기계학습과 시스템 다이내믹스를 이용한 재난예측 및 대응정책효과 시뮬레이션: 경기도 단기가뭄을 사례로

Disaster Prediction and Policy Simulation for Evaluating Mitigation Effects Using Machine Learning and System Dynamics: Case Study of Seasonal Drought in Gyeonggi Province

박해경* · 이동근**

Park, Haekyung*, and Lee, Dongkun**

Abstract

Korea has had fewer droughts than floods; thus, its drought mitigation policies are insufficient. Typically, it takes a long time to confirm the effects of any policy and frequent revisions to a policy can cause social disruption. Therefore, a new method is needed, with which we can simulate policies in advance based on drought situation forecasts. This study deals with policy evaluation, using machine learning and system dynamics, by forecasting agricultural drought trends and simulating the effects of drought mitigation policies. The study area was the southern part of Gyeonggi Province. As a result, the soil moisture map predicted by machine learning for a time after three months of no rainfall clearly showed the resultant agricultural drought distribution. Also, the water price increase policy was simulated using system dynamics and found to be ineffective for drought mitigation because of insufficient water security measures.

Key words : Machine Learning, System Dynamics, Drought Prediction, Climate Changes Mitigation, Increasing Residential Water Price

요 지

우리나라는 홍수에 비해 가뭄에 대한 경험이 부족해 관련 정책이 미흡하다. 일반적으로 정책은 실행 후 효과가 확인되기까지 긴 시일이 걸릴 뿐만 아니라 빈번하게 수정되면 사회적 혼란이 야기되므로 이를 사전에 모의할 수 있는 새로운 방법이 필요하다. 본 연구는 기계학습과 시스템 다이내믹스를 이용하여 농업적 가뭄의 진행양상을 예측하고 이를 토대로 가상의 가뭄대응정책의 효과를 시뮬레이션 하는 전 과정을 다루었다. 연구 대상지는 경기도 남부이며, 연구 결과에 의하면 기계학습에 의해 예측된 3개월간의 가뭄 후의 토양 수분지도는 농업적 가뭄 분포 패턴을 보여 주었다. 그리고 이 지도로부터 확인된 가뭄위험지역과 동일 취수원을 사용하는 모든 지자체를 대상으로 시스템 다이내믹스를 이용하여 가상의 수도가격 인상정책을 모의하였더니 확보 가능한 수자원량이 미미하여 가뭄완화에 거의 실효성이 없는 것으로 나타났다.

핵심용어 : 머신러닝, 기계학습, 시스템 다이내믹스, 가뭄 예측, 기후변화 완화, 상수도 누진세

1. 서 론

수개월에 걸쳐 발생하는 단기 가뭄은 예측과 같은 미래적 정보가 중요하다. 가뭄피해가 이미 시작된 후에는 비가

내리는 것 외에는 특별한 대안이 없기 때문이다. 따라서 앞서 제공된 가뭄 정보는 수자원의 사전 확보와 신속한 분배를 위한 가뭄 대응계획 수립이 근거 자료가 되므로 가뭄 피해가 최소화 되도록 돕는다(Rhee and Im, 2017).

*정회원, 서울대학교 협동과정 조경학 박사과정(E-mail: yerri@snu.ac.kr)

Member, Ph. D. Student, Interdisciplinary Program in Landscape Architecture, Seoul National University

**교신저자, 서울대학교 조경·지역시스템공학부 교수(Tel: +82-2-880-4885, Fax: +82-2-875-2276, E-mail: dklee7@snu.ac.kr)

Corresponding Author, Professor, Department of Landscape Architecture and Rural System Engineering, Seoul National University

그러나 가뭄은 여러 요인에 의해 발생할 뿐만 아니라 가뭄 예측의 핵심인 강수량과 기온은 기간이 길어질수록 예측이 어려워 한달 이상 앞선 가뭄의 예측은 사실상 신뢰할만하지 못하다(NDMC, 2017).

이 가뭄의 예측을 더욱 어렵게 하는 것은 기후변화로 인한 이상기후이다. 우리나라의 경우에도 전형적인 가뭄 발생지역은 충청도 내륙지방이었으나 2014년 이후부터는 경기 남부지역도 점차 가뭄으로 인한 피해가 빈번해졌다. 이제 기후가 기존의 패턴에서 벗어나 점차 알수 없는 방향으로 변화하고 있어 홍수나 가뭄을 예측한다는 것이 더 이상 의미가 없어졌다(Kwon et al., 2016). 따라서 정확한 강수량의 예측보다는 대략적인 강수량 부족이 예측 될 때 오히려 가뭄 발생을 가정하여 경계-해제로 미리 대응 태세를 취하는 것이 현명한 방법일 것이다.

이러한 사고에 기반하여, 우리는 수개월 동안 비가 오지 않는다는 가정 하에 현재 데이터로 수개월 뒤 토양 수분의 공간적 분포를 앞서 예측하고 이 결과를 토대로 단기가뭄 대응대책을 세운다는 관점으로 연구를 진행하였다. 일반적으로 가뭄은 기상학적 가뭄, 수문학적 가뭄, 농업적 가뭄, 사회경제적 가뭄의 4가지로 구분하는데(Wilhite and Glantz, 1985), 본 연구는 토양 수분 손실 측면에서 접근하므로 농업적 가뭄 연구에 해당한다.

