

원격탐사 및 기후자료를 이용한 아태지역 가뭄예측모델 개발: 인도네시아를 중심으로

Development of a drought forecasting model for the Asia-Pacific region using
remote sensing and climate data: Focusing on Indonesia

이진영

원격탐사 및 기후자료를 이용한 아태지역 가뭄예측모델 개발: 인도네시아를 중심으로

Development of a drought forecasting model for the Asia-Pacific region using remote sensing and climate data: Focusing on Indonesia

이진영

발간사

아시아 태평양 지역은 가뭄, 태풍, 홍수, 산사태 등 다양한 자연 재난이 빈번하게 발생하는 곳으로 이러한 재난을 예방하고 감소시키기 위해 많은 노력이 요구됩니다. 적절한 재난 관리와 재난 리스크 저감을 위해서는 특히 재난의 감시 및 예측이 중요한데, 본 APEC기후센터에서는 가뭄 재난의 감시와 예측을 위한 연구를 수 년 간 수행하여 재난 리스크 저감 기술 개발에 힘써 왔습니다. 주로 국내를 대상으로 위성 영상 자료를 이용하여 관측 자료가 없는 지역에 대해 가뭄 상태를 감시할 수 있도록 하고 여기에 장기 기후 예측 모델 자료를 결합, 기계 학습 기법을 적용하여 가뭄 상태를 예측할 수 있는 기술을 개발하였습니다.

본 연구보고서 「원격탐사 및 기후자료를 이용한 아태지역 가뭄예측모델 개발: 인도네시아를 중심으로」는 아시아 태평양 지역 국가들의 사회·경제적 발전과 번영에 기여하고자 하는 APEC기후센터의 노력의 일환으로, 국내를 대상으로 개발된 기술을 개선하고 아시아 태평양 지역에 적용하여 해당 지역의 재난 저감을 위해 노력하고자 기획되었습니다. 국내에 대해 수행한 그간의 연구와 더불어 본 연구보고서에서 다룬 인도네시아 연구를 시작으로 대상 지역을 확장하여 앞으로 아시아 태평양 지역의 국가들의 가뭄 재난 리스크 저감에 기여할 수 있을 것으로 기대합니다.

본 연구보고서가 발간되기까지 많은 분들의 도움이 있었습니다. 자문위원으로서 아낌없는 조언과 격려를 해주신 서울대학교 최지용 교수와 부산대학교

신현석 교수, 그리고 보고서의 수준을 제고하도록 좋은 논평을 해주신 익명의 검토자들에게 깊은 감사를 표합니다. 연구를 수행한 본원의 이진영 박사와 김가영 연구원에게도 감사의 뜻을 전합니다.

2017년 1월
APEC 기후센터
원장 정 홍 상

ABSTRACT

Three regions of Indonesia with different rainfall characteristics were chosen to develop drought forecast models based on machine learning. The 6-month Standardized Precipitation Index was selected as the target variable. The models' forecast skills were compared to the skills of long-range climate forecast models in terms of drought accuracy and regression-based Mean Absolute Error (MAE).

Indonesian droughts are known to be related to El Nino Southern Oscillation (ENSO) variability despite regional differences, as well as related to monsoon, local Sea Surface Temperature (SST), other large-scale atmosphere-ocean interactions (such as the Indian Ocean Dipole and Southern Pacific Convergence Zone), and local factors including topography and elevation. Machine learning models were thus utilized to enhance drought forecast skill by combining local and remote SST and remote sensing information, reflecting initial drought conditions to the long-range climate forecast model results.

A total of 126 machine learning models were developed and six long-range climate forecast models (MSC_CanCM3, MSC_CanCM4, NCEP, NASA, PNU, POAMA) with 1 to 6-month lead times, as well as one climatology model based on remote sensing precipitation data were used for the three regions of West Java, West Sumatra, and Gorontalo.

When comparing the results of the machine learning models and long-range climate forecast models, the West Java and Gorontalo regions showed similar characteristics in terms of drought accuracy. Drought accuracy of the long-range climate forecast models were generally higher than the machine learning models

with short lead times, but the opposite occurred for longer lead times. For West Sumatra, however, the machine learning models and the long-range climate forecast models showed similar drought accuracy. The machine learning models showed smaller regression errors for all three regions, especially with longer lead times.

Among the three regions, the machine learning models developed for the Gorontalo region showed the highest drought accuracy and the lowest regression error. The West Java region showed higher drought accuracy compared to the West Sumatra region, while West Sumatra showed lower regression error compared to West Java. The lower error in the West Sumatra region may be due to the smaller sample size used for training and evaluation for the region. Regional differences in forecast skill are determined by the effect of ENSO and the following forecast skill of the long-range climate forecast models.

Relative importance of input variables of the machine learning models were evaluated for each region. In all cases, the importance of the SPI6 forecast (SPI6 FCST) was the highest, especially with short lead times. For West Java, month (MONTH) and the SST forecast of the Nino3 region (NINO3_SST FCST) showed higher importance. For West Sumatra, locational information including latitude (LAT) and longitude (LON) has higher importance, probably due to the shape of the region. For Gorontalo, the importance of SST forecast in SPCZ (SPCZ_SST FCST) was more obvious compared to West Java. While somewhat high in West Sumatra, the relative importance of remote sensing variables were generally low in most cases. High importance of the variables based on long-range climate forecast models indicates that the forecast skill of the machine learning models are mostly determined by the forecast skill of the climate models.

A case study was performed for West Java. Drought forecast results for drought events during 2003–2015 based on the NASA model, indicate that the long-range forecast models tend to underestimate drought severity, while the machine learning

models tend to forecast drought to a narrower range of drought index values. It may be solved by testing the design of machine learning model training.

If given information on drought occurrences in advance, loss and damages due to drought can be reduced by securing resources and planning its efficient allocation. In order to prevent and reduce drought risk, nonstructural measures such as the development of a drought monitoring and forecasting system is essential. Through this study, forecast skill of meteorological drought in Indonesia can be improved. The drought forecast models developed in this study can help to reduce drought disaster risk.

요약본

연구 목적

본 연구의 목적은 국내를 대상으로 개발된 가뭄예측 기술을 기반으로 인도네시아의 가뭄 특성을 반영하여 인도네시아에 적합한 가뭄예측 모델을 개발하는 것이다. 상이한 강우 특성을 가지는 인도네시아의 세 지역을 선정하여 각 지역에 대해 기계학습을 기반으로 한 가뭄예측 모델을 개발하였다.

연구 절차

기상학적 가뭄지수인 6개월 시간 스케일의 표준강수지수(SPI6)를 목표 변수로 설정하여 이의 예측 성능을 가뭄 정확도와 회귀 오차의 측면에서 장기기후예측 모델 예측 값을 그대로 사용한 경우를 기준 값으로 삼아 비교하였다. 인도네시아의 가뭄 발생은 지역적 차이는 있지만 ENSO의 변동과 깊은 관련이 있으며 몬순, 국지적인 SST, IOD, SPCZ 등 해양과 대기의 상호작용 뿐 아니라 지형 및 고도 등의 지역적인 요인의 영향도 크게 받는다. 따라서 기계학습 모델의 입력 변수로 장기기후예측 모델의 예측 값 뿐 아니라 국지 및 원격 SST, 가뭄의 초기 조건을 나타내는 원격 탐사 정보 등을 포함시켜 가뭄예측의 성능을 높이하고자 하였다.

서부 자바, 서부 수마트라, 고론탈로의 세 지역을 대상으로 MSC_CanCM3, MSC_CanCM4, NCEP, NASA, PNU, POAMA의 6개 장기기후예측 모델과 위성 기반의 강우 합성장을 활용하여 과거 기후 값을 구한 CLIM을 포함한 7개

모델, 그리고 1-6개월의 예측 선행시간에 대해 총 126개의 기계학습 모델을 구축하였다.

연구 결과

가뭄 정확도에 있어서 서부 자바와 고론탈로 지역은 선행시간별로 기계학습과 장기기후예측 결과를 비교한 결과 비슷한 양상을 보였는데, 선행시간이 1개월 정도로 짧은 경우는 장기기후예측 결과를 그대로 이용한 경우의 가뭄 정확도가 높았으나 대부분의 좀 더 긴 선행시간의 경우 기계학습을 적용한 경우의 가뭄 정확도가 높았다. 반면 서부 수마트라 지역은 다른 두 지역과는 다르게 대부분의 경우 장기기후예측 결과를 이용한 경우와 기계학습 모델을 적용한 경우 사이의 우열을 가리기 어려웠다. 회귀 오차의 경우는 세 지역 모두에서 특히 선행시간이 길어질수록 기계학습 모델을 적용한 경우가 장기기후예측 모델 결과를 그대로 이용한 것보다 낮은 오차를 보였다.

지역별 차이를 분석하면 고론탈로 지역의 기계학습 모델이 가뭄 정확도와 회귀 오차의 측면에서 가뭄예측 성능이 가장 우수하였다. 다른 두 지역에서는 모든 선행시간에서 가뭄 정확도는 서부 자바 지역에서 높게 나타났지만 회귀 오차에 있어서는 서부 수마트라 지역의 오차 값이 작게 나타났는데 이는 모델의 구축 및 성능 평가에 이용한 표본 수의 차이 때문인 것으로 보인다. 가뭄예측 성능의 지역별 차이는 각 지역이 ENSO에 영향을 받는 정도와 이로 인해 장기기후예측의 예측 성능이 달라지는 정도와 관련이 있다.

지역별 기계학습 모델의 입력 변수별 상대적 중요도를 평가하였는데, 모든 경우 특히 선행시간이 짧은 경우 개별 모델의 SPI6 예측 값의 중요도가 가장 높았다. 서부 자바 지역에서는 이어서 월(MONTH), NINO3 지역의 SST 예측 값(NINO3_SST FCST)의 중요도가 높았으며 서부 수마트라 지역에서는 위도

(LAT), 경도(LON) 등 지역의 위치적인 정보가 중요한 것으로 드러났다. 이는 해당 지역의 형태와 관련이 있는 것으로 보인다. 고론탈로 지역에서는 서부 자바 지역과 변수의 상대적 중요도가 유사하게 나타나나 SPCZ 지역 SST 예측 값의 중요도가 좀 더 부각된다. 서부 수마트라 지역에서 일부 비교적 높게 나타나기는 하지만 원격 탐사한 지표면온도, 식생지수, 토양수분 등의 가뭄 상태 초기 값의 중요도는 대부분의 경우 상대적으로 낮았다. 장기기후예측 자료를 이용한 입력 변수의 중요도가 높게 나타나는 것은 기계학습을 적용하더라도 기후모델의 예측 성능이 높아야 기계학습 모델의 예측 성능도 높아짐을 뜻한다.

서부 자바 지역에 대해 사례분석을 통해 장기기후예측 모델과 이 결과를 기계학습 모델에 적용한 결과를 비교하여 보았는데, 특히 NASA 모델을 이용하여 2003년에서 2015년 가뭄 사상에 대해 예측한 결과를 보면 장기기후예측 모델 결과를 바로 적용한 경우 가뭄 사상을 과소 추정하며 기계학습 모델을 적용한 경우 가뭄 발생의 폭을 좁게 예측 하는 경향이 있었다. 이러한 점은 기계학습 모델 훈련 설계의 시험을 통해 개선될 수 있을 것으로 보이며 후속 연구를 통해 해결책이 모색되어야 할 것이다.

가뭄 발생에 대한 정보가 사전에 주어진다면 가뭄 피해를 경감하기 위한 자원을 확보하고 효율적 배분을 위한 계획을 세워 가뭄 피해를 최소화할 수 있을 것이다. 가뭄 발생으로 인한 피해를 예방 및 저감하기 위해서는 구조적인 대책과 더불어 가뭄감시·예측시스템 개발과 같은 비구조적인 대응방안이 필수적이다. 본 연구를 통해 인도네시아 지역에 대해 개발된 가뭄예측 모델을 활용하여 기상학적 가뭄지수의 예측 성능을 향상시킬 수 있다. 이를 통해 인도네시아의 가뭄 재난 예방을 지원하여 가뭄 피해 최소화에 도움이 될 수 있을 것이다.

