을 1:1로 산정하고, Table 11과 같은 데이터 세트를 산출하였다. 학습 데이터 세트는 2015년도부터 2020년까지 재해 연보를 바탕으로 대설피해 기간의 기상 데이터를 수집해 총 60만 로우(row)로 구성하였다.

본 연구에서는 총 60만 개의 학습에 충분한

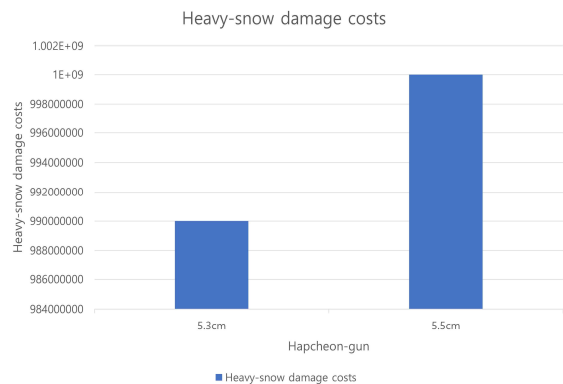


Fig. 5 Hapcheon-gun Heavy-Snow Damage Costs

Table 11 Training Data-Set

Country	City	Temperature	Humidity	Snowfall	Heavy-snow sensitivity	Hazard
Gyeongsangbuk-do	Ulleung-gun	-3.6	87	93.8	0	9
Jeollanam-do	Gochang-gun	-10.07	96	29.36	0.3	7
Chungcheongnam-do	Seocheon-gun	-11.4	90	25	0.11	6
Daejeon	Dong-gu	-12.42	87	12	0.14	3

데이터 세트를 보유하고 있어 학습의 속도 향상을 위하여 k-fold 기법을 사용하지 않고 60만 개의 Holdout Cross Validation을 적용하여 진행하였다. 일반적으로 1만 개 수준의 적은 데이터에서는 유의미한 테스트 데이터를 확보하기 위하여 학습데이터 수를 줄이고 6:2:2와 같은 비율로 머신러닝의 학습, 검증과 평가를 진행하였지만, 학습과 평가를 위한 데이터의 양이 충분한 경우는 다양한 패턴과 최대한 많은 데이터를 학습하고 파라미터를 최적화시키는 것이 중요하기 때문에 실제 학습에 사용하기 위한 훈련 데이터로 전체 데이터의 90%인 54만 개를 사용하였다. XGBoost 모델 성능 향상 및 모델 예측 검증 데이터(Validation Data)로 전체 데이터의 5%인 3만 개, 최종 결과 모델 평가를 위한 평가 데이터로 전체 데이터의 나머지 5%인 3만 개를 사용하여 진행하였다. 이때, 데이터 분할 시 종속변수인 위험도에 대하여 Stratify를 진행하여 학습, 검증, 테스트 진행 시 데이터의 편향이 이루어져 모델의 신뢰성이 떨어지지 않도록 진행하였다.

또한, 대설피해 유발인자로서 적설 하중에 기인하는 요인들에 관한 선행 연구에 따르면 습도가 높은 습설의 경우 낮은 건설에 비해 단위 중량이 약 7배 더 크고 눈의 유형이 달라져 적설 피해가 더 크고, 영상의 경우 눈이 녹을 수 있는 조건이 형성되어 적설에 영향을 끼친다는 결과가 있다. (Oh and Chung, 2017) 따라서 기온이 영상과 영하일 때를 구분하여 이전 대설민감도와 기상 데이터의 피해 비율 1:1 관계 중 비율적 계산의 용이성을 위하여 총 100점을 기준으로 대설민감도 50점, 기상 데이터 50점을 나누었고 습도가 높은 습설의 경우 건설에 비해 약 7배 중량이 크다는 연구 결과를 활용하여 습도 또한 위험도를 산정하는 기준으로 기상 데이터의 50점을 1:7의 비율로 나누어 반올림할 시 약 6:44의 비율로 나누어지는 값을 5단위로 스케일링을 진행하여 최종적으로 적설 45점, 습도 5점으로 레이블링을 진행하였다. 적설량의 따라 민감도와 습도의 점수를 조정하였고 그에 따라 위험도를 산정했다.