본 연구는 두개의 큰 틀로 구성되어 있는데, 첫 번째는 랜덤 포레스트 알고리즘(Random forest algorithm) 기반으로 농업적 가뭄을 기계학습시켜 비강우 기간 이후 나타날 지표의 토양수분의 변화 양상을 예측하는 것이고, 두 번째는 시스템다이내믹스(System Dynamics)를 이용하여 단기가뭄 대비 물 확보를 위한 대응정책을 모의(Simulation)함으로써 실효성을 평가하는 것이다.

랜덤 포레스트는 Breiman (2001)에 의해 창시된 분류와 회귀에 사용되는 대표적인 비선형 머신러닝 알고리즘 중 하나로 여러 결정트리들의 평균을 이용하므로 과대적합의 가능성이 적고 뛰어난 성능을 낸다고 알려져 있다. 그리고 큰 dataset에 적용 가능하므로 위성영상과 같은 공간데이터와 함께 이용되기에 적합할 뿐만 아니라, 특히 트리구조로 회귀모델을 생성하기 때문에 변수들 간의 범위나 단위를

조정할 필요가 없다는 강점이 있다.

시스템 다이내믹스는 1950년 중반 MIT에서 개발된 개념으로 정책 시뮬레이션에 유용하다. 독립변수와 종속변수가 여러 개라는 점이 구조방정식과 유사해 보이지만 구조방정식과 달리 시간, 순환(loop)의 개념을 포함하고 있어 시간에 따른 정책의 효과나 사람의 행태 등을 동태적으로 분석할 수 있다. 따라서 시스템 다이내믹스를 이용하면 미래 전망부터 정책의 파급효과까지 분석이 가능하여 군사, 정치, 사회, 경제, 환경 등 다양한 분야의 연구에 폭넓게 활용되고 있다(Kim et al., 2007).

본 연구는 다음과 같은 순서로 진행되었다. 우선 기계학습을 이용하여 3개월간의 비강우 지속시 예상되는 가뭄우심 지역을 추출하였다. 그리고 이 지역을 대상으로 시스템 다이내믹스를 이용하여 가뭄이 진행되는 3개월 동안 기존 수도요금 대비 3단계로 요금을 향상시켰을 경우 물사용 절감이 얼마나 이루어지는지, 그리고 이를 통해 수자원을 얼마나 확보하여 단기가뭄을 대비할 수 있는지 정책적 효과를 확인해 보았다.

2. 연구방법

2.1 연구지역

연구지역은 2010년 중반이후 기후변화로 인해 가뭄이 잦아진 경기도 남부지역으로 광주시, 군포시, 수원시, 시흥시, 안산시, 안성시, 오산시, 용인시, 의왕시, 이천시(일부), 평택시, 화성군 12개 시군이 대상이다(Fig. 1). 이 지역은 2015년부터 2017년까지 봄가뭄이 심각하여 3~7월간 강수량이 평년 50%에도 미치지 않아(Gyeonggi Province Statistics, 2017) 가뭄으로 인한 농업의 피해가 극심했던 지역 중 하나이다.

2.2 데이터

본 연구는 가뭄의 기계학습을 위해 30 m 해상도급의 위성 영상인 Landsat-8 이미지들과 지형공간정보 중 하나인 수치고도자료(Digital Elevation Model)를 데이터로 하였으며, 미국 지질조사국(U.S. Geological Survey)이 운영하는 사이트(Earth Explore)에서 무료로 제공하는 것을 이용하였다. 이

Fig. 1. Study Area

공간 자료들을 가공하기 위하여 사용된 Software는 ArcGIS Pro version이며, 기계학습은 Programming 언어인 Python 3.6.1 version을 이용하였다.

수도요금 인상 정책 시뮬레이션은 Software인 Vensim PLE version을 이용하였으며, 사용된 데이터는 우리나라 1인 물 사용량, 인구수, 가정용 수도요금으로, K-water에서 운영하는 사이트(My water, 2018)와 통계청(KOSIS, 2015) 그리고 각 지자체별 수도급수 조례를 참고하였다.

2.3 가뭄의 학습

우리는 기존 연구들에 근거하여 비강우 기간 동안에 토양수분의 손실과 유지에 영향을 주는 지표 환경요인을 식생 특성, 지형 특성, 열 특성, 물 환경 특성의 4가지 요소로 조작적 정의 하였다. 식생은 지표열의 증가를 더디게 함으로써 토양수분의 손실을 지연시키며(Sruthi and Mohammed Aslam, 2015), 지형 역시 토양수분의 중요한 결정 인자 중 하나로 알려져 있다(Radula et al., 2018). 특히 온도 상승은 토양수분의 소실을 유발해 농업적 가뭄의 위험을 높이는 가장 영향력이 있는 요소이다(UCS, 2018). 또한, 현재의 물 환경 상태는 가뭄이 시작될 때의 토양수분 초기값에 해당하므로 수개월 뒤 토양수분상태를 좌우하게 된다(Hao et al., 2018).