1. 서론	1
1.1 연구의 필요성 및 목적	1
2. 자료 및 연구방법	3
2.1 연구 지역	3
2.1.1 인도네시아의 강우 특성	3
2.1.2 인도네시아의 가뭄 피해	7
2.1.3 인도네시아의 가뭄 관련 제도	9
2.1.4 인도네시아의 가뭄 관련 정보 시스템	12
2.1.5 연구 지역의 선정	13
2.2 자료	17
2.2.1 관측 자료	17
2.2.2 강우 자료	17
2.2.3 지표면온도 자료	20
2.2.4 식생지수 자료	22
2.2.5 토양수분 자료	22
2.2.6 해수면온도 자료	26

2.2.7 장기기후예측 자료-----	27
2.2.8 보조 자료-----	34
2.3 연구 방법론-----	37
2.3.1 가뭄 지수의 선정-----	37
2.3.2 가뭄예측 모델의 구축-----	38
3. 결과 및 토의-----	44
3.1 가뭄 예측 성능의 평가-----	44
3.1.1 서부 자바(JB) 지역-----	44
3.1.2 서부 수마트라(SB) 지역-----	51
3.1.3 고론탈로 (GO) 지역-----	57
3.1.4 지역 간 비교-----	64
3.2 입력 변수의 상대적 중요도-----	67
3.2.1 서부 자바 (JB) 지역-----	67
3.2.2 서부 수마트라 (SB) 지역-----	68
3.2.3 고론탈로 (GO) 지역-----	68
3.2.4 지역 간 비교-----	68
3.3 가뭄예측 사례 분석-----	73
3.3.1 가뭄지수 지도-----	74
3.3.2 지역 평균 비교-----	88
4. 결론-----	90
4.1 요약 및 결론-----	90
4.2 가뭄예측 모델 활용 방안-----	92
Ⅰ REFERENCE-----	93

LIST OF TABLES

Table 2-1. Land and production damage caused by El Niño (adopted from Tabor et al., 2015; originally from Bank Indonesia's Laporan Nusantara, May 2014). ----	8
Table 2-2. Harvested Area of Paddy (2014; BPS, 2016) and Area Equipped for Irrigation (2005; FAO, 2016) -----	15
Table 3-1. Drought Accuracy based on ML and FCST in the JB region. -----	48
Table 3-2. Regression MAE based on ML and FCST in the JB region. -----	51
Table 3-3. Drought Accuracy based on ML and FCST in the SB region. -----	54
Table 3-4. Regression MAE based on ML and FCST in the SB region. -----	57
Table 3-5. Drought Accuracy based on ML and FCST in the GO region. -----	61
Table 3-6. Regression MAE based on ML and FCST in the GO region. -----	64

LIST OF FIGURES

Figure 2-1. Indonesia archipelago.	4
Figure 2-2. The three climate regions according to the mean annual patterns using the DCM (adopted from Aldrian and Sustanto, 2003).	4
Figure 2-3. The annual cycles of the three climate regions (solid lines) using the DCM (adopted from Aldrian and Susanto, 2003).	6
Figure 2-4. Indonesia drought-related information systems. --	13
Figure 2-5. Indonesian provinces (a) grouped for rainfall regions, and (b) with harvested area percentage.	15
Figure 2-6. Selected provinces and their land cover information based on Global Land Cover Network(GLCN) data (Source: http://www.fao.org/geonetwork/). ----	16
Figure 2-7. TRMM 3B43 monthly precipitation data for Jan. 1998 (mm/month).	18
Figure 2-8. GPM IMERG monthly precipitation data for Jan. 2015 (mm/month).	19
Figure 2-9. PERSIANN-CDR monthly precipitation data for Jan. 1984 (mm/month)	19
Figure 2-10. MODIS monthly averaged (a) daytime, (b) nighttime, and (c) mean LST for Aug. 2002.	21

Figure 2-11. MODIS monthly averaged NDVI for Jul. 2003 (unitless).	22
Figure 2-12. AMSR-E monthly averaged (a) daytime, (b) nighttime, and (c) mean soil moisture data for Sep. 2011 (%).	24
Figure 2-13. AMSR2 monthly averaged (a) daytime, (b) nighttime, and (c) mean soil moisture data for Aug. 2015 (%).	25
Figure 2-14. ERSST v4 monthly sea surface temperature for Aug. 2015 (degree C).	26
Figure 2-15. TCC maps for precipitation prediction in October over Indonesian region with lead times from 1-2 months.	28
Figure 2-16. TCC maps for precipitation prediction in October over Indonesian region with lead times from 3-4 months.	29
Figure 2-17. TCC maps for precipitation prediction in October over Indonesian region with lead times from 5-6 months.	30
Figure 2-18. RMSE maps for precipitation prediction in October over Indonesian region with lead times from 1-2 months.	31
Figure 2-19. RMSE maps for precipitation prediction in October over Indonesian region with lead times from 3-4 months.	32
Figure 2-20. RMSE maps for precipitation prediction in October over Indonesian region with lead times from 5-6 months.	33

Figure 2-21. GTOPO30 Elevation data (m). -----	34
Figure 2-22. Crop Land Areas from GLCN data for 2005. ---	35
Figure 2-23. MODIS Land Cover Type for 2012. -----	36
Figure 2-24. SPI6 for Aug. 2015 (unitless). -----	38
Figure 2-25. Remote and local regions with SST input data. -	41
Figure 3-1. Drought Accuracy based on ML and FCST in the JB region. -----	46
Figure 3-2. Comparisons between models for Drought Accuracy based on ML and FCST in the JB region. ----	47
Figure 3-3. Regression MAE based on ML and FCST in the JB region. -----	49
Figure 3-4. Comparisons between models for regression MAE based on ML and FCST in the JB region. ----	50
Figure 3-5. Drought Accuracy based on ML and FCST in the SB region. -----	52
Figure 3-6. Comparisons between models for Drought Accuracy based on ML and FCST in the SB region. ----	53
Figure 3-7. Regression MAE based on ML and FCST in the SB region. -----	55
Figure 3-8. Comparisons between models for regression MAE based on ML and FCST in the SB region. ----	56
Figure 3-9. Drought Accuracy based on ML and FCST in the GO region. -----	59
Figure 3-10. Comparisons between models for Drought Accuracy based on ML and FCST in the GO region. ---	60
Figure 3-11. Regression MAE based on ML and FCST in the GO region. -----	62

Figure 3-12. Comparisons between models for regression MAE based on ML and FCST in the GO region. --	63
Figure 3-13. Regional comparison of Drought Accuracy and regression MAE. -----	66
Figure 3-14. Averaged relative importance of input variables for machine learning models in the JB region. --	70
Figure 3-15. Averaged relative importance of input variables for machine learning models in the SB region. --	71
Figure 3-16. Averaged relative importance of input variables for machine learning models in the GO region. -	72
Figure 3-17. Indonesian region affected by drought in 2015 (Source: DMCDD, 2015). -----	73
Figure 3-18. Observed and forecasted SPI6 using BEST methods for August 2015 in the JB region. -----	78
Figure 3-19. Observed and forecasted SPI6 using FCST_ONLY methods for August 2015 in the JB region. ·	79
Figure 3-20. Observed and forecasted SPI6 using BEST methods for September 2015 in the JB region. -----	80
Figure 3-21. Observed and forecasted SPI6 using FCST_ONLY methods for September 2015 in the JB region. --	81
Figure 3-22. Observed and forecasted SPI6 using BEST methods for October 2015 in the JB region. -----	82
Figure 3-23. Observed and forecasted SPI6 using FCST_ONLY methods for October 2015 in the JB region. --	83
Figure 3-24. Observed and forecasted SPI6 using BEST methods for November 2015 in the JB region. -----	84

- Figure 3-25. Observed and forecasted SPI6 using FCST_ONLY methods for November 2015 in the JB region. -- 85
- Figure 3-26. Observed and forecasted SPI6 using BEST methods for December 2015 in the JB region. ----- 86
- Figure 3-27. Observed and forecasted SPI6 using FCST_ONLY methods for December 2015 in the JB region. - 87
- Figure 3-28. Scatterplots (a) between FCST and OBS and (b) between ML and OBS based on NASA model for 4-month lead time. ----- 89
- Figure 3-29. Scatterplots (a) between FCST and OBS and (b) between ML and OBS based on NASA model for 6-month lead time. ----- 89

1. 서론

1.1 연구의 필요성 및 목적

인도네시아는 광범위한 면적과 태평양, 인도양에 모두 접하여 있는 지리적인 위치로 인해 태풍, 홍수, 지진, 화산, 해일, 가뭄 등 거의 모든 자연 재난이 빈번히 발생한다. 이 중 가뭄은 직·간접적으로 다양한 피해를 초래하는데 물부족, 수질 악화, 염수 침투, 토양 유실 및 토사 재해, 공중 위생 저하, 대기질 악화, 산불 증가 등의 문제를 일으킬 뿐 아니라 농축산물 생산량 저하, 레저 및 관광 산업 침체를 유발하기도 한다(APA, 2013). 역사적으로 가뭄이 농작물 생산량 등에 악영향을 미치고 산불을 유발하여 연무로 인한 피해를 발생시킨 사례가 많이 존재하므로 가뭄 발생에 대한 정보가 사전에 주어진다면 가뭄 피해를 경감하기 위한 자원을 확보하고 효율적 배분을 위한 계획을 세워 가뭄 피해를 최소화할 수 있을 것이다. 가뭄 발생으로 인한 피해를 예방 및 저감하기 위해서는 구조적인 대책과 더불어 가뭄감시·예측시스템 개발과 같은 비구조적인 대응방안이 필수적이다.

인도네시아의 가뭄의 발생은 특히 지역적으로 차이는 있으나 엘니뇨 및 남방진동(El Nino and Southern Oscillation; ENSO)¹⁾의 변동과 관련이 깊은 것으로 알려져 있어 엘니뇨 전망을 활용한 가뭄 예측이 유망해 보인다. 그러나 몬순, 국지적인 해수면온도(Sea Surface Temperature; SST), Indian Ocean Dipole(IOD), South Pacific Convergence Zone(SPCZ) 등 해양과 대기의 상호작용 뿐 아니라 지형 및 고도 등의 지역적인 요인 등 강수 변동에 영향을 주는 요인은 다양하게 존재하므로 장기기후예측자료와 가뭄의 초기 조건을 나타내는 원격탐사 정보를 결합한다면 좀 더 가뭄예측의 성능을 높일 수 있을 것이다.

본 연구를 통해 아태지역에 위치한 인도네시아의 가뭄 재난 예방을 지원하여 가뭄 피해 최소화에 도움이 되고자 한다. 인도네시아 지역은 거대한 면적에 비하여 지속적으로 수집되는 현장관측 자료가 풍부하지 않으므로 원격탐사 자료를 적극 활용하면 정보의 공간적 범위를 확장시킬 수 있다. 연구의 목적은 국내를 대상으로 개발된 가

1) 기상 용어의 경우 상세한 정의는 기상청 기상백과(<http://web.kma.go.kr/communication/encyclopedia/list.jsp>)를 참고할 것.

2 | 한반도 겨울철 기온 계절예측을 위한 기후인자 선정 및 통계 모델 개선

뭍예측 기술을 기반으로 인도네시아의 가뭄 특성을 반영하여 인도네시아에 적합한 가뭄예측 모델을 개발하는 것이다. 인도네시아의 강우 특성을 고려하여 지역을 선정하고 지역별로 가뭄예측 모델을 개발하였다.

2. 자료 및 연구방법

2.1 연구 지역

2.1.1 인도네시아의 강우 특성

인도네시아는 17,504개의 섬으로 이루어진 국가로 필리핀, 파푸아 뉴기니등과 함께 해양성 대륙(Maritime Continent)으로 불리는 동남아시아 지역에 위치한다. 면적은 190만km²에 달하며 주요 섬은 수마트라, 자바, 누사텐가라, 칼리만탄, 술라웨시, 말루쿠, 파푸아(이리안 자바)가 있다(Figure 2-1). 수도는 자바 섬에 위치한 자카르타이고 행정구역은 크게 34개의 도로 이루어져 있는데, 이는 349개의 Regency(kabupaten)와 91개의 시(kota), 그리고 5,656개의 소구역(kecamatan)과 71,563개의 마을(desa/kelurahan)로 나누어진다(FAO, 2016).