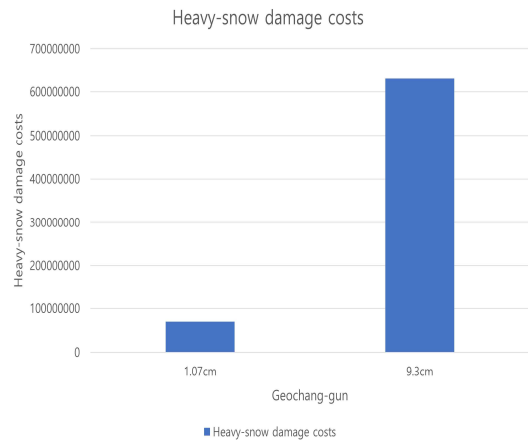


Fig. 6 Geochang-gun Heavy-Snow Damace costs

2.5 모델 학습

2.5.1 XGBoost를 활용한 모델 학습

XGBoost는 파라미터를 조절하면서 예측과 분류 성능이 좋은 최적의 모델을 개발할 수 있는 장점이 있다. XGBoost 모델의 학습 데이터 세트 독립 변수로 대설피해를 유발하는 기상 요소인 적설량, 기온, 습도 3가지 요소와 대설 피해액과 교통에 대한 간접 피해액의 상관분석 결과로 구한 지역 민감도와 교통 민감도를 더하고 MinMaxScaler를 통하여 0과 1 사이의 값을 가지는 229개 시·군·구별 고유한 대설 민감도 지수를 사용하였으며 이러한 독립변수들로 결정되는 종속변수로 독립변수들을 실제 발생 피해 규모와 레이블링하여 선정한 1과 10 사이의 위험도를 매칭시켜 데이터 세트를 구성하여 학습을 진행하였다. XGBoost 모델의 파라미터 중 booster는 gmtree를 사용해 트리를 기반으로 모델 학습을 진행했다. 모델의 정확성을 위해 과적합(Overfitting)이 발생하지 않도록 Grid Search 기법을 사용해 Table 12의 주요 하이퍼 파라미터의 최적값을 하였다. 특히 Grid Search를 적용 시 학습 진행에 따라 최적의 값을 결정하기 위한 국소 지점에 도달하지 못하는 경우를 방지하기 위하여 Gradient Boosting 방식의 모델에서는 Learning Rate를 조절하여 최적의 학습 Step을 결정하는데 모델 학습의 속도를 고려

한 Grid Search로 확인한 결과 Learning Rate의 최적값을 0.300000012로 도출하여 모델 손실을 최소화하는 국소 지점 도달이 가능하고 가장 최단 시간 학습이 가능하도록 모델에 적용했다.

Table 12 Parameter Set Value

Hyper Parameter	Set Value
Base_score	0.5
colsample_bylevel	1
max_depth	6
n_estimators	100
random_state	5488
tree_method	auto
use_label_encoder	True

Grid Search를 통해 결정된 최적의 하이퍼파라미터를 모델에 적용한 후 평가 데이터 세트를 활용해 모델을 평가하여 Table 13과 같은 성능을 측정했다. 성능 지표로 정밀도는 0.999, 재현율은 0.997, F1은 0.999, 그리고 정확도는 0.999의 높은 모델의 성능 지표를 확인했다.

Table 13 Xgboost Performance Indicator Result

Performance Indicator	Score
Precision	0.999
Recall	0.997
F1	0.999
Accuracy	0.999

2.6 위험도 도출에 따른 연구 결과

학습데이터에 사용하지 않은 기간의 데이터를 이용해서 모델 실증과 시각화를 진행했다. 먼저, 2016년 1월 25일 오전 9시의 위험도를 분석하였는데, 시베리아 고기압의 남하가 한반도 기후에 영향을 끼쳐 Fig. 7과 같이 광주광역시, 전라남도, 제주특별자치도에 기록적인 폭설이 내렸다. Table 14와 같이 전라북도 고창군과 정읍시의 경우 대설민감도가 각각 0.3, 0.24로 전라북도 도 내에서 가장 높고, 위험도 또한 8과 7로 높은 결과를 보였다. 또한, 울릉군의 경우

민감도가 0임에도 불구하고 적설량이 93.8cm로 위험도가 9로 매우 높게 나타났다.