우리는 이 4개 범주에 해당하는 하위 요소를 구성하고 기계학습의 입력 변수(input variables)로 사용하기 위해 미국 지질조사국과 통합가뭄관리 프로그램(The Integrated Drought Management Programme, IDMP)에서 제공하는 자료에 근거하여(WMO and GWP, 2016) 위성영상과 수치표고모델과 같은 공간자료로 생성할 수 있는 하위요소 22개를 후보로 선정하였다. 그리고 1차적으로 기계학습을 실행하여 토양수분지수(Soil Moisture Index)에 회귀하지 않는 7개의 변수를 제거하여 Table 1과 같이 최종 15개를 선정하였다.

농업적 가뭄의 기계학습을 위해 선정된 이 15개의 입력 변수들은 2017년 3월 19일의 Landsat-8 영상과 수치표고모델을 이용하여 생성된 것이며, 약 3개월(97일) 뒤인 2017년 6월 23일의 Landsat-8 영상을 이용하여 산출된 토양수분지수는 기계학습의 출력 변수(output variable)로 사용되었다.

Table 1. Land Surface Factors and Input Variables

Land surface factors	Input Variables
Vegetation features	EVI, NDVI, SAVI, MSAVI
Topographic features	TWI, Slope, Aspect
Thermal features	NIR, SWIR ₁ , SWIR ₂ , TIRS ₁ , TIRS ₂
Water environment features	NDMI, MNDWI, MSI

가뭄의 학습은 연구지역 전체가 아닌 일부를 훈련지역(Training area)으로 선정하여 이루어졌는데, 다양한 토지피복을 포함하면서도 해당 기간 중 구름의 영향이 가장 적고, 인근의 기상측정지점의 자료를 모두 확인하여 분명하게 가뭄이 있었던 지역을 엄선하여 정사각형 형태로 추출하였다(Fig. 1). 훈련지역이 정사각형인 것은 중요하지 않으며, 다만 연구지역 전체를 훈련하지 않고 지역의 일부를 이용한 이유는, 훈련샘플이 많으면 학습 시간이 굉장히 길어질 뿐만 아니라 기상현상의 개입의 존재여부를 통제할 수 없기 때문에 가뭄 함수의 대표성이 보장될 수 없기 때문이다.

특히 기상현상 개입이 최소화 될수록 예측력이 좋은 가뭄 함수를 만들 수 있는데, 2015년 이후 이 훈련 지역의 강수량은 2017년에 최소였기 때문에 이 해의 가뭄을 학습시켰다.

가뭄의 기계학습은 총 62,500개의 샘플을 75%의 훈련 dataset (n = 46,875개)과 25%의 테스트 dataset (n = 15,625개)로 나누어 python scikit-learn library의 Random Forest Regression 함수를 이용하여 이루어졌다. 이렇게 기계학습된 가뭄은 가뭄함수 $f(x)$ 가 되어(Fig. 2) 농업적 가뭄의 분포를 예측하는데 이용된다.

2.3.1 기계학습의 입력 변수

전체 15개의 입력변수 중 식생 특성 요소에 해당하는 것은 총 4개로 Enhanced Vegetation Index (EVI), Normalized Difference Vegetation Index (NDVI), Soil Adjusted Vegetation Index (SAVI), Modified Soil Adjusted Vegetation Index (MSAVI)이며 다음과 같은 Eqs. (1), (2), (3) and (4)에 의해 계산되었다(Tucker, 1979; Huete, 1988; Qi et al., 1994;

Fig. 2. Process of Derivation of Drought Function

Huete et al., 2002; USGS, 2017). 수식들의 각 인수 중에서 *NIR*, *Red*, *Blue*는 Landsat-8영상의 파장대를 의미하는 것으로 각각 near infrared, red and blue wavelength를 말한다.

$$EVI = G \times \frac{NIR - Red}{NIR + C_1 \times Red - C_2 \times Blue + L} \quad (1)$$

G = gain factor

L = canopy background adjustment

C = coefficients for atmospheric resistance

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (2)$$

$$SAVI = \frac{NIR - Red}{NIR + Red + L} \times (1 + L) \quad (3)$$

L = brightness correction factor

$$MSAVI = \quad (4)$$

$$\frac{2 \times NIR + 1 - \sqrt{(2 \times NIR + 1)^2 - 8 \times (NIR - Red)}}{2}$$

지형 특성 요소는 Topographic Wetness Index (TWI), 경사 (slope), 향(aspect) 총 3개이며, 수치표고모델을 이용하여 계산되었다. 경사와 향은 ArcGIS의 내장기능을 이용하여 얻었고, TWI은 Eq. (5)의 수식으로 얻어졌다.

$$TWI = \ln \frac{\alpha}{\tan \beta} \quad (5)$$

α = upslope area per unit contour length (m)

β = slope expressed in radians

열 특성 요소는 적외선 파장대의 5개 영상으로 구성되어 있다. Landsat 8의 Operational Land Imager (OLI) 센서로 촬영된 *NIR*, Short-Wavelength Infrared band 1과 2(*SWIR₁*, *SWIR₂*), 지표면 열 감지 센서로 촬영된 Thermal Infrared Sensor band 1과 2 band (*TIRS₁*, *TIRS₂*)를 사용하였다(Landsat Science, 2018).