기후는 고온·습윤한 열대성으로 연중 비가 많은데 지역에 따라 차이가 있다. Aldrian and Susanto(2003)는 Double Correlation Method(DCM)를 이용하여 인도네시아 지역의 기후학적 강우 변동 특성을 도출하고 이에 따라 전체 지역을 세 지역(Region A, B, C)으로 나누었다(Figure 2-2). Region A는 남부 수마트라에서 티모르 섬에 이르는 남부 인도네시아 지역과 남부 칼리만탄, 술라웨시, 파푸아의 일부 지역으로 인도네시아의 가장 넓은 부분을 차지하기 때문에 인도네시아의 일반적인 기후를 대표한다. Region B는 북부 수마트라에서 북서부 칼리만탄에 이르는 지역으로 북서 인도네시아 지역에 해당되며, Region C는 말라쿠와 북부 술라웨시를 포함한다(Figure 2-2).

세 지역의 연간 강우 변동성을 보면 Region A는 1월에 강수가 가장 많고 8월에 비교적 적는데, 11월에서 3월까지는 습윤한 북서 몬순의 영향을 받고 5월에서 9월까지는 건조한 남동 몬순의 영향을 받기 때문으로 알려져 있다. Region B는 ITCZ(Inter-Tropical Convergence Zone) 이동의 영향으로 북반구 겨울철 강수가 억제되어 두 개의 정점을 가지며 Region C는 6-7월이 다우기, 11월-2월이 상대적으로 건조한 시기이다(Figure 2-3; Aldrian and Susanto, 2003).

4 | 한반도 겨울철 기온 계절예측을 위한 기후인자 선정 및 통계 모델 개선



Figure 2-1 Indonesia archipelago.




Figure 2-2 The three climate regions according to the mean annual patterns using the DCM (adopted from Aldrian and Sustanto, 2003).

태평양과 인도양의 경계에 위치한 인도네시아의 강우는 국지 또는 원격 SST의 영향을 모두 받는 것으로 알려져 있다(e.g., Aldrian and Sustanto, 2003; Hendon, 2003; Juneng and Tangang, 2005). Region C와 Region A는 ENSO의 영향을 받으며(Aldrian and Sustanto, 2003), Region A는 또한 국지적인 SST 및 SPCZ와 양의 상관관계를 가지는 것으로 알려져 있다(Aldrian and Sustanto, 2003). Hendon(2003)

은 인도네시아 지역의 강수 아노말리가 건기 동안에 공간적으로 일관되게 나타나며 ENSO와 높은 상관성이 있고 적도 인도양의 SST 동서 편차(IOD; Indian Ocean Dipole)와 관련이 깊음을 밝혔다. 또한 인도네시아 평균 강우와 ENSO, 서부 인도양 SST, 국지 SST의 지연상관을 살펴보았는데, 인도네시아 지역 9월의 건조한 상태는 최대 4월 이후의 중앙 및 동태평양의 높은 SST, 최대 7월 이후의 서부 인도양의 높은 SST, 그리고 최대 5월 이후의 낮은 국지 SST와 지연 상관성이 있는 것으로 알려져 있다(Hendon, 2003). Juneng and Tangang(2005)은 동남아시아 강우 아노말리가 El Nino 상태와 높은 상관성이 있으며 Extended Empirical Orthogonal Function(EEOF)를 이용하여 분석한 결과 강우 아노말리가 El Nino가 발달하고 약해지는 과정에서 북동쪽으로 진화함을 밝혔다.




Figure 2-3 The annual cycles of the three climate regions (solid lines) using the DCM (adopted from Aldrian and Susanto, 2003).

2.1.2 인도네시아의 가뭄 피해

Setiawan et al(2016)은 표준강수지수(Standardized Precipitation Index; SPI)의 EOF 분석을 통해 과거 El Nino 사상을 강, 중, 약으로 나누어 El Nino 동안에 가뭄에 영향을 많이 받는 시기와 지역을 도출하였다. 가뭄 발생에 대한 ENSO의 영향은 강수에 대한 영향과 마찬가지로 9-11월에 가장 크게 나타나는데(Setiawan et al., 2016) Aldrian and Sustanto(2003)의 Region A와 C의 경우 연간 강우 변동의 상대적인 건조기와 강한 ENSO 상태가 중첩되거나 우기의 시작을 저해하는 경우 심한 가뭄이 발생할 수 있음을 알 수 있다.

가뭄은 태풍이나 화산 등의 재난과는 다르게 광범위한 지역에서 장기적으로 발생하는 경우가 많으며 그러한 특성으로 인해 심한 가뭄의 경우 영향을 받는 인구가 증가하게 된다. 인도네시아의 과거 재난 발생을 보면 1900년에서 2016년 6월까지 가장 많은 사망자가 발생한 열 건의 자연 재난은 대부분 화산 및 지진이지만 태풍(1973년 6월, 1650명 사망)과 가뭄(1966년 1월, 8000명 사망)도 큰 피해를 발생시킨 적이 있으며, 영향을 받은 인구 순으로 보면 1972년 가뭄의 경우가 350만 명의 피해자를 발생시켜 가장 많은 영향을 주었다. 전 기간에 대해서 기록된 것은 총 10건의 가뭄으로 9,340명의 사망자와 4,804,220명의 영향, 16,020만 달러의 경제적 피해를 발생시켰다(EM-DAT, 2016).

가뭄의 여러 영향 가운데 심각한 것이 농작물 생산량 감소로, 과거 여러 차례의 El Nino와 연관된 가뭄으로 많은 농작물 피해가 발생하였다(Tabor et al., 2015; Table 2-1). 예를 들어, 1997/1998년의 가뭄으로 161,144ha의 농경지가 피해를 입어 총 714,512ton의 쌀 생산이 감소하였으며 2006년에는 El Nino의 강도가 약했음에도 73,045ha의 농경지에 피해가 발생하여 쌀 생산량이 337,468ton 감소하였다(Table 2-1).

Table 2-1 Land and production damage caused by El Niño (adopted from Tabor et al., 2015; originally from Bank Indonesia's Laporan Nusantara, May 2014).

Year	Intensity of El Nino	Land Damage (ha)	Loss of Paddy Production (ton)
1994	Moderate	161,000	700,028
1997	Strong	161,144	714,512
2003	Moderate	114,038	517,504
2006	Weak	73,045	337,468
2009	Moderate	35,000	174,965

최근의 2015/2016 El Nino 역시 많은 영향을 끼쳤는데, 인도네시아 일부 지역은 평년보다 많은 비로 홍수 피해를 겪은 반면에 34개도 가운데 16개도에서는 가뭄 피해가 발생하였고 이 중 8개도의 43개 구역에서는 심각한 가뭄이 발생한 것으로 알려졌다(OCHA, 2015). 가뭄으로 인해 산불 발생이 파생되어 연무로 4천3백만명이 피해를 입었으며 관련 급성 호흡기 질환으로 2015년 8월과 9월에 10명의 사망자가 발생하고 272,000명이 피해를 입었다(OCHA, 2015).

세계식량프로그램(World Food Programme; WFP)은 2015년 12월 가뭄 피해를 입은 8개 구역의 2,400가구를 대상으로 인터뷰를 실시하였는데, 해당 가뭄으로 인해 40%의 쌀 생산자가 50% 이상의 수확량 손실을 입었으며 2/3의 농가가 가뭄으로 인해 3개월 간 작물 파종을 연기하거나 취소한 것으로 나타났다(WFP, 2016). 5가구 중 3가구는 소득이 줄었고 5가구 중 1가구는 가뭄으로 인해 식비를 줄였으며 전체적으로 120만명이 지원이 필요한 것으로 나타났다(WFP, 2016).

인도네시아 지역이 El Nino의 영향 하에 있을 때 쌀 생산량이 감소하는 것은 쌀의 생산성(yield)이 줄어들어서가 아니라 쌀 재배면적(planted area) 자체가 줄어들기 때문으로 알려져 있다(GRiSP, 2013). 관개 시스템이 되어있는 곳에서도 가용한 수자원이 줄어들기 때문에 쌀 재배면적이 감소하게 된다(GRiSP, 2013). 쌀 생산량이나 수확 면적이 관개 면적과 매우 큰 상관관계를 가지는 것(각각 $r = 0.99, 0.98$)과는 달리 쌀 생산성은 관개 면적과 그다지 큰 상관관계가 없는 것으로 알려져 있다($r = 0.46$; Panuju et al., 2013). 쌀 생산성에는 많은 요인이 영향을 미치는데, 자바나 발리 지역과 같이 생산성이 높은 지역의 경우에는 낮은 쌀 가격 등의 사회·경제적인

요인이 큰 영향을 미치며 수마트라는 열악한 배수나 강한 산성과 같은 토양 문제의 영향이 크고, 술라웨시나 누사텐가라와 같은 지역은 건조한 기후, 물 부족, 가뭄의 영향이 큰 것으로 알려져 있다(Makarim, 2000). 생산성이 가장 낮은 칼리만탄, 말루쿠, 파푸아 지역은 앞서 언급한 토양 및 사회경제적인 요인들이 복합적으로 생산성을 저하시키고 있다(Makarim, 2000).

2.1.3 인도네시아의 가뭄 관련 제도

2.1.3.1 물 관련 제도

인도네시아 헌법 제33조(Undang-Undang Dasar 1945)는 물을 포함한 모든 자연 자원은 국가에 속하며 인도네시아 국민의 복지를 위해 사용되어야 함을 명시하고 있다. 이와 관련된 운영상의 정책은 2004년 제7호 법률(Undang-Undang)에 나타나 있는데, 특히 수자원과 관련된 두 부처를 지정하고 있다. Department of Public Works는 지표수자원과 관련된 계획, 공학기술의 적용, 감독, 사업 개발, 유지, 입법, 이용과 관련된 모든 활동과 노력을 관리하며 Department of Mining and Energy는 지하수자원을 관리하도록 되어있다(FAO, 2016).

물관리 관련 법안은 아래와 같다(FAO, 2016).

- Indonesian Law No. 7/2004: Water Resources Laws
- Government Regulation No. 77/2001: Irrigation
- Government Regulation No. 82/2001: Water Quality Management and Water Pollution Control
- Government Regulation on Water Resource Management
- Government Regulation on Management of Water Resources in River System
- Government Regulation on Financing Water Resource Development
- Government Regulation on Rivers

- Government Regulation on Groundwater
- Government Regulation on Drinking Water
- Government Regulation on Perum Jasa Tirta I
- Government Regulation on Perum Jasa Tirta II
- Presidential Instruction No. 3/1999: Policy Reformation on Irrigation Management
- Presidential Decree No. 9/1999: Coordination Team on River Water Use and Development Policies
- Presidential Decree No. 123/2001 (renewed by President Decree Number 83/2002): Coordination Team on Water Resources Management
- Decision of the Coordinator Ministry on Economy, Finance, and Industry
- Decision of the Coordinator Ministry on Economy
- Decision of the Ministry of Settlements and Regional Infrastructures (Dept of Public Works)
- Decision of the Ministry of Internal Affairs
- Decision of the Ministry of Environment
- Provincial Regulations on formation of the agencies for water resources development (8 provinces)
- Provincial Regulations on water pollution control (4 provinces)
- Governor Decisions on development of the Coordination Teams for Provincial Water Resources Management (8 provinces)
- District and Municipality Regulation concerning water resources for domestic, agricultural and industrial use

인도네시아 정부는 1969년을 시작으로 정부 주도의 5개년 개발계획(Rapelita)을 추진해오고 있는데, 이는 특히 쌀 자급을 위한 관개 시스템의 확충, 고생산성 품종의 활용, 비료 및 제초제의 사용 등을 포함하고 있다. 처음 1969-1993년의 25년의 기간 동안 수자원 정책은 농업에 중점을 두고 다양한 부문의 개발을 지원하는 방향으로 형성되었으며 새로운 관개 시설의 개발 등에 초점을 맞추었다. 1994-2019년의 기간은 지속가능한 개발과 수자원 관리에 중점을 두고 있다. 기존의 농업 중심에서 다부문으로 수자원 관리의 필요성이 확대되었으며 쌀 자급과 함께 수자원 기반시설의 운영 및 관리의 중요성이 강조되었다(FAO, 2016).