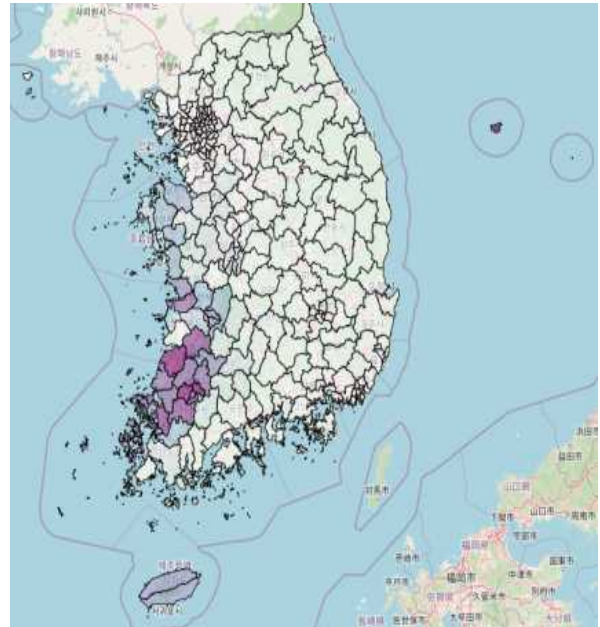


Fig. 7 Heavy-Snow Hazard (01-25-2016)

언론 매체에 따르면 울릉군은 주요 도로가 막혀 곳곳이 고립상태가 되었고 산간마을 주민들은 며칠째 집안에 갇혀있었으며, 불일을 보러 나갔던 주민 200명 이상이 울릉군에 돌아오지 못했다. 이틀 동안 공무원 350여 명과 제설차 5대를 동원해 제설작업을 진행했다. 포항시와 울릉군 사이의 여객선 운항이 8일째 결항되어 생필품을 공급하지 못했다. 울릉군의 경우 대설민감도가 0으로 229개 시·군·구 중 가장 낮은 수치이며 눈이 자주 오는 지역으로 대처가 빠르지만, 적설량이 많아 민감도와 상관없이 기상 상태에 맞게 위험도가 9의 결과를 나타냈다. 또한, 2016년 재해 연보에 따르면 2016년 1월 17일부터 1월 25일까지 전라북도는 약 65억 원, 전라남도는 약 50억 원, 경상북도는 약 5억 원 상당의 피해가 발생하며 피해 규모가 크다는 것을 알 수 있는데 본 연구에서 위험도도 8과 7의 높은 수준으로 도출되었다.

또한, 고창군과 정읍시의 경우 시가지 도로가 눈으로 뒤덮여 인도와 차도의 구분이 어려워 교통사고 발생 가능성이 높았고 간선도로들은 제

설 차량이 동원되어 눈을 치웠지만 통행하는 데 어려움이 많았다는 언론 보도가 있었다. 교통뿐만 아니라 적설에도 큰 피해가 있었는데 정읍시의 비닐하우스 4개의 동이 적설로 인해 주저앉았고, 고창군 공음면에서도 비닐하우스가 주저앉고 고창군수를 중심으로 700여 명의 전직원이 비상근무에 들어갈 정도로 피해가 컸다. 이렇듯 위험도가 7과 8 수준으로 도출되었을 때 피해 규모가 상당히 크다는 것을 알 수 있다.

Table 14 Gyeongsang, Jeollabuk-do Heavy-Snow Hazard (01-25-2016)

Country	City	Heavy-Snow Sensitivity	Hazard
Gyeongsangbuk-do	Ulleung-gun	0	9
Jeollabuk-do	Gochang-gun	0.3	8
Jeollabuk-do	Jeongeup-si	0.24	7

Fig. 8은 2018년 11월 24일 오전 10시 229개 지역의 위험도를 시각화한 결과이다. Table 15와 같이 서울특별시의 적설량이 8.8cm로 가장