물 환경 특성 요소는 총 3개로 Normalized Difference Moisture Index (NDMI), Modification of Normalized Difference Water Index (MNDWI), Moisture Stress Index (MSI)를 이용하였다. 사용된 수식은 Eqs. (6), (7) and (8)과 같으며, 수식의 인수들 중 *Green*과 *MidIR*은 Landsat-8영상의 green and mid-infrared wavelength를 의미한다.

$$NDMI = \frac{NIR - SWIR_2}{NIR + SWIR_1} \quad (6)$$

$$MNDWI = \frac{Green - SWIR_1}{Green + SWIR_1} \quad (7)$$

$$MSI = \frac{MidIR}{NIR} \quad (8)$$

2.3.2 출력 변수

가뭄의 정의가 다른 것과 같이 가뭄을 나타내는 지수도 다양하며 나타내고자 하는 가뭄의 종류나 분석 목적에 따라 적합한 지수를 선택한다. 예를 들면 기상학적 가뭄은 비강우 기간으로 표현되는 Standardized Precipitation Index (SPI)와 같은 지수로 나타낸다면, 농업적 가뭄은 토양수분을 나타내는 Soil Moisture Index (SMI)를 사용해 표현된다. 우리는 농업적 가뭄 분포의 예측이 목표이므로, 앞선 입력 변수들이 토양수분지수로 회귀되도록 토양수분지수를 기계학습의 출력변수(output variables)로 하였다.

우리가 사용한 토양수분지수(SMI)의 계산 방식은 Sandholt et al. (2002)에 의해 고안된 것으로 본 연구를 위해 여러 토양수분지수를 검토하였을 때 봄계절의 단기가뭄을 예측 하기에 가장 적합했다. Van Leeuwen (2015)에 의하면, 이 토양수분지수처럼 중간 해상도의 지표 온도(LST)와 식생지 수(NDVI)를 기반으로 계산된 토양수분지수는 식생의 생육 기간의 토양수분을 나타내기에 적합하며 이것을 이용하면 가뭄에 대한 예보가 가능하다고 하였다. 본 연구에서 사용된 토양수분지수 산식은 Eq. (9)와 같으며, T_s 는 Weng et al. (2004)의 연구를 참고하여 계산하였다.

$$SMI = \frac{T_{s_{max}} - T_s}{T_{s_{max}} - T_{s_{min}}} \quad (9)$$

T_s = surface temperature and NDVI derived from remote sensing data

2.4 가뭄모델의 적용과 검증

우리는 기계학습으로 생성된 가뭄 함수를 이용하여 3월부터 3개월간 봄가뭄이 지속될 경우에 나타날 경기도 남부지역의 토양수분지수를 추정함으로써 농업적 가뭄의 분포를 예측하고자 하였다. 그래서 실제 가뭄이 있었던 2015년 3월 14일의 Landsat-8 영상과 수치표고모델을 이용하여 15개의 입력 변수를 생성하고 이것을 가뭄 함수에 적용하여 3개월 뒤인 2015년 6월 18일의 토양수분지수를 예측하였다.

예측된 토양수분지수로 매끄러운 농업적 가뭄분포지도 를 만들기 위하여 연구지역에 총 40만개의 점을 무작위로 생성하여 예측된 토양수분지수를 입력시켰다. 그리고 이 무작위 점들을 kriging 기법으로 내삽(interpolation)하여 3월 부터 3개월간 비가 오지 않을 경우 추정되는 최종 토양수분지 수 지도를 생성하였다.

예측된 토양수분지수의 검증은 2015년 7월 14일의 Landsat-8 영상을 이용하여 계산된 실제의 토양수분지수와 비교함으로써 정확도를 확인하였다. 다만, 2015년 6월 18일 의 영상을 이용해 검증되어야 했지만 해당 날짜의 영상에는 윤량이 많아 사용이 불가해 차선택으로 7월 영상을 이용하게 되었다.

연구의 맥락상 2017년 가뭄이 학습된 가뭄함수 $f(x)$ 를 이용해 2018년의 가뭄을 예측하면 더 자연스러웠겠지만, 실제로 2018년에는 가뭄이 존재하지 않았기 때문에 과거(2015년)의 가뭄을 검증자료로 사용하였다. 그러나 본 연구에서 의미하는 예측은 3월의 시점에서 6월을 예측하는 것이므로 년 단위의 전후관계는 중요하지 않다.

2.5 시스템 다이내믹스를 활용한 정책 시뮬레이션

2.5.1 가상의 정책수립

본 논문에서는 가뭄 기간 동안 일시적으로 수도요금을 인상하여 물 수요를 조절하고, 이를 통해 가뭄에 대비한 수자원을 확보 한다는 개념으로 가상의 가뭄 대응정책을 3단계로 세워보았다. 우선, 종전의 요금제를 Base 정책(1,028원)으로 하여 1단계는 기존요금대비 120%인상된 가격(1,234원)을 적용, 2단계는 140%인상(1,439원), 3단계는 160%인상(1,645원)을 적용하였다.