2004-2009년 기간 동안의 수자원관리 정책은 수자원 보존, 수자원의 최적화된 이용, 잠재적인 수자원 위해 요소의 규제, 커뮤니티, 민간 및 정부기관의 참여 제고, 수자원관리 관련 자료 및 정보의 가용성과 투명성 증대의 다섯 가지로 말할 수 있는데(FAO, 2016), 이 중 가뭄 감시 및 예측과 관련이 깊은 정책은 잠재적인 수자원 위해 요소의 규제와 관련된 정책이다. 해당 정책의 목표는 태풍, 가뭄 등 자연 재난의 잠재적인 영향에 대처하고 농업 및 공업 생산, 인간 정주 및 기반 시설 지역의 토양 침식 등을 감소시키는 것으로(FAO, 2016) 효율적인 가뭄 감시 및 예측을 통해 정책 실행에 기여할 수 있다.

2.1.3.2 재난 관련 제도

인도네시아의 재난관리 관련 법안은 다음과 같다(ADRC, 2012).


- Disaster Management Law No. 24/2007
- Government Regulation No. 21/2008: Operation of Disaster Management
- Government Regulation No. 22/2008: Funding and Managing in Disaster Assistance
- Government Regulation No. 23/2008: Role of International Agencies and Foreign Non Governmental Agencies in Disaster Management
- Presidential Regulation No. 8/2008: Establishment of NADM(National

Agency for Disaster Management; Badan Nasional Penanggulangan Bencana; BNPB)


국가재난관리기관인 BNPB에서 2010-2014년의 기간에 추진한 재난관리 정책 및 전략은 계획, 지시, 조율, 통합, 포괄적이고 책임 있는 재난 관리의 이행, 신속한 대응을 통한 재난 인식, 대응 능력, 예방의 증대, 재난 사후 지역에서 긴급 재난 피해자에 대한 재빠르고 정확하며 효과적인 처리, 그리고 통합적이고 포괄적인 물리/비물리적 기반 시설의 회복 등을 포함한다(ADRC, 2012). 2010-2014년 동안의 국가 중장기 계획을 보면 기후변화, 환경 악화 규제, 조기경보 시스템, 재난 관리가 포함되어 있는데(ADRC, 2012) 환경 악화 규제를 제외한 세 항목이 모두 가뭄 감시 및 가뭄 예측과 관련되어 있다.

2.1.4 인도네시아의 가뭄 관련 정보 시스템


인도네시아 기상청(BMKG)은 여러 형태의 기후 정보를 제공하는데 이는 무강우 일수(Figure 2-4a; http://www.bmkg.go.id/BMKG_Pusat/Informasi_Iklim/Informasi_Hari_Tanpa_Hujan.bmkg), SPI(Figure 2-4b; http://www.bmkg.go.id/BMKG_Pusat/Informasi_Iklim/Indeks_Presipitasi_Terstandarisasi.bmkg), 토양 수분 가용도(Figure 2-4c; http://www.bmkg.go.id/BMKG_Pusat/Informasi_Iklim/Neraca_Air.bmkg) 등의 모니터링 정보 및 강수 예측, 엘니뇨 전망 등의 예측 정보와 기후 변화에 대한 정보를 포함한다. 또한 기후조기경보시스템(<http://cews.bmkg.go.id/depan.bmkg>)을 통해 건기의 시작점을 예측(Figure 2-4d; <http://cews.bmkg.go.id/depan.bmkg?pt=aawmk>)하고 있다.




(a) Consecutive Dry Days



(b) SPI3 monitoring



(c) Soil Moisture Availability



(d) Dry Season Onset Prediction

Figure 2-4 Indonesia drought-related information systems.

2.1.5 연구 지역의 선정

Aldrian and Susanto(2003)가 강우 특성에 따라 나눈 Region A, B, C를 이용하여 인도네시아 34개도를 각 지역에 해당하는 도와 중간적인 특성을 가진 도로 분류하였으며 Region A, B, C에 대해 각 지역 별로 한 개 켢의 도로 선정하였다(Figure 2-5a). 이는 상이한 강우 특성을 가지는 지역에 대해 가뭄에 영향을 미치는 요인이 다를 수 있으므로 개발된 가뭄예측 모델의 성능이 어떻게 다르게 나타나는지 평가하기 위함이다. 지역별로 도로를 선정할 때 인도네시아의 주식이며 가장 많이 생산되는 작물이 쌀이라는 점을 고려하여 전체 면적 대비 쌀의 수확 면적 비율(Figure 2-5b; Table 2-2)이 높은 곳을 선정하였다.

인도네시아는 중국, 인도에 이어 세계에서 세 번째로 쌀을 많이 생산한다(FAO,

2016). 인도네시아 도별 면적과 쌀 생산량, 쌀 생산성, 쌀 수확 면적 자료를 인도네시아 통계청에서 수집하였다(<http://www.bps.go.id>). 쌀 생산이 가장 크긴 하지만 인도네시아의 전체 쌀 수확 면적은 2014년 기준으로 13,797,307ha로 인도네시아 전체 면적의 7.22%에 불과하며 쌀 생산은 91% 정도가 논에서 이루어지고 9% 정도는 밭에서 이루어진다(FAO, 2016).

Region A에 대해서는 서부 자바(West Java; Jawa Barat; 이하 JB), Region B에 대해서는 서부 수마트라(West Sumatra; Sumatera Barat; 이하 SB), Region C에 대해서는 고론탈로(Gorontalo; 이하 GO) 지역을 선정하였다(Figure 2-6). 2014년 기준으로 JB 지역의 전체 면적은 3,537,800ha로 쌀 수확 면적인 1,979,799ha는 무려 55.96%를 차지한다(Table 2-2). Figure 2-5b를 보면 반텐, 서부 자바, 중앙 자바, 동부 자바 지역의 쌀 수확 면적 비율이 압도적으로 높은 것을 알 수 있다. SB 지역은 전체 면적이 4,201,300ha이고 쌀 수확 면적이 503,198ha로 11.98%를 차지하며 GO 지역은 전체 면적이 1,125,700ha, 쌀 수확 면적이 62,690ha로 5.57%를 차지한다(Table 2-2).

2005년의 관개 면적 자료를 살펴보면 인도네시아 전체 지역의 관개 면적은 6,722,299ha로, 관개시스템을 통하지 않고 습지의 경우처럼 자연적으로 물이 공급되는 3,133,317ha의 면적을 합하면 9,855,616ha의 면적에 대해 수자원 공급이 원활이 이루어진다고 볼 수 있다. 이는 인도네시아 전체 면적의 5.16%에 해당하고 전체 경작지 면적의 26%에 해당한다(FAO, 2016). 앞서 선정한 세 개 도의 경우 JB, SB, GO 지역의 관개 설비가 되어 있는 면적은 각각 1,096,022ha, 374,388ha, 19,664ha로 농작물 중 쌀 생산 면적이 압도적으로 크고 관개 시설을 가장 많이 활용하여 생산되는 작물이 쌀이므로 2014년의 쌀 수확 면적에 대한 비율을 보면 각각 55.36%(전체 면적의 30.98%), 74.40%(전체 면적의 8.91%), 31.37%(전체 면적의 1.75%)에 해당한다(FAO, 2016; Table 2-2). 최근 자료에는 2012년 기준으로 인도네시아 전체 쌀 생산지역의 84%가 관개되어 있고 16%만이 비에 의존하는 것으로 알려져 있다(GRiSP, 2013). 하지만 앞서 언급한 대로 관개가 되어있는 지역이라고 할지라도 가뭄이 심한 경우 가용한 수자원의 양이 줄어 농작물의 생산이 영향을 받게 된다.

쌀 수확 면적 비율을 이용하여 연구 대상 지역을 선정하였으나 본 연구의 가뭄예측

의 목적이 농업적 가뭄을 중심으로 하는 것은 아니다. 쌀 생산에 영향을 미치는 요소는 앞 장에서 언급한 바와 같이 매우 복잡하게 나타나므로 그 경우 기상학적 가뭄지수를 이용하기 보다는 직접적으로 쌀 생산과 관련된 변수나 농업 모델링을 결합하여 활용하는 것이 적합하다. 다만 전체 면적 대비 쌀의 수확 면적이 높은 경우 해당 도의 농업에 대한 의존이 상대적으로 높으며 가뭄 정보 활용에 대한 관심이 높을 것으로 가정하였다.




Figure 2-5 Indonesian provinces (a) grouped for rainfall regions, and (b) with harvested area percentage.

Table 2-2 Harvested Area of Paddy (2014; BPS, 2016) and Area Equipped for Irrigation (2005; FAO, 2016)

Province	Harvested Area (ha)	Total Area (ha)	Harvested Area Percentage (%)	Area Equipped for Irrigation (ha)	Area Equipped for Irrigation Percentage (%)
West Java (JB)	1979799	3537776	55.96	1096022	55.36
West Sumatra (SB)	503198	4201289	11.98	374388.39	74.40
Gorontalo (GO)	62690	1125707	5.57	19664	31.37




Figure 2-6 Selected provinces and their land cover information based on Global Land Cover Network(GLCN) data (Source: <http://www.fao.org/geonetwork/>).

2.2 자료

2.2.1 관측 자료

관측 자료로 사용하기 위해 Global Historical Climatology Network-Monthly (GHCN-M) 지점 자료를 검토하였다. 전구기후모델(Global Climate Model; GCM)의 장기기후예측 자료에 편의보정, 공간상세화 등을 적용하는 경우 관측 자료를 이용해야 하므로 본 연구에서 활용한 전구 기후모델의 Hindcast 기간 중 모델 간에 중첩되는 1983년 1월부터 2009년 8월의 기간에 대해 GHCN 강수 자료의 가용성을 평가하였다. 인도네시아 지역에는 518개의 GHCN 지점이 존재하는데, 이 중 어느 지점의 어느 월도 18년 이상의 가용한 자료를 보유하지 못하였다. 따라서 본 연구에서는 위성에 기반을 둔 강우 자료를 관측 강우 자료 대신 활용하였다.

2.2.2 강우 자료

강수량 자료는 Tropical Rainfall Measuring Mission(TRMM) 자료와 Global Precipitation Measurement(GPM) 자료를 중심으로 활용하였다. TRMM은 미국 National Aeronautics and Space Administration(NASA)와 일본 Japan Aerospace Exploration Agency(JAXA)에 의해 개발되었으며 1998년 1월부터 2014년 3월까지 TRMM 3B43의 원격 탐사 자료와 관측 자료를 융합한 월별 자료를 미국 Goddard Earth Sciences Data and Information Service Center(GES DISC)에서 획득하여 이용하였다. 자료 제공 범위는 50°S - 50°N , 180°W - 180°E 이며, 공간 해상도는 $0.25 \times 0.25^{\circ}$ 이다(Figure 2-7).

TRMM 3B43 자료와 마찬가지로 강우 합성장인 GPM Integrated Multi-satellite Retrievals for GPM(IMERG) 자료는 2014년 4월부터 2015년 12월까지 NASA의 Precipitation Measurement Missions(PMM)에서 획득하여 이용하였다. IMERG 자료의 제공 범위는 90°S - 90°N , 180°W - 180°E 이며, 공간 해상도는 $0.1 \times 0.1^{\circ}$ 이다(Figure 2-8).

가뭄지수를 예측하기 위해서는 강우 시계열을 확률분포함수에 적용시켜야 하는데,

이를 이해서는 30개 정도의 자료가 요구된다. TRMM 자료와 GPM IMERG 자료의 총 기간은 각 월에 대해 17개(17년)의 자료만이 존재한다. 따라서 확률분포함수 매개변수 도출을 위해 충분한 기간의 자료를 확보하기 위해 과거 기간에 대해 Precipitation Estimation from Remotely Sensed Information using Artificial neural Networks (PERSIANN)-Climate Data Record(CDR) 자료를 이용하였다. PERSIANN-CDR 자료는 마이크로웨이브 센서가 존재하지 않는 기간에 대해 적외선 센서 자료를 활용하여 만들어지며 60°S-60°N, 180°W-180°E의 공간 범위에 대해 0.25×0.25°의 공간해상도로 1983년부터 제공된다(Ashouri et al, 2015; Figure 2-9). 생산 과정 및 상세한 알고리즘은 Ashouri et al.(2015)에 나타나 있다.




Figure 2-7 TRMM 3B43 monthly precipitation data for Jan. 1998 (mm/month).