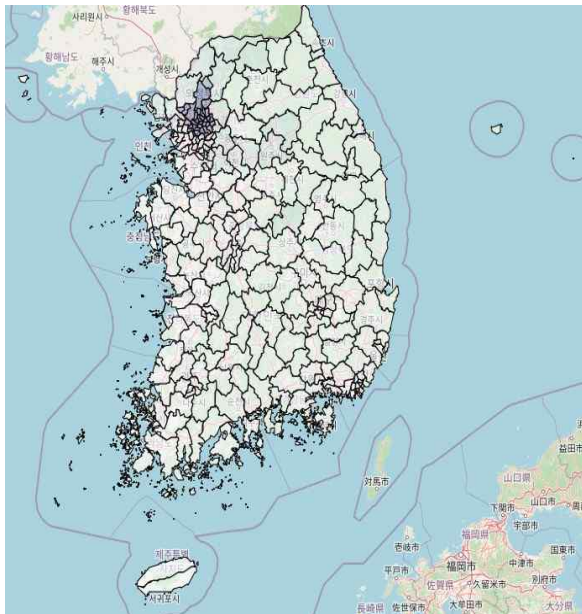


Fig. 8 Heavy-Snow Hazard (11-24-2018)

높았으며, 위험도 4의 결과를 보였다. 그러나 경기도 동두천시의 경우 적설량이 8.28cm였지만 민감도가 0.03으로 낮아 위험도가 3의 결과를 보이고 경기도 이천시의 경우 적설량이 7.84cm지만 민감도가 0.27로 위험도가 2로 도출되었다. 서울특별시의 경우 1990년 이후로 기록적인 폭설이었다. 서울특별시의 경우 적설에 의한 피해는 없었지만, 출퇴근 시간인 오전에 발생한 적설로 교통사고가 발생해 교통체증 현상이 일어났다.

Table 15 Seoul, Gyeonggido Heavy-Snow Hazard (11-24-2018)

Country	City	Heavy-Snow Sensitivity	Hazard
Seoul	Gangnam-gu	0.27	4
Seoul	Seocho-gu	0.34	4
Gyeonggido	Dongducheon-si	0.03	3
Gyeonggido	Icheon-si	0.27	2

55번 중앙고속도로 부산 방향 신림 부근에서 교통사고가 발생해 전면 차단해 차량 이동이 불가능한 상황이 발생했었다. 그러나 이천시의 경우 적설량이 서울특별시와 크게 차이 나지 않았지만, 위험도 결과도 2의 수준으로 도출되고 재해 연보 상에서도 이 기간에 피해액이 집계되지 않았으며 피해 기사를 검색했을 때 교통이나 적설의 피해가 있었다는 내용은 없었다. 서울특별시의 기록적인 폭설이었지만 눈이 3시간 동안 내리고 그쳐 재해 연보 상의 피해액이 집계되지 않아 직접적인 피해가 없었다는 것을 확인할 수 있었지만, 출퇴근 시간에 교통체증이 일어나고 위험도 또한 4로 도출되었다. Fig. 9와 같이 '본 연구의 취지에 맞게 지역 단위의 특성에 따라 그리고 일부 지역에만 발생하는 재난의 특징을 잘 반영했다'라고 판단되며 적설량이 비슷한 인접 지역이었지만 지역의 특성에 맞게 피해 유형과 정도가 다르다는 것을 알 수 있다.

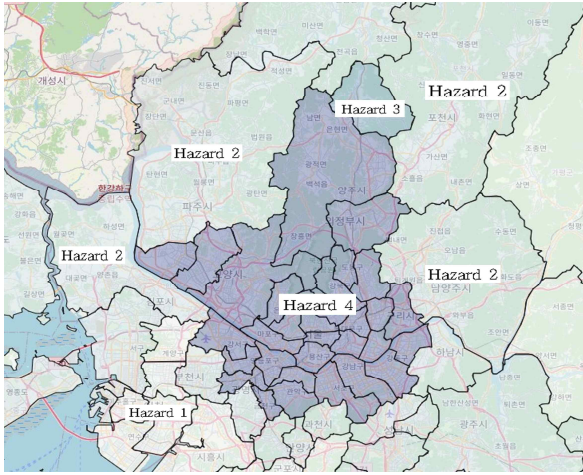


Fig. 9 Seoul, Gyeonggi-do Heavy-Snow Hazard (11-24-2018)

마지막으로 2015년 11월 26일의 위험도를 분석했다. Fig. 10와 같이 충청도에는 해당 기간동안 많은 적설량으로 인해 대설주의보가 발령되었다.