2.5.2 시뮬레이션 모형의 설계

정책의 시뮬레이션을 위해서는 변수들 간의 인과관계로 구성된 모델이 필요한데, 각 변수들은 누적될 수도 있으며 상수를 포함하기도 한다. 우리는 각 단계별 요금 인상에 따른 개인의 물 사용량의 변화와 이에 따른 수자원 확보량을 시뮬레이션하기 위해 1인 물 사용량(일), 1인 물 사용량(월), 수도요금을 변수로 하는 모델을 설계하였다. 가격변동에 의한 물사용량의 변화는 지방 상수도 생활용수 수요의 가격 탄력성 지수를 이용하여 계산하였는데, 우리나라는 -0.156에서 -0.189 사이의 값을 갖는다는 연구(Kim, 2018)를 참조하여 중간 값인 -0.175를 사용하였다.

이 모델을 이용하여 각 요금 단계별 6개월 간 개인 물 사용량 변화를 시뮬레이션 하였으며 실제 확인하고자 하는 기간은 가격인상이 시행되는 3개월이다. 우리는 이 모의 결과를 이용하여 가뭄대비 확보 가능한 지하채 전체의 수자원량을 총 인구수를 이용하여 계산하였다.

3. 연구결과

3.1 농업적 가뭄의 공간 분포 예측

가뭄함수 $f(x)$ 의 예측력을 산점도(X_{실제값}, Y_{예측값})로 확인한 결과는 Fig. 3(a)와 같다. 그리고 2015년 3월 14일 연구지역의 입력 변수를 $f(x)$ 에 대입하여 비 강우시 3개월 후의 토양수분지수를 예측하고 내삽하여 얻어진 최종 농업적 가뭄 예측지도는 Fig. 4이며 검증 결과는 Fig. 3(b)와 같다. 연구 결과에 의하면, 2015년 3월 14일 기준 3개월간 기상학적 가뭄이 지속되면 불투수 지역인 시가화 지역을 제외하고 이천, 수원, 광주, 인천, 평택 농경지 일대가 다른 지역에 비해 상대적으로 토양수분지수가 낮아 농업적 가뭄이 발생되는 것으로 예측되었다.

Fig. 3. (a) Performance of drought function and (b) validation

Fig. 4. Predicted Agricultural Drought Area (soil moisture map)

3.2 수도요금 조절정책 효과 시뮬레이션

토양수분지수 분포의 결과를 토대로 농업적 가뭄이 예상되는 5개 시군과 동일한 취수원(팔당3취수장, 이천 취수장, 충주 취수장, 광주용인공공취수장)을 사용하는 9개 시군(인천광역시, 수원시, 부천시, 시흥시, 군포시, 용인시, 이천시, 광주시, 평택시)(MyWater, 2018)을 대상으로 가뭄기간 동안 수도가격 인상을 실시할 경우에 변화되는 개인의 물 사용량을 시뮬레이션하였고, 이를 위해 설계한 모델은 Fig. 5이다.

Fig. 5. System Dynamics Model for Simulation

Fig. 6은 모델을 실행하여 얻은 수도요금 인상에 따른 개인 물 사용량의 변화 시뮬레이션 결과이다. 이 결과에 의하면, 1단계 요금은 개인의 물사용량의 변화가 없어 전혀 효과가 없는 것으로 나타났고 가장 비싼 3단계에서 약간 효과가 있는 듯 보이지만, 가시적인 효과는 3개월 이후부터 나타나 정책이 시행되고 물이 확보되어야 하는 3개월간은 그다지 큰 효과가 없는 것으로 나타났다.

Fig. 6. Changes in Individual Daily Water Usage

Table 2는 각 인상요율에 따라 지자체에서 확보 가능한 수자원의 총량을 표로 정리한 것이다. 결과에 의하면, 120% 인상 시 처음 1개월간은 확보되는 물이 전혀 없으며, 수도요금 인상 3개월까지도 확보되는 물의 양은 모든 정책에서 상당히 저조해 정책의 실효성은 없는 것으로 나타났다.

Table 2. The Amount of Secured Water for Local Government (unit: thousand liter)

Policy	1 month	2 month	3 month	Cumulative amount
Step 1	0	6,829	27,316	34,145
Step 2	6,829	20,487	47,804	75,120
Step 3	6,829	34,145	88,778	129,753

4. 토 의

4.1 머신러닝을 이용한 농업적 가뭄 패턴의 예측

본 연구를 통해 머신러닝과 위성영상 및 수치표고모델과 같은 공간자료를 이용하면 지표요소만으로도 단기 가뭄이후 나타날 토양수분의 공간패턴을 $R^2 = 0.58$ 로 예측함을 확인하였다. 이러한 예측이 가능했던 것은 예측의 불확실성을 높이는 기상요소를 제외하고 토양수분의 소실과 밀접하게 관련된 지표요소만을 변수로 사용하였기 때문이다. 가뭄이 발생하는 것은 강수의 유무이지만, 토양수분의 소실과 그 잔존량은 강수량이 결정하는 것이 아니라 현재의 물 환경상태, 지표온도, 식생의 유무 등과 같은 토지피복 상태 등에 따라 달라지는 것이므로 비강우를 가정하면 지표요소만으로도 농업적 가뭄의 발전패턴 예측이 가능했던 것이다.