Figure 2-8 GPM IMERG monthly precipitation data for Jan. 2015 (mm/month).






Figure 2-9 PERSIANN-CDR monthly precipitation data for Jan. 1984 (mm/month)

2.2.3 지표면온도 자료


미국 NASA의 Aqua 위성에 탑재된 Moderate Resolution Imaging Spectroradiometer (MODIS) 센서의 월별 지표면온도 표준 생산물인 MYD11C3 Land Surface Temperature and Emissivity 자료를 이용하였다. 본 자료는 $0.05 \times 0.05^\circ$ 공간해상도로 지구에 대하여 주간 및 야간 지표면온도를 제공한다(Figure 2-10). 본 연구에서 사용한 MODIS 자료의 공간 해상도는 모두 같으며 미국 NASA의 Earth Observing System Data and Information System(EOSDIS, <http://reverb.echo.nasa.gov>)에서 획득하였다.



(a)



(b)



(c)

Figure 2-10 MODIS monthly averaged (a) daytime, (b) nighttime, and (c) mean LST for Aug. 2002.

2.2.4 식생지수 자료

가시광선 영역의 적색광(RED)과 근적외선 영역(Near Infrared; NIR)의 표면반사율을 이용하는 식생지수의 하나인 정규식생지수(Normalized Difference Vegetation Index; NDVI)를 이용하였는데(Tucker, 1979), 지표면온도와 마찬가지로 Aqua 위성의 MODIS 센서 표준 자료를 활용하였다. MYD13C2 Vegetation Indices 자료는 역시 $0.05 \times 0.05^\circ$ 공간해상도로 전구에 대하여 제공된다(Figure 2-11).

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (\text{Eq. 2-1})$$





Figure 2-11 MODIS monthly averaged NDVI for Jul. 2003 (unitless).


2.2.5 토양수분 자료

토양수분 자료는 2002년 7월부터 2011년 9월까지의 Aqua 위성에 탑재된 Advanced Microwave Scanning Radiometer-EOS(AMSR-E) 위성의 표준 생산물인 AE-Land3 Surface Soil Moisture 일별 자료로부터 도출하여 월별 자료로 변환하였다. 자료는 MODIS 자료와 마찬가지로 미국 NASA의 Earth Observing System Data and Information System(EOSDIS, <http://reverb.echo.nasa.gov>)에서 획득


하였으며, 자료의 공간 해상도는 $0.25 \times 0.25^\circ$ 이다(Figure 2-12). 2012년 7월에서 2015년 12월까지의 자료는 일본의 Global Change Observation Mission 1st-Water (GCOM-W1) 위성의 Advanced Microwave Scanning Radiometer 2 (AMSR2) 센서 자료를 GCOM-W1 Data Providing Service 웹사이트를 통해 획득하여 이용하였는데, 공간 해상도는 $0.1 \times 0.1^\circ$ 이다(Figure 2-13).



(a)




(b)




(c)


Figure 2-12 AMSR-E monthly averaged (a) daytime, (b) nighttime, and (c) mean soil moisture data for Sep. 2011 (%).



(a)



(b)



(c)

Figure 2-13 AMSR2 monthly averaged (a) daytime, (b) nighttime, and (c) mean soil moisture data for Aug. 2015 (%).

2.2.6 해수면온도 자료

과거 기간의 해수면온도 자료는 미국기후자료센터(National Climate Data Center; NCDC)에서 제공하는 Extended Reconstructed Sea Surface Temperature (ERSST) v4 자료를 이용하였다(<https://www.ncdc.noaa.gov/data-access/marineocean-data/extended-reconstructed-sea-surface-temperature-ersst-v4>). ERSST-v4 자료는 1854년 1월부터 제공되며 $2 \times 2^\circ$ 의 공간 해상도를 가진다. 인도네시아 지역 뿐 아니라 원격 SST의 영향을 살펴보기 위해 전구에 대한 자료를 모두 이용하였다(Figure 2-14).




Figure 2-14 ERSST v4 monthly sea surface temperature for Aug. 2015 (degree C).

2.2.7 장기기후예측 자료

본 연구에서는 국내에 대하여 기계학습 기반 가뭄예측 모델을 개발한 이진영(2015)과 마찬가지로 APEC기후센터(APCC)의 6개월 예측에 사용되는 여섯 가지 개별 모델인 MSC_CanCM3(Meteorological Service of Canada Climate Centre third generation coupled global climate model), MSC_CanCM4(Meteorological Service of Canada Climate Centre fourth generation coupled global climate model), POAMA(Predictive Ocean Atmosphere Model for Australia), NCEP CFSv2(National Centers for Environmental Prediction Coupled Forecast System version 2), PNU(Pusan National University), NASA(National Aeronautics and Space Administration)의 1-6개월 예측 선행 시간의 강우 및 SST를 이용하였다. 자료는 APCC 데이터베이스로부터 획득하였으며 자료의 월별, 공간해상도는 $2.5 \times 2.5^\circ$ 이다.

개별 모델과 이들을 단순조합법(Simple Composite Method; SCM) 방법으로 다중 모델 앙상블(Multi-Model Ensemble; MME)한 모델의 Hindcast 기간인 1983-2005년의 자료를 이용하여 여러 모델 변수의 인도네시아 지역에 대한 예측 성능을 평가하였다(Figures 2-15 to 2-20). 이 중 강우 변수에 대하여 인도네시아 지역의 가뭄에 대한 El Nino의 영향이 크게 나타나는 9-11월의 기간 중(Setiawan et al., 2016) 10월의 시간적 상관계수(Temporal Correlation Coefficient; TCC; Figures 2-15 to 17)와 평균제곱오차제곱근(Root Mean Squared Error; RMSE in mm/day; Figures 2-18 to 20)을 살펴보았다. TCC에 있어서 일반적으로 선행시간이 길어질수록 예측 성능이 떨어지며, 지역적으로 차이가 나타나고 모델 간에도 어느 정도 차이가 드러났다(Figures 2-15 to 17). 특히 6개월 선행시간의 경우를 보면 MSC_CanCM4 모델의 경우 누사텐가라 지역 등지에서 예측 성능이 매우 높게 나타나며 이는 MME SCM의 경우보다 높다(Figure 2-17). RMSE를 보면 선행시간이 길어진다고 해서 오차 값이 급격히 증가하지는 않았다(Figures 2-18 to 2-20).

다중모델 앙상블의 경우 개별 모델에 비하여 예측 성능이 높게 나타나기는 하지만 모델 간 상이한 가뭄예측 결과를 종합적으로 제시하고자 본 연구에서는 가뭄예측 모델을 각 모델에 대해 개별적으로 개발하여 평가하였다.





Figure 2-15 TCC maps for precipitation prediction in October over Indonesian region with lead times from 1-2 months.





Figure 2-16 TCC maps for precipitation prediction in October over Indonesian region with lead times from 3-4 months.





Figure 2-17 TCC maps for precipitation prediction in October over Indonesian region with lead times from 5-6 months.





Figure 2-18 RMSE maps for precipitation prediction in October over Indonesian region with lead times from 1-2 months.





Figure 2-19 RMSE maps for precipitation prediction in October over Indonesian region with lead times from 3-4 months.





Figure 2-20 RMSE maps for precipitation prediction in October over Indonesian region with lead times from 5-6 months.

2.2.8 보조 자료

연구에서 활용한 보조 자료는 위도, 경도, 고도(Figure 2-21) 자료와 토지피복(Figures 2-6, 2-22, 2-23) 자료가 있다. 고도 자료는 Global 30 Arc-Second Elevation (GTOPO30) 자료를 이용하였는데, 자료는 미국 지질조사국(U.S. Geological Survey)에서 획득하였으며 대략 $1 \times 1 \text{ km}$ 의 해상도를 가진다. 토지피복 자료는 2005년의 GLCN 자료(Figures 2-6, 2-22)와 함께 Aqua 위성 및 Terra 위성의 MODIS 표준 생산물인 MCD12C1 Land Cover Type Yearly의 2012년 자료를 참고하였다. MODIS MCD12C1 자료는 IGBP(International Geosphere-Biosphere Programme) 분류를 이용하였으며 공간해상도는 $0.05 \times 0.05^\circ$ 이다.

두 자료를 살펴보면 GLCN자료는 관개 농지 면적은 너무 작게 나타나나 천수 농지의 경우 넓은 면적에 분포하고 있는데 MODIS MCD12C1의 자료는 농지 면적 자체가 매우 작게 나타난다.




Figure 2-21 GTOPO30 Elevation data (m).




Figure 2-22 Crop Land Areas from GLCN data for 2005.




Figure 2-23 MODIS Land Cover Type for 2012.

2.3 연구 방법론

2.3.1 가뭄 지수의 선정

가뭄은 강수량 부족으로부터 시작되며 지속되는 기간과 발생의 빈도에 따라 여러 가지 다양한 피해를 가져온다. 따라서 현재 가뭄의 상태가 어떠한지 평가하는 가뭄 감시(가뭄 모니터링)는 가뭄 상태를 평가하고자 하는 목적이 무엇인지에 따라 적합한 가뭄 지수를 선정하여 수행하게 된다. 예를 들어 농작물 생산량 등에 영향을 미치는 농업 가뭄을 보고자 할 경우 농작물 생산량이나 생산성과 높은 상관관계가 있는 가뭄 지수를 선정하며 물 가용량에 영향을 미치는 수문학적 가뭄을 보고자 하는 경우 댐유입량, 하천 유출량 등과 상관관계가 높은 지수를 선정하게 된다.

본 연구에서 JB, SB, GO 지역을 선정하기 위한 기준으로 전체 면적에 대한 쌀 수확 면적의 비율을 이용했지만 쌀 생산량이나 생산성을 가뭄 지수로 이용하지는 않았다. 이는 심각한 El Nino 영향 하에서는 가뭄이 쌀 생산량에 크게 영향을 미친다고 알려져 있으나(Tabor et al., 2015) 쌀 생산량이나 생산성은 연별 자료로만 획득이 가능하므로 월 단위로 생산되는 장기기후예측 자료 및 이에 기반을 둔 기계학습 모델을 평가하기에는 적합하지 않다고 판단하였기 때문이다.

본 연구에서는 기상학적 가뭄 지수로 가장 널리 사용되고 있으며 WMO (World Meteorological Organization)에서 사용을 권고하고 있는 SPI를 가뭄예측 모델의 목표 변수로 사용하였다. 선행시간이 6개월까지인 전구 기후모델을 이용하고 있으므로 선행시간에 따른 가뭄예측의 성능을 평가할 수 있도록 6개월 시간 스케일의 적용하여 SPI6를 목표 변수로 선정하였다(Figure 2-24).




Figure 2-24 SPI6 for Aug. 2015 (unitless).

2.3.2 가뭄예측 모델의 구축

국내의 가뭄지수 예측을 위해 이진영(2015)에 의해 개발된 기계학습 기반 가뭄예측 모델을 바탕으로 하여 인도네시아 가뭄지수 예측을 위한 기계학습 기반 가뭄예측 모델을 구축하였다. 국내의 미계측 유역 가뭄 예측을 위해 개발된 모델은 관측 지점에 대해 관측 값을 기반으로 하여 장기기후예측 자료를 적용시킨 지점 위치에 대한 예측 값이 존재하는 경우 지점이 없는 미계측 지역에 대한 가뭄 예측 정보를 생산하는 것을 목적으로 하였다.

본 연구에서는 인도네시아 지역에 대해 장기기후예측 모델의 Hindcast 기간에 대해 가용한 관측 자료가 없어, 앞서 서술한 바와 같이 위성을 중심으로 한 강우 합성장 자료를 관측 대신 활용하였다. 따라서 지점에만 존재하는 예측 자료를 미계측 유역으로 확장시키는 것을 목적으로 하기 보다는 원격 탐사 자료를 이용하여 가뭄 예측의 초기값을 강화시키고 원격 SST 등 대규모 기후-해양 상호작용을 반영하여 가뭄 예측을 개선하고자 하였다.