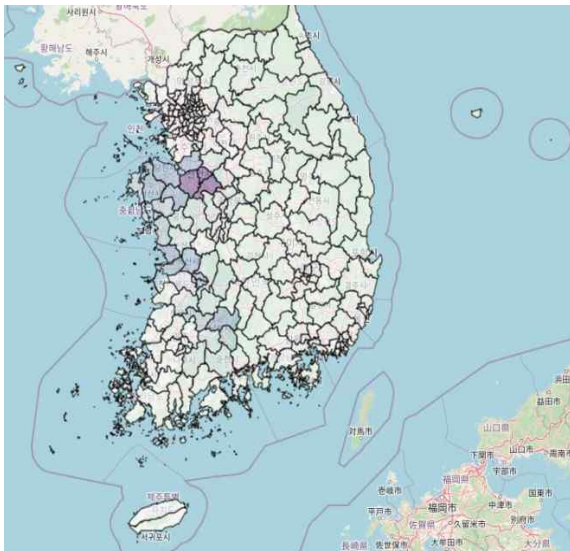


Fig. 10 Heavy-Snow Hazard (2015-11-26)

아산시의 경우 적설량이 17.5cm를 기록했으며 천안시는 16.05cm, 서천군은 20.34cm를 기록했다. 그러나 Table 16과 같이 천안시의 경우 세 지역 중 적설량이 제일 낮지만, 민감도가 0.5로 제일 높아 위험도가 6으로 도출되었으며 재해

연보 상의 해당 기간 피해액도 제일 높은 것을 확인하였다. 또한, 아산시의 경우는 서천군과 비교했을 때 대설민감도가 높아 적설량이 낮아도 피해액이 더 많이 발생했다. 이 분석을 통해 본 연구에서 대설민감도가 실제 피해와 밀접한 연관성이 있음을 알 수 있으며, 경제적인 피해액과 위험도가 유의미함을 확인했다.

Table 16 Chungcheongnam-do Heavy-Snow Hazard (11-26-2015)

City	Heavy-Snow Sensitivity	Hazard	Heavy-Snow Damage Costs
Asan-si	0.25	6	302,349
Cheonan-si	0.53	6	341,008
Seocheon-gun	0.11	4	269,341

3. 결론

본 연구는 대설에 의한 재해 연보 자료의 직접 피해 또는 교통에 의한 지역경제에 발생하는 간접피해에만 국한되어 진행된 선행 연구에서 대설에 의한 피해를 229개 시·군·구 지역별 대설 직접 피해로 세분화하여 도출한 지역 민감도와 대설과 교통에 의하여 발생하는 간접피해로 도출한 교통 민감도를 구하여 대설민감도라는 새로운 개념을 제안하였다는 것에 차별성을 지니고 있다. 따라서 대설에 의한 직접 및 간접의 통합된 피해로 지역별 특성에 따라 다른 위험을 예측하는 데 의의가 있다. 대설민감도와 적설량, 습도, 기온을 독립 변수로, 독립 변수에 따라 도출된 위험도를 종속변수로 선정하고 머신러닝(XGBoost)를 통해 대설피해 위험도 예측 모델을 생성했다. 본 연구의 타당성을 위해 2차례의 실증도 진행했다. 해당 기간의 재해 연보와 언론 보도를 통해 위험도를 분석해 연구의 타당성을 확인했다.

대설의 경우 전국에 걸쳐 발생하는 재난이

아닌, 제한적 지역에서 발생하는 만큼 위험도가 전국 발령이 아닌 시·군·구의 특성과 기상 상황에 따라 발령된다면 더욱 정확한 위기 발령으로 사전에 피해를 예방할 수 있으며, 기상 데이터의 예보를 통해 위험도를 예측할 수 있으며 선제 대응 또한 가능하다. 비닐하우스는 적설 피해가 없도록 걷어놓고 노후주택과 온실, 축사는 보강을 통해 지방자치단체에서는 제설 차량을 미리 준비할 수 있다. 또 도로나 집 앞의 눈을 치우고 염화칼슘이나 모래를 뿌려 재산 피해를 줄일 수 있다. 지하철이나 버스 등 대중교통의 경우 막차 연장 및 추가 배치와 신속한 제설작업을 통해 도로 혼잡도를 줄여 간접피해 또한 예방할 수 있다.