두 번째는 가뭄의 학습에 big data를 처리할 수 있고 방대한 샘플 데이터를 기반으로 하는 좋은 성능의 알고리즘이 사용되었기 때문이다. 이 연구에서도 랜덤 포레스트 알고리즘은 약 100만개가 넘는 부동산 소수점 숫자 데이터를 한꺼번에 처리하여 빠르게 비선형 회귀모델을 만들어 내었다. 즉, 우리가 30 m 해상도급의 농업적 가뭄 지도를 생성할 수 있었던 것은 기계학습을 이용해 한번에 많은 공간정보 데이터를 사용할 수 있었기 때문이다.

우리나라에서 제공되는 가뭄 예보지도는 실질적으로 정책에 활용하기에 어렵다. Fig. 7(a)는 현재 우리나라에서 행정구역 단위로 집계(aggregation)되어 제공되는 농업적 가뭄(발토양 유효토양수분) 예보 자료로(KRC, 2017), 이를 토대로 대응전략을 수립하기에는 정보가 부족하다. 반면에 본 연구와 같이 30 m 해상도급의 격자단위로 예측되는 가뭄 예보는 Fig. 7(b)와 같이 공간분포를 상세하게 확인할 수 있어 지역적 차원에서 실질적인 가뭄대비를 용이하게 해준다. 우리는 이 지도와 토지피복도를 중첩함으로써 토양수분 지수가 상대적으로 낮았던 곳이 대부분 5개 시군 지역의 농경지임을 확인할 수 있었다.

Fig. 7. Comparing the Drought Forecasting Map in Administrative Units and Grid Units

본 연구와 같이 30 m 해상도급 가뭄 공간정보를 이용하면 구체적인 가뭄 위치 정보를 얻을 수 있어 해당 지역에 대해 물 확보 계획을 사전에 수립할 수 있다. 뿐만 아니라 가장 가까운 수자원(저수지나 지하수 등)의 정보도 함께 중첩하여 확인할 수 있으므로 다각도로 대응대책 수립이 가능하게 된다.

이와 관련하여 IPCC 5차 보고서에서는 유럽을 포함하여 각 국가별 기후변화 적응전략이 제대로 이행되지 않는 것은 광역적 단위에서 분석이 이루어지고 있기 때문이라고 지적하고 있으며, 이러한 단위의 분석결과는 광역적 측면에서 바라볼 때 의미있는 결과를 줄 수 있다고 말하고 있다(Barros et al., 2014). 따라서 그간의 가뭄 대응대책의 수립과 이행이 어려웠던 것은 분석 단위와 각 지자체에서 수립하고자 하는 계획 단위의 불일치 때문이라는 점을 시사한다.

따라서 본 연구와 같이 기계학습을 이용한 30 m 해상도급 공간정보로 제공되는 농업적 가뭄 예측자료는 기존의 행정 구역 단위로 제공되던 가뭄 정보에 비해 지역적 차원의 단기 대응대책을 수립을 가능하게 해줄 것이다. 기계학습은 이미 많은 연구들에 의하여 좋은 성능이 검증되어 왔으며, 여러 분야에서 좋은 결과를 내고 있어 앞으로도 다양한 재난재해 분석에도 다양한 활용 가능성이 높다.

4.2 시스템 다이내믹스를 이용한 대응정책 평가

본 연구를 통해 시스템 다이내믹스를 이용하면 인간의 행태와 시간의 변화에 따른 정책의 효과를 분석할 수 있어 가뭄 시 가격정책으로 물 수요를 조절하고자 할 때 정책의 효과가 언제부터 나타나는지, 그리고 수자원 확보량 등을 추정할 수 있었다. 그 결과, 일시적으로 수도요금을 조절하여 물을 확보하고자 하는 이 정책은 우리나라에서는 효과가 거의 없는 것으로 나타났다.

이것은 우리나라의 경우에 지방 상수도 생활용수 가격탄력성이 모두 비탄력적으로 나타나 가격정책을 통해 물수요를 관리하기 위해서는 상당히 높은 수준의 요금인상이 필요하다(Kim, 2018)라는 다른 연구 결과와도 일맥상통한다. 더불어, 이 연구에서는 우리나라의 경우에 물수요 조절을 위해서 높은 수준의 가격정책 이외에도 다른 비가격 정책들이 함께 이루어 져야 한다고 말하고 있다.

가정 내 물수요 조절을 위한 비가격 정책과 관련하여 Wichman (2017)은 수도요금 고지의 빈도를 높이는 것만으로도 수도 사용량을 줄일 수 있다고 하였으며, Grafton et al. (2011)도 가뭄시 물사용 절약 캠페인을 하는 것 만으로도 물절약을 가져올 수 있다고 하였다.