기계학습과 기계학습 모델에 대한 설명은 이진영(2015)에 상세히 나타나 있다. 이진영(2015)의 가뭄예측 모델과 마찬가지로, 가뭄 상황에서의 가뭄예측 성능을 향상시

키기 위해 Near Normal과 Moderate Drought 범주의 중간에 위치한 값인 -0.5를 기준으로 이용하여 이보다 가뭄이 심한 경우의 자료를 이용하여 기계학습 모델을 훈련하였다. 단, 이진영(2015)에서는 완벽한 예측을 가정하여 관측 값을 이용하여 기계학습 모델을 훈련시키고 성능 평가 시 장기기후예측 모델 값이나 기후 값을 적용하였다면, 이 경우 해당 입력 변수에 대한 가중치가 지나치게 커질 우려가 있어 본 연구에서는 장기기후예측 모델 값이나 기후 값을 그대로 이용하여 기계학습 모델을 훈련하였다.

2.3.2.1 기계학습 모델 및 변수 선정

이진영(2015)은 가뭄 예측을 위한 기계학습 모델 중 의사결정트리(Decision Tree), 랜덤포레스트(Random Forest), 극(極)랜덤트리(Extremely Randomized Tree; 이하 ERT) 모델을 사용하였는데, 본 연구에서는 이 중 가뭄 예측에 가장 우수한 성능을 보였던 ERT모델을 이용하였다. ERT 모델은 Geurts et al.(2006)에 의해 제안되었으며 각 노드에서 분할이 이루어지는 방식에 임의적인 요소가 추가되었다. 즉 랜덤포레스트에서는 각 잎에서 분할이 이루어질 때 입력 벡터 부분 집합이 가장 차별적으로 나뉘는 기준을 사용하는데, ERT 모델에서는 그 기준을 임의로 선택한 후에 그 중 가장 우수한 기준을 분할 규칙으로 선정한다.

국내 가뭄예측 모델에서 El Nino의 영향을 고려하기 위하여 Multivariate ENSO Index와 북극 진동의 영향을 반영하기 위해 Arctic Oscillation Index를 입력 변수에 포함하였는데, 인도네시아 지역은 우리나라에 비하여 원격상관이 크게 관찰되므로 El Nino의 영향을 볼 수 있는 Nino3 지역 이외에도 서부 적도 인도양 지역, SPCZ 지역의 SST가 입력 변수에 포함되었으며 Region A, B, C로 나누어 선정한 연구 대상 지역에 따라 각 지역의 국지적 SST도 입력 변수에 포함시켰다(Figure 2-25).

이진영(2015)의 가뭄예측 모델에서 입력 변수의 상대적인 중요도를 보았을 때 표준 강수증발산지수(Standardized Precipitation Evapotranspiration Index)를 예측하는 경우 증발산량의 중요도가 높게 나타났으나 SPI를 예측하는 경우에는 증발산량의 상대적 중요도가 그다지 높지 않았다. 본 연구에서는 목표 변수로 SPI6만을 사용하였고, Penman-Monteith 방법과 같이 물리적인 수식을 이용하여 증발산량을 산정

하기에 필요한 변수 값이 부재하므로 입력 변수에 증발산량을 포함시키지 않았다. 그러나 인도네시아 지역의 방대한 증발산량은 가뭄의 상태에 영향을 미치지 않을 수 없으므로 후속 연구에서는 원격탐사 자료에 기반을 두고 산정된 증발산량을 포함시킬 것이다. 또한 농경지의 관개 비율이 낮은 편이기 때문에 관측 값을 이용하여 검증하지는 못하였으나 원격 탐사 기반의 토양수분을 입력 변수에 포함하였다.

본 연구에서 이용한 입력 변수의 목록은 다음과 같다. 국지해의 SST의 경우 각 지역에 해당하는 변수만을 포함시켰다. 원격탐사 자료의 경우 각 월별로 최댓값과 최솟값을 이용하여 표준화하여 계절 효과를 제거하였으며 장기기후예측모델 자료의 경우 Quan et al.(2012)의 방법론대로 강수량 자료는 모델 아노말리의 증가율, SST 자료는 모델 아노말리의 차를 모델 기후 값에 적용시켜 예측값을 구하였다.

- 월(MONTH), 위도(LAT), 경도(LON), 고도(ELEV)
- 주간, 야간, 평균 지표면 온도(LST_DAY, LST_NIGHT, LST_MEAN)
- 정규식생지수(NDVI)
- 주간, 야간, 평균 토양수분(SM_DAY, SM_NIGHT, SM_MEAN)
- 위성 강우 합성장과 장기기후예측자료를 결합하여 산정한 SPI6 예측값(SPI6 FCST)
- Nino3 지역 SST 예측값: 위도 5°S - 5°N, 경도 150°W - 90°W (NINO3_SST FCST)
- 서부 적도 인도양의 SST 예측값: 위도 10°S - 10°N, 경도 50°E - 70°E (IO_SST FCST)
- SPCZ 지역의 SST 예측값: 위도 15°S - 25°S, 경도 160°E - 180°E (SPCZ_SST FCST)
- Region A의 남 말루쿠 티모르 해 SST 예측값: 위도 15°S - 5°S, 경도 120°E - 135°E (LOCAL_SST FCST)
- Region B의 남 중국 해 SST 예측값: 위도 1.5°S - 8°N, 경도 102°E - 110°E (LOCAL_SST FCST)
- Region C의 말루쿠 해 SST 예측값: 위도 6°S - 2°N, 경도 122°E - 135°E (LOCAL_SST FCST)




Figure 2-25 Remote and local regions with SST input data.

2.3.2.2 모델 설계 및 성능 평가 기준

기계학습 ERT 모델을 이용한 가뭄예측 모델은 인도네시아의 JB, SB, GO 세 지역에 대하여 구축하였다. 이진영(2015)가 각 장기기후예측 모델의 예측 값을 앙상블하여 장기기후예측 자료에 기반을 둔 가뭄예측과 과거 기후 값을 이용한 가뭄예측을 비교하였던 것과 비교하여 본 연구에서는 기후 값을 예측 값 대신 이용한 경우(이하 CLIM)를 하나의 모델처럼 다루어 MSC_CanCM3, MSC_CanCM4, NCEP, NASA, PNU, POAMA의 6개 장기기후예측 모델 예측 값과 함께 총 7가지 모델에 대해 가뭄예측을 별도로 수행하였다. 또한 1-6개월까지의 선행시간에 대해 별도의 모델이 구축되었다.

따라서 모두 3 지역 (JB, SB, GO)×7 모델 (MSC_CanCM3, MSC_CanCM4, NCEP, NASA, PNU, POAMA, CLIM)×6 선행시간 (Lead Time from 1 to 6 months)= 126개의 모델이 구축되었다. 기후 값을 예측 값 대신 이용할 때에는 Monte-Carlo Simulation을 적용하여 과거 같은 기간(달)에 대한 자료를 100회 추출하여 중간값(median)을 이용

하였다(Quan et al., 2012).

입력 변수 중 위성 강우 합성장과 장기기후예측 자료를 결합하여 산정한 SPI6 예측 값이 들어가게 되는데, 기계학습 모델을 거치지 않은 이 가뭄지수 예측 값을 기준 값으로 삼아 비교하였다.

모델의 성능 평가 기준은 이진영(2015)에서 제안한대로 Moderate Drought, Severe Drought, Extreme Drought의 가뭄 카테고리에 대한 생산자 정확도 (Producer's Accuracy)를 이용하여 정의하였다. 생산자 정확도는 어떠한 Class A에 대하여 실제 Class A에 속하는 샘플 수와 그 중 분류를 통해 Class A로 분류된 샘플 수의 비를 나타낸다. 생산자 정확도를 선택한 이유는 가뭄예측에 있어 만일 심한 가뭄으로 예측하였는데 그렇게 심한 가뭄이 오지 않은 경우 발생하는 비용보다 심한 가뭄이 아니라고 예측하였는데 극심한 가뭄이 발생한 경우에 발생한 비용이 더 크다고 가정하였기 때문이다.

즉, 성능 평가 기준으로 사용한 가뭄 정확도는 다음과 같다.

$$Drought\ Accuracy = \frac{C_{ED} + C_{SD} + C_{MD}}{N_{ED} + N_{SD} + N_{MD}} \quad (Eq. 2-2)$$

N은 실제로 각 Class에 속하는 샘플의 수이고 C는 그 중 그 Class로 맞게 분류된 샘플의 수이다.

ERT 모델은 감독 분류 및 회귀가 모두 가능하다. 회귀 모델의 경우 평균절대치오차 (Mean Absolute Error; MAE)를 성능 평가 기준으로 활용하였다. 가뭄에 대한 정보를 의사결정에 활용할 때 주로 가뭄 카테고리 정보가 사용되므로 분류 모델의 결과와 회귀를 수행하여 이를 다시 McKee et al.,(2003)의 가뭄 카테고리에 맞추어 재차 분류한 결과를 비교하였다.

2.3.2.3 매개변수 최적화 및 교차 검증

ERT 모델에 있어 트리의 최대심도(MAX_DEPTH)와 트리의 개수(NUM_TREES)에 대한 최적화를 실행하였다. 즉 MAX_DEPTH의 값을 [3, 5, 10, 완전히 성장시키는 경우]에 대해서 변화시키고 NUM_TREES를 [10개, 50개, 100개, 200개]로 변화시켜 이러한 조합 중 앞서 제시한 성능 평가 기준을 이용하여 모델이 성능이 우수한 경우의 매개변수를 선정하여 이용하였다.

이진영(2015)에서 제안한 바와 같이 과적합을 피하기 위해 각 연도 별로 1년씩 제외한 자료를 이용하여 모델을 훈련시키고 그 제외된 1년의 자료를 이용하여 성능을 평가하는 Leave-1Year-Out 교차검증을 수행하였다. 하나의 트리만을 이용하는 의사결정 트리 모델에 비하여 ERT 모델은 여러 개의 트리를 앙상블하여 이용하므로 과적합이 적은 것으로 알려져 있으나 자료의 기간이 짧아 이 짧은 기간에 나타나지 않았던 기상학적/기후학적 양상이 나타날 수 있으므로 정확도를 객관적으로 평가하기 위해 이와 같은 과정을 포함시켰다.

3. 결과 및 토의

3.1 가뭄 예측 성능의 평가

인도네시아의 JB, SB, GO의 세 지역, 1개월에서 6개월까지의 예측 선행시간, MSC_CanCM3, MSC_CanCM4, NCEP, NASA, PNU, POAMA, CLIM의 7개 모델에 대해 기계 학습 모델(이하 ML)의 가뭄지수 SPI6의 예측 성능을 평가하였다. 기준 값(baseline)으로 기계 학습 모델을 통하지 않고 장기기후예측 모델이나 기후 값을 그대로 사용하는 경우(이하 FCST)의 가뭄 정확도 및 회귀 MAE를 이용하였다. 모든 경우, 가뭄 카테고리 분류를 위해서는 분류 모델을 구축하여 가뭄지수의 카테고리를 예측한 경우보다 회귀 모델을 구축하여 적용한 다음 가뭄 카테고리에 맞추어 재분류한 경우의 가뭄 정확도가 더 높았다(자료 미제시). 따라서 본 장에서 기계학습 분류 모델의 결과는 제시하지 않았으며 회귀 모델 결과를 재분류한 경우에 대한 가뭄 정확도 및 회귀 MAE를 중심으로 분석을 수행하였다.

3.1.1 서부 자바(JB) 지역

3.1.1.1 가뭄 정확도

MSC_CanCM3 모델을 제외한 모든 경우, 선행시간이 1개월인 경우에만 기준 값으로 삼은 FCST의 가뭄 정확도가 ML의 경우보다 높았으며 선행시간이 2-6개월인 경우 모두 ML의 가뭄 정확도가 높았다(Figure 3-1). MSC_CanCM3 모델의 경우에는 선행시간이 1-2개월인 경우까지 FCST의 가뭄 정확도가 높고 3-6개월에는 ML의 가뭄 정확도가 높았다(Figure 3-1a).

이진영(2015)에서 나타난 바와 같이 본 연구의 목표 변수인 SPI6는 6개월 강수 누적 값을 사용하므로 선행시간이 길어질수록 이미 존재하는 관측 값의 비율이 낮아지고 예측 값의 비중이 커진다. 선행시간이 6개월인 경우에는 6개월 강수 누적 값에 관측 값은 존재하지 않고 모두 예측 값으로 이루어지게 되는데, 따라서 가뭄 지수의 예측 성능도 상대적으로 낮아지게 된다. 그러나 기계학습 모델을 이용한 경우 긴 선행시간에 대해서도 어느 정도의 가뭄 정확도가 유지되는 것을 알 수 있다(Figure 3-1).