실시간으로 기상 데이터를 수집해 적용해야 하며 민감도의 경우 고정값으로 들어가기 때문에 매해 통계 자료가 나올 때마다 업데이트해야 하는 한계점이 있다. 향후 이 부분을 고도화한다면 더 정확한 대설피해 위험도 도출이 가능할 것이다.

References

- Cheon (2017). A study on changes of disaster area caused by heavy snowfall and classification of the disaster in South Korea. Thesis, Graduate School of Konkuk University. Seoul, Korea.
- Gyeongbuk Male. (2016). Snowbomb Ulleung Mountain Area, Still Isolated, <http://www.kbmaeil.com/news/articleView.html?idxno=374114> (Accessed on Jan. 27th, 2016)
- Ha. (2021). A Study on the Typhoon Damage Risk Level Prediction Model using Local Sensitivity, Graduate School of Seoul National University of Science and Technology. Seoul, Korea.
- Kim et al, (2015). Influence Factors Suggestion and Prediction Model Development of Regional Building Damage Costs according to Typhoon. *Journal of the Korea Institute of Building Construction*. <https://doi.org/10.5345/JKIBC.2015.15.5.515>
- Kim, et al, (2018). The Study for Damage Effect Factors of Heavy Snowfall Disasters : Focused on Heavy Snowfall Disasters during the Period of 2005 to 2014. *Journal of the Korea Academia-Industrial cooperation Society* Vol. 19, No. 2 pp. 125-136.
- Kwon, et al, (2016). Analysis of Snow Vulnerability and Adaptation Policy for Heavy Snow. *J. Korean Soc. Hazard Mitig.* Vol. 16, No. 2 (Apr. 2016), pp. 363~368.
- Lee & Chung (2018). Measures to Respond to the Cost of Traffic Congestion Caused by Heavy. Thesis, Graduate School of Hoseo University. Asan, Korea.
- Moon & Kim. (2018). Economic Loss Assessment caused by Heavy Snowfall, *Journal of Korea Planning Association*, 53(6), 117-130.
- News 1. (2016). "Will the nightmare of heavy snow 11 years ago come back to life?" Gochang-gun is nervous, <https://www.news1.kr/>, (Accessed on Jan. 24th, 2016)
- Oh. Y. R. (2017). Estimate of Snow Damage using Snow Damage Vulnerability Analysis in South Korea. Thesis, Graduate School of Hoseo University. Asan, Korea.
- Oh & Chung (2017). Estimation of Snow Damage and Proposal of Snow Damage Threshold based on Historical Disaster Data, *Journal of the Korea Society of Civil Engineers*, 37(2), 325-331.
- YTN (2018). The traffic jam... Accidents everywhere, <https://www.ytn.co.kr/>, (Accessed on Nov. 24th, 2018)



하 광 립 (KwangRim Ha)

- 정회원
- 서울과학기술대학교, 산업정보 시스템, 석사
- 성균관대학교, 전기전자컴퓨터공학, 학사

• 관심분야: 인공지능(딥러닝, 머신러닝), 빅데이터, 클라우드, 블록체인



정 용 철 (YongCheol Jung)

- 세명대학교, 컴퓨터학부, 학사
- 인천대학교, 임베디드시스템, 석사
- (현재) (주)씨에스리, 데이터엔지니어링팀, 책임연구원

• 관심분야: 인공지능(딥러닝, 머신러닝), 빅데이터, IoT system



유 진 영 (JinYoung Yoo)

- 명지전문대학, 정보통신공학과, 공학사
- (현재) (주)씨에스리, 데이터엔지니어링팀, 연구원

• 관심분야: 인공지능(딥러닝, 머신러닝), 빅데이터, 데이터마이닝



이 준 희 (JunHee Lee)

- 경운대학교, 항공소프트웨어공학과, 학사
- (현재) (주)씨에스리, 데이터엔지니어링팀, 연구원

• 관심분야: 인공지능(딥러닝, 머신러닝), 빅데이터