많은 나라들이 가뭄을 대비하여 물 수요를 조절하고자 많은 노력들을 하고 있고 우리나라도 예외일 수 없다. 물 수요는 42%가 가정에서 이루어지고 있으므로 가뭄 회복력을 위하여 수도 비용은 조절되어야 한다(PPIC Water Policy Center, 2016).

다만, 가정 내 물수요 조절 방법에 대해서 수도요금을 이용한 물 소비 조절이 효과적이지 않다는 연구(Owen, 2017)

도 있는 반면, 효과적이라는 연구(McDonnell and Lochlainn, 2013)도 있다. 또는 가격정책이 전혀 효과가 없는 것은 아니며 가격이 물수요의 절감을 가져오며 단기간에만 효과가 있다(Nataraj, 2007)는 중립적인 연구도 있다.

이와 같이 연구마다 상반된 결과가 나타나는 것은 나라마다 물수요 가격탄력성 각기 다르고 물사용이나 수도요금에 대한 정서적 차이, 혹은 국가별 상황이나 보유 수자원 상태가 각기 다르기 때문이다. 예를 들면, 우리나라에서 2016년에 가뭄 할증요금 관련 연구 용역이 국감에서 지적된 바 있는데(Seo, 2016), 이는 우리나라의 수도요금이 다른 국가 대비 저렴함에도 불구하고(Grafton et al., 2011) 우리나라는 수도요금 인상에 대해 거부감이 상당하다는 증거이기도 하다.

따라서 무조건적으로 선진국의 사례를 따라서 혹은 가격정책만으로 물 수요를 조절해야한다는 논리를 앞세우기 보다는, 우리나라의 실정에 맞는 가뭄 대응을 위한 물수요 조절정책을 구축해 나가야 할 것이다. 이를 위해서는 시스템 다이내믹스와 같은 방법을 이용하여 사전에 가상으로 정책을 시행하고 수정을 반복함으로써 실효성을 거둘 수 있는 정책을 만들어 나가는 노력을 해야 한다(Fig. 8).

Fig. 8. Concept of Machine Learning and System Dynamics Use for Policy Simulation

특히, 우리나라의 경우에는 Fig. 5와 같이 가격 요소만으로 구성된 모델을 비가격 요소를 포함한 모델로 확장하여 시뮬레이션을 함으로써 가뭄 완화를 위한 우리나라에 적합한 정책을 만들어 나가야 한다. 뿐만 아니라, 수도 요금의 상승에 민감한 우리나라의 정서를 고려할 때 이러한 분석의 결과를 근거로 국민적 합의를 이끌어 나가는 방식을 취해야 한다.

5. 결 론

이상기후로 인한 강우의 불균형현상으로 예기치 않은 가뭄과 홍수가 반복되고 있어 우리나라도 이제 더 이상 기후

변화로부터 안전하지 않다. 우리나라의 적은 가뭄경험으로 인하여 관련 대응정책은 여전히 부족한 실정이다. 우리는 이러한 문제를 해소하기 위하여 앞으로 수립해야 하는 가뭄 완화 정책의 시행착오를 줄이고 효과를 사전에 확인하기 위한 방법으로 기계학습과 시스템 다이내믹스의 복합적 사용을 제안하고 경기도 남부지역의 단기 가뭄을 사례로 분석을 진행하였다.

그 결과, big data와 자연계의 비선형 회귀의 처리가 가능한 기계학습은 3개월 후의 농업적 가뭄의 공간분포를 나타내 주었다. 그리고 이 예측 결과로 확인된 가뭄 우심지역을 대상으로 시스템 다이내믹스를 이용해 가상의 수도요금 인상 정책을 시뮬레이션한 결과, 가격에 의한 상수도 조절 정책은 가뭄완화에 그다지 효과적이지 않다는 것을 확인할 수 있었다. 기계학습과 시스템 다이내믹스의 조합은 가뭄뿐만 아니라 기후 변화로 인해 발생하는 다양한 재난재해의 예측과 관련 완화정책 수립을 위하여 활용 가능성이 높다.

감사의 글

본 논문은 행정안전부가 주최한 「2018년 대학(원)생 재난 안전 논문 공모전」에서 수상작으로 선정된 논문입니다. 많은 도움을 주신 방재학회장님과 관계자분들에게 깊은 감사의 말씀을 드립니다.