모델 간의 예측 성능을 비교하면, 1개월 선행시간에서는 기계학습 모델을 거치지 않고 직접 MSC_CanCM3 모델과 MSC_CanCM4 모델의 예측 값을 이용하는 경우가 가뭄 정확도가 가장 높았으며 CLIM이나 PNU 모델도 비슷한 정확도를 보였고, 2개월 선행시간에 대해서는 기계학습 모델을 이용한 경우의 예측 성능이 더 높지만 장기기후예측 모델 결과 값 보다는 기후 값을 이용한 경우(CLIM)의 가뭄 정확도가 가장 높았다(Figure 3-2; Table 3-1). 3-6개월의 선행시간에 대해서는 장기기후예측 모델 결과 값을 이용하여 기계학습 모델을 구축한 경우의 가뭄 정확도가 높았는데, 모델들 간에 차이가 있어 3개월 선행시간의 경우 MSC_CanCM4 모델과 POAMA 모델의 경우가 CLIM과 마찬가지로 가뭄 정확도가 높았으며(Figure 3-2; Table 3-1) 선행시간 4-6개월의 경우는 모두 NASA 모델이 가장 우수한 결과를 보였다(Figure 3-2a; Table 3-1a)




Figure 3-1 Drought Accuracy based on ML and FCST in the JB region.




Figure 3-2 Comparisons between models for Drought Accuracy based on ML and FCST in the JB region.

Table 3-1 Drought Accuracy based on ML and FCST in the JB region.

(a) ML

Model / LT	1	2	3	4	5	6
CLIM	0.47	0.39	0.32	0.30	0.31	0.34
MSC_CanCM3	0.40	0.32	0.28	0.31	0.33	0.36
MSC_CanCM4	0.35	0.32	0.32	0.31	0.31	0.33
NASA	0.42	0.36	0.31	0.32	0.35	0.37
NCEP	0.37	0.32	0.27	0.30	0.29	0.31
PNU	0.42	0.34	0.29	0.28	0.26	0.29
POAMA	0.40	0.35	0.32	0.27	0.28	0.28

(b) FCST

Model / LT	1	2	3	4	5	6
CLIM	0.48	0.27	0.11	0.06	0.02	0.00
MSC_CanCM3	0.49	0.35	0.21	0.16	0.11	0.07
MSC_CanCM4	0.49	0.30	0.19	0.16	0.14	0.08
NASA	0.42	0.28	0.16	0.07	0.02	0.02
NCEP	0.41	0.28	0.08	0.06	0.05	0.09
PNU	0.48	0.30	0.19	0.14	0.04	0.01
POAMA	0.47	0.30	0.21	0.12	0.09	0.04

3.1.1.2 회귀 MAE

회귀 MAE의 경우도 가뭄 정확도와 마찬가지로, MSC_CanCM3 모델을 제외한 모든 경우 선행시간이 1개월인 경우에만 기준 값으로 삼은 FCST의 MAE가 ML의 경우보다 낮았으며 선행시간이 2-6개월인 경우 모두 ML의 MAE가 낮았다(Figure 3-3). MSC_CanCM3 모델의 경우에는 선행시간이 1-2개월인 경우까지 FCST의 MAE가 낮고 3-6개월에는 ML의 MAE가 낮았다(Figure 3-3a).

모델 간 비교를 보면, 1개월 선행시간의 경우에만 기계 학습 모델을 적용하지 않은 CLIM의 경우가 MAE가 가장 낮았고(Figure 3-4b, Table 3-2b) 나머지 경우는 모두 ML의 MAE가 낮았는데 특히 NASA 모델의 경우가 작은 오차 값을 보였다(Figure 3-4a, Table 3-2a).




Figure 3-3 Regression MAE based on ML and FCST in the JB region.




Figure 3-4 Comparisons between models for regression MAE based on ML and FCST in the JB region.

Table 3-2 Regression MAE based on ML and FCST in the JB region.

(a) ML

Model / LT	1	2	3	4	5	6
CLIM	0.35	0.48	0.55	0.62	0.64	0.60
MSC_CanCM3	0.44	0.54	0.60	0.64	0.64	0.62
MSC_CanCM4	0.46	0.58	0.60	0.64	0.64	0.62
NASA	0.39	0.47	0.55	0.60	0.63	0.60
NCEP	0.50	0.53	0.62	0.65	0.67	0.62
PNU	0.38	0.53	0.59	0.68	0.73	0.68
POAMA	0.43	0.51	0.62	0.66	0.69	0.64

(b) FCST

Model / LT	1	2	3	4	5	6
CLIM	0.31	0.54	0.78	1.02	1.26	1.47
MSC_CanCM3	0.36	0.52	0.76	0.99	1.20	1.48
MSC_CanCM4	0.41	0.64	0.86	1.04	1.23	1.38
NASA	0.36	0.53	0.78	1.07	1.43	1.61
NCEP	0.50	0.62	0.95	1.24	1.50	1.55
PNU	0.36	0.62	0.88	1.07	1.45	1.69
POAMA	0.42	0.62	0.83	1.11	1.21	1.48

3.1.2 서부 수마트라(SB) 지역

3.1.2.1 가뭄 정확도

SB 지역의 가뭄예측은 JB 지역과 매우 다른 결과를 보여준다. 가뭄 정확도의 경우 ML과 FCST의 차이가 크지 않으며 모델 및 선행시간에 따라 ML의 가뭄 정확도가 높기도 하고 FCST의 가뭄 정확도가 높게 나타나기도 한다(Figure 3-5). MSC_CanCM3, NCEP 모델과 CLIM의 경우는 모든 선행시간에서 ML이 FCST보다 가뭄 정확도가 같거나 높지만 다른 모델에서는 비슷한 값을 보인다(Figure 3-5).

모델 간 가뭄 정확도를 비교하여도 선행시간에 따라 높은 가뭄 정확도를 보이는 모델이나 방법론의 경우가 뒤섞여 나타난다(Figure 3-6, Table 3-3). 다만 NASA 모델의 경우 2개월, 4개월 및 5개월 선행시간의 경우 기계 학습을 적용시키지 않은 FCST에서 가장 높은 가뭄 정확도를 보였다(Figure 3-6b, Table 3-3b).




Figure 3-5 Drought Accuracy based on ML and FCST in the SB region.




Figure 3-6 Comparisons between models for Drought Accuracy based on ML and FCST in the SB region.

Table 3-3 Drought Accuracy based on ML and FCST in the SB region.

(a) ML

Model / LT	1	2	3	4	5	6
CLIM	0.37	0.24	0.16	0.13	0.13	0.14
MSC_CanCM3	0.38	0.29	0.23	0.10	0.16	0.13
MSC_CanCM4	0.43	0.23	0.22	0.14	0.12	0.08
NASA	0.30	0.21	0.13	0.15	0.13	0.15
NCEP	0.37	0.23	0.08	0.10	0.08	0.09
PNU	0.26	0.15	0.14	0.09	0.05	0.06
POAMA	0.32	0.14	0.17	0.13	0.07	0.09

(b) FCST

Model / LT	1	2	3	4	5	6
CLIM	0.37	0.21	0.08	0.04	0.01	0.00
MSC_CanCM3	0.37	0.22	0.13	0.09	0.03	0.02
MSC_CanCM4	0.42	0.29	0.19	0.15	0.10	0.03
NASA	0.36	0.32	0.19	0.18	0.17	0.09
NCEP	0.36	0.20	0.08	0.03	0.02	0.00
PNU	0.28	0.19	0.08	0.06	0.08	0.04
POAMA	0.27	0.22	0.12	0.09	0.13	0.05

3.1.2.2 회귀 MAE

가뭄 정확도의 경우 ML과 FCST 사이의 확연한 성능 차이가 드러나지 않은 것에 반하여 회귀 MAE의 경우에는 모든 모델과 선행시간에서 ML의 경우가 오차 값이 낮게 나타났다(Figure 3-7). 특히 FCST의 경우 선행시간이 길어지면 오차가 증가하게 되는데 ML의 경우 일정한 오차 범위를 유지하고 있다(Figure 3-7). 그럼에도 불구하고 ML의 가뭄 정확도가 FCST와 비슷한 값을 가지는 것은 오차 값의 범위가 작더라도 가뭄 카테고리의 차인 0.5를 전후하면서 예측 결과의 가뭄 카테고리가 다르게 분류될 수 있기 때문인 것으로 보인다.

모델 간의 차이를 보면 1-4개월의 선행시간에서 MSC_CanCM3 모델과 MSC_CanCM4 모델이 가장 낮은 오차를 보였으며 5개월 선행시간에서는 MSC_CanCM4 모델과 NCEP 모델이, 그리고 6개월 선행시간에서는 NASA 모델과 CLIM이 가장 낮은 오차를 보였다(Figure 3-8, Table 3-4).




Figure 3-7 Regression MAE based on ML and FCST in the SB region.




Figure 3-8 Comparisons between models for regression MAE based on ML and FCST in the SB region.

Table 3-4 Regression MAE based on ML and FCST in the SB region.

(a) ML

Model / LT	1	2	3	4	5	6
CLIM	0.32	0.40	0.45	0.42	0.43	0.40
MSC_CanCM3	0.30	0.36	0.37	0.40	0.43	0.42
MSC_CanCM4	0.30	0.36	0.37	0.40	0.42	0.43
NASA	0.35	0.42	0.43	0.42	0.43	0.40
NCEP	0.32	0.40	0.44	0.43	0.42	0.42
PNU	0.39	0.44	0.47	0.43	0.46	0.44
POAMA	0.35	0.44	0.45	0.45	0.48	0.42

(b) FCST

Model / LT	1	2	3	4	5	6
CLIM	0.35	0.56	0.78	0.95	1.12	1.31
MSC_CanCM3	0.35	0.53	0.64	0.86	1.00	1.17
MSC_CanCM4	0.36	0.51	0.64	0.79	0.85	1.10
NASA	0.40	0.50	0.65	0.78	0.83	1.05
NCEP	0.37	0.61	0.93	1.12	1.24	1.48
PNU	0.52	0.88	1.27	1.71	1.98	2.24
POAMA	0.47	0.70	0.94	1.10	1.20	1.29

3.1.3 고론탈로 (GO) 지역

3.1.3.1 가뭄 정확도

GO 지역은 JB와 유사하면서도 다른 결과를 보이는데, 특히 ML의 예측 성능이 FCST에 비하여 높게 나타난다. 또한 결과로 나타나는 가뭄 정확도가 JB 지역 및 SB 지역에 비해 상당히 높게 나타난다(Figures 3-1, 3-5, 3-9).

JB 지역에서는 선행시간이 2-6개월의 경우에는 대부분 ML의 가뭄 정확도가 높게 나타났음에도 1개월 선행시간에는 모든 경우 FCST의 가뭄 정확도가 높았다(Figure 3-1). 그런데 GO 지역에서는 NCEP 모델과 PNU 모델을 제외하고는 1개월 선행시간을 포함한 모든 선행시간에서 ML의 가뭄 정확도가 FCST보다 높게 나타난다(Figure 3-9). NCEP 모델의 경우 1개월 선행시간에서만 FCST의 가뭄 정확도가 ML보다 높고

PNU 모델의 경우 1-2개월 선행시간의 경우 FCST의 가뭄 정확도가 ML보다 높게 나타난다. 다른 모든 경우 ML의 가뭄 정확도가 높다(Figure 3-9).

모델간 예측 성능을 비교해 보면, 1개월 선행시간에서는 기계 학습을 적용하지 않은 PNU 모델의 FCST 값이 가장 가뭄 정확도가 높았다. 다른 선행시간에서는 ML의 가뭄 정확도가 높았는데 JB 지역에서 2-3개월 선행시간에서 CLIM의 가뭄 정확도가 높았던 것과 같이 GO 지역에서도 2-3개월 및 5개월 선행시간에서 CLIM의 가뭄 정확도가 높게 나타났다(Figure 3-10a, Table 3-5a).




Figure 3-9 Drought Accuracy based on ML and FCST in the GO region.




Figure 3-10 Comparisons between models for Drought Accuracy based on ML and FCST in the GO region.

Table 3-5 Drought Accuracy based on ML and FCST in the GO region.