References

- Barros, V.R., Field, C.B., Dokke, D.J., Mastrandrea, M.D., Mach, K.J., Bilir, T.E., et al. (2014). *Climate change 2014: Impacts, adaptation, and vulnerability - Part B: Regional aspects*. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change, Cambridge University Press.
- Breiman, L. (2001). Random forests. *Machine Learning*, Vol. 45, No. 1, pp. 5-32.
- Earth Explorer. Retrieved May 11, 2018, from <https://earthexplorer.usgs.gov>
- Grafton, R.Q., Ward, M.B., To, H., and Kompas, T. (2011). Determinants of residential water consumption: Evidence and analysis from a 10-country household survey. *Water Resources Research*, Vol. 47, No. 8, W08537.
- Gyeonggi Province Statistics. (2017). Retrieved from <https://stat.gg.go.kr>
- Hao, Z., Singh, V.P., and Xia, Y. (2018). Seasonal drought prediction: Advances, challenges, and future prospects. *Reviews of Geophysics*, Vol. 56, No. 1, pp. 108-141.
- Huete, A. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, Vol. 25, No. 3, pp. 295-309.
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., and Ferreira, L.G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, Vol. 83, No. 1-2, pp. 195-213.
- Kim, H. (2018). Estimating price elasticity of residential water demand in Korea using panel quantile model. *Environmental and Resource Economics Review*, Vol. 27, No. 1, pp. 195-214.
- Kim, Y.P., Han, S.H., Kim, M.J., and Kim, H.J. (2007). *Development of simulation system for financial investment impact assessment and set-up of national development index (I)*. Korea Research Institute for Human Settlements.
- Korea Rural Community Corporation (KRC). (2017). Agricultural Drought Management System (ADMS). Retrieved from <http://adms.ekr.or.kr/>
- Korean Statistical Information Service (KOSIS). (2015). Retrieved from <http://kosis.kr>
- Kwon, H.D., Kim, J.R., Kim, J.I., Kim, J.Y., Sa, D.H., Yoo, S.H., et al. (2016). *Water & climate change*. Seoul: Pieona.
- Landsat Science. (2018). Thermal Infrared Sensor (TIRS). Retrieved from <https://landsat.gsfc.nasa.gov/>
- McDonnell, T., and Lochlainn, A.N. (2013). *Paying for water: Equity, efficiency and sustainability*. Think-tank for Action on Social Change (TASC), Dublin, Ireland.
- My Water. (2018). Retrieved from <https://www.water.or.kr>
- Nataraj, S. (2007). Do residential water consumers react to price increases? Evidence from a natural experiment in Santa Cruz. University of California Giannini Foundation of Agricultural Economics, *Agricultural and Resource Economics Update*, Vol. 10, No. 3, pp. 9-11.
- National Drought Mitigation Center (NDMC). (2017). *Predicting drought*. Retrieved January 19, 2018, from <http://drought.unl.edu>
- Owen, D. (2017). Water and taxes. *U.C. Davis Law Review*, Vol. 50, pp. 1559-1617.
- Public Policy Institute of California (PPIC) Water Policy Center. (2016). *California's water*. Retrieved from <https://www.ppic.org/publication/>
- Qi, J., Chehbouni, A., Huete, A.R., Kerr, Y.H., and

- Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, Vol. 48, No. 2, pp. 119-126.
- Raduła, M.W., Szymura, T.H., and Szymura, M. (2018). Topographic wetness index explains soil moisture better than bioindication with Ellenberg's indicator values. *Ecological Indicators*, Vol. 85, pp. 172-179.
- Rhee, J., and Im, J. (2017). Meteorological drought forecasting for ungauged areas based on machine learning: Using long-range climate forecast and remote sensing data. *Agricultural and Forest Meteorology*, Vol. 237-238, pp. 105-122.
- Sandholt, I., Rasmussen, K., and Andersen, J. (2002). A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. *Remote Sensing of Environment*, Vol. 79, No. 2-3, pp. 213-224.
- Seo, S.K. (2016). K-Water tried to raise water tax during drought (September 30, 2016). *News1 News*. Retrieved from <http://news1.kr/articles/?2788956>
- Sruthi, S., and Mohammed Aslam, M.A. (2015). Agricultural drought analysis using the NDVI and land surface temperature data; A case study of Raichur District. *Aquatic Procedia*, Vol. 4(Icwrcoe), pp. 1258-1264.
- Statistics Korea, Retrieved from <http://kostat.go.kr>
- Tucker, C.J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, Vol. 8, No. 2, pp. 127-150.
- U.S. Geological Survey (USGS). (2017). *Product guide: Landsat surface reflectance-derived spectral indices*.
- Union of Concerned Scientists (UCS). (2018). *Causes of drought: What's the climate connection?*.
- Van Leeuwen, B. (2015). GIS workflow for continuous soil moisture estimation based on medium resolution satellite data. *18th AGILE International Conference on Geographic Information Science*, Lisbon, Portugal.
- Weng, Q., Lu, D., and Schubring, J. (2004). Estimation of land surface temperature-vegetation abundance relationship for urban heat island studies. *Remote Sensing of Environment*, Vol. 89, No. 4, pp. 467-483.
- Wichman, C.J. (2017). Enduring effects of changes in billing frequency: Evidence from urban water use. *2017 ASSA Conference*, Allied Social Science Associations.
- Wilhite, D., and Glantz, M. (1985). Understanding: the drought phenomenon: The role of definitions. *Water International*, Vol. 10, No. 3, pp. 111-120.
- World Meteorological Organization (WMO) and Global Water Partnership (GWP). (2016). *Handbook of drought indicators and indices*. Integrated Drought Management Programme (IDMP), Integrated Drought Management Tools and Guidelines Series 2. Geneva.

Received	■ August 31, 2018
Revised	■ October 27, 2018
Accepted	■ November 27, 2018