(a) ML

Model / LT	1	2	3	4	5	6
CLIM	0.54	0.57	0.54	0.54	0.56	0.51
MSC_CanCM3	0.55	0.52	0.48	0.45	0.50	0.54
MSC_CanCM4	0.53	0.48	0.47	0.43	0.43	0.49
NASA	0.56	0.49	0.48	0.46	0.47	0.50
NCEP	0.49	0.45	0.47	0.54	0.51	0.48
PNU	0.51	0.38	0.41	0.55	0.43	0.46
POAMA	0.54	0.56	0.54	0.53	0.53	0.53

(b) FCST

Model / LT	1	2	3	4	5	6
CLIM	0.41	0.20	0.11	0.04	0.02	0.00
MSC_CanCM3	0.44	0.22	0.08	0.04	0.00	0.00
MSC_CanCM4	0.46	0.27	0.14	0.02	0.00	0.00
NASA	0.46	0.32	0.19	0.09	0.03	0.02
NCEP	0.55	0.44	0.37	0.24	0.20	0.16
PNU	0.57	0.41	0.34	0.13	0.04	0.00
POAMA	0.52	0.48	0.30	0.27	0.18	0.18

3.1.3.2 회귀 MAE

GO 지역의 회귀 MAE의 경우도 JB 지역과 유사한 결과를 보여주는데, 다만 오차 값의 범위가 JB 지역 및 SB 지역에 비해 더 작다(Figures 3-2, 3-6, 3-10).

NCEP, PNU, POAMA 모델의 경우만 1개월 선행시간에서 ML이 FCST보다 큰 오차 값을 보여주며 나머지 경우는 모두 ML의 MAE가 FCST보다 작다(Figure 3-11). 다른 지역과 마찬가지로 FCST의 오차 값은 선행시간이 길어질수록 눈에 띄게 증가하는데 ML의 경우에는 일정한 오차 범위를 유지하고 있다(Figure 3-11).

모델 간 결과를 비교하면 가장 성능이 좋은 경우는 모두 ML에 해당하며 1, 2개월 선행시간의 경우 NASA 모델이, 3개월 선행시간의 경우 MSC_CanCM4 모델과 PNU 모델이, 그리고 4-6개월 선행시간의 경우 PNU 모델이 가장 작은 오차 값을 보인다(Figure 3-12, Table 3-6).




Figure 3-11 Regression MAE based on ML and FCST in the GO region.




Figure 3-12 Comparisons between models for regression MAE based on ML and FCST in the GO region.

Table 3-6 Regression MAE based on ML and FCST in the GO region.

(a) ML

Model / LT	1	2	3	4	5	6
CLIM	0.27	0.31	0.36	0.38	0.39	0.41
MSC_CanCM3	0.25	0.31	0.36	0.39	0.38	0.41
MSC_CanCM4	0.25	0.31	0.33	0.41	0.42	0.42
NASA	0.23	0.29	0.35	0.39	0.40	0.41
NCEP	0.30	0.35	0.39	0.40	0.39	0.43
PNU	0.27	0.34	0.33	0.29	0.31	0.34
POAMA	0.32	0.31	0.37	0.41	0.42	0.44

(b) FCST

Model / LT	1	2	3	4	5	6
CLIM	0.29	0.48	0.69	0.88	1.06	1.26
MSC_CanCM3	0.28	0.47	0.72	0.93	1.15	1.50
MSC_CanCM4	0.26	0.44	0.65	1.00	1.39	1.70
NASA	0.26	0.37	0.58	0.79	1.06	1.38
NCEP	0.26	0.36	0.42	0.53	0.61	0.72
PNU	0.24	0.40	0.52	0.74	0.94	1.25
POAMA	0.26	0.33	0.52	0.68	0.79	0.90

3.1.4 지역 간 비교

앞서 JB, SB, GO 세 지역에 대해 ML과 FCST에 의한 각 선행시간과 모델별 가뭄 정확도 및 회귀 MAE 결과를 살펴보았다. 이 결과 중 각 지역과 선행시간에 대해 가장 우수한 예측 성능을 보인 경우(이하 BEST)만을 이용하여 지역별 차이를 살펴보았다 (Figure 3-13).

모든 선행시간에 있어 본 연구를 통해 시험한 모델의 가뭄지수 예측 성능은 가뭄 정확도 및 회귀 MAE에 있어 GO 지역에서 가장 높게 나타났다(Figure 3-13). JB 지역과 SB 지역은 가뭄 정확도와 회귀 MAE에 따라 다른 결과를 얻을 수 있었는데, 모든 선행시간에서 가뭄 정확도는 JB 지역에서 높게 나타났지만 회귀 MAE에 있어서는 SB 지역의 오차 값이 작게 나타났다(Figure 3-13). 이러한 차이는 모델의 구축 및 성능 평가에 이용한 표본 수의 차이 때문인 것으로 보인다. 즉 모든 입력 변수의 값

이 유효한 입력 벡터만이 모델의 구축이나 성능 평가에 사용될 수 있는데 JB 지역의 경우 상대적으로 가용한 입력 벡터의 수가 많아 대략적으로 SB, GO 지역에 비해서 두 배 정도의 표본 수를 활용할 수 있었다(자료 미제시). 따라서 MAE 산정에 있어 큰 표본 수에 영향을 받아 MAE 값이 증가한 것으로 보인다. 가뭄 정확도의 경우 표본 수에 영향을 받지 않았다.

가뭄 정확도가 GO, JB, SB 지역 순으로 예측 성능이 높은 것은 Aldrian and Susanto(2003)가 관측 자료를 이용하여 Region A, B, C를 El Nino 등에 영향을 받는 지역 순으로 Region C, Region A, Region B 로 설명한 것과 관련이 있는 것으로 보인다. 또한 앞서 장기기후예측 모델의 예측 성능을 살펴보았을 때 GO 지역과 그 주변 지역이 모델 예측 성능이 높은 것도 하나의 원인으로 꼽을 수 있다. 가뭄지수 예측 모델의 각 입력 변수가 어느 정도의 기여를 했는지는 기계 학습 모델이 제시하는 각 입력 변수의 상대적인 중요도를 통해 다음 절에서 살펴보았다.




Figure 3-13 Regional comparison of Drought Accuracy and regression MAE.

3.2 입력 변수의 상대적 중요도

지역별, 선행시간별, 모델별로 구축된 기계학습 회귀모델에 대해 입력 변수의 상대적 중요도를 얻을 수 있었다. 가뭄 카테고리 재분류를 위해 사용한 회귀 모델과, 회귀를 위해 사용한 회귀 모델 간에 큰 차이가 나타나지 않았으므로 본 절에서는 가뭄 카테고리 재분류를 위해 사용한 회귀 모델의 입력 변수 상대적 중요도를 살펴 보았다. Leave-1Year-Out 교차검증을 적용하였으므로 입력 변수의 상대적 중요도는 2003년에서 2015년까지의 기간 중 장기기후예측 모델 결과가 존재하는 기간에 대해 1년씩 제외한 총 8년에 대해 각각 주어진다. 분석의 편의를 위하여 이를 평균하여 살펴보았다.

3.2.1 서부 자바 (JB) 지역

JB 지역에서 가뭄예측을 위해 가장 중요한 변수를 꼽으면 SPI6 예측값(SPI6 FCST), 월(MONTH), 그리고 NINO3 지역의 SST 예측값(NINO3_SST FCST)을 들 수 있다. 선행시간이 짧은 경우는 SPI6 예측값의 중요도가 가장 높으며 길어질수록 NINO3 지역의 SST 예측값의 중요도가 높아진다. 이어서 국지 및 다른 지역의 원격 SST 예측이 중요한 변수로 나타났는데, 반면 원격 탐사한 지표면온도, 식생지수, 토양수분 등의 가뭄 상태 초기 값의 중요도는 대부분의 경우 상대적으로 낮았다(Figure 3-14). 이진영(2015)의 연구에 비해 원격탐사 입력 변수들의 상대적 중요도가 낮게 나타난 까닭은, 이진영(2015)의 연구에서는 지점 자료를 이용하여 모델을 훈련하고 미계측 유역의 가뭄예측을 위해 모델을 적용하였기 때문에 예측 자료가 없는 미계측 지역에서 원격탐사 입력 변수의 중요도가 높아졌기 때문이다. 본 연구에서는 관측 지점 자료의 부재로 격자 기반의 위성 자료를 관측 자료로 사용했으므로 미계측 지역에 대해 예측을 수행한 것이 아니며 다만 가뭄의 초기 상태에 대한 정보를 제공하여 예측 성능을 높이기 위해 원격탐사 입력 변수를 활용하였다.

3.2.2 서부 수마트라 (SB) 지역

SB 지역에서는 월(MONTH)의 상대적 중요도는 NCEP 모델을 적용한 경우를 제외하고는 크지 않게 나타났는데, 반면 지역의 위치적인 정보가 중요한 것으로 드러났다(Figure 3-15). 대부분의 경우 가장 중요한 변수는 SPI6 예측 값인데 그 다음이 위도(LAT)이며 경도(LON) 정보도 매우 중요한 것으로 나타났다(Figure 3-15). 위경도의 상대적 중요도가 높은 원인에 대해서는 추가적인 분석이 필요하나, 동서 방향으로 길쭉한 GO 지역이나 전체적으로 조밀하게 뭉쳐있는 JB 지역에 비하여 사선으로 길게 놓여있는 SB 지역의 형태도 관련이 있는 것으로 생각된다.

국지 및 원격 SST 예측 값도 원격 탐사 가뭄 상태 초기 값에 비하여 상대적으로 중요하게 나타났다. 하지만 원격 탐사 변수들의 경우 JB 지역에 비해서는 중요도가 약간 높게 나타났다(Figure 3-15).

3.2.3 고론탈로 (GO) 지역

GO 지역의 입력 변수의 상대적 중요도는 JB 지역과 유사하게 나타나기는 하나 SPCZ 지역 SST 예측 값의 중요도가 좀 더 부각된다(Figure 3-16). 특히 4개월 선행 시간에서 PNU 모델을 적용한 경우나 6개월 선행시간에서 MSC_CanCM3 모델을 적용한 경우 등 가장 우수한 예측 성능을 보인 경우에 SPCZ 지역의 SST 예측값의 상대적 중요도가 가장 높았다(Figure 3-16).

3.2.4 지역 간 비교

세 지역 모두 선행시간이 짧은 경우에는 SPI6 예측 값의 중요도가 압도적으로 크게 나타났다(Figures 3-14 to 3-16). 선행시간이 길어지면 다른 변수의 중요도가 커지게 되는데, 입력 변수로 사용한 장기기후예측 모델에 따라 다르게 나타나기는 하지만 JB 지역에서는 특히 NINO3 지역 SST 예측 값, SB 지역에서는 위도(LAT), GO 지역에서는 NINO3 지역과 SPCZ 지역의 SST 예측 값의 중요도가 높았다.

지역별로 나타난 입력 변수의 상대적 중요도의 차이는 각 지역별로 드러난 가뭄지수

예측 성능의 차이와 연관이 있다. 즉 GO 지역에서 여러 국지 및 원격의 SST 예측 값의 중요도가 높다는 것은 그러한 변수들을 통해 가뭄지수를 더 잘 예측할 수 있다는 의미이며 따라서 높은 가뭄지수 예측 성능으로 연결된다고 볼 수 있다. SB 지역에서도 국지 및 원격 SST 예측 값의 중요도가 꽤 높기는 하지만 이들의 영향 보다는 지역의 위경도와 같은 위치적인 정보가 더 중요하게 나타나는데 이는 그러한 대규모 기후-해양의 상호작용으로부터 가뭄지수 예측 성능을 올릴 수 있는 정보를 그만큼 덜 얻을 수 있다는 의미가 될 수 있다.




Figure 3-14 Averaged relative importance of input variables for machine learning models in the JB region.




Figure 3-15 Averaged relative importance of input variables for machine learning models in the SB region.




Figure 3-16 Averaged relative importance of input variables for machine learning models in the GO region.

3.3 가뭄예측 사례 분석

최근의 2015/2016 El Nino와 관련 있는 인도네시아 가뭄을 대상으로 가뭄예측 사례 분석을 실시하였다. 해당 가뭄으로 인하여 인도네시아에서 2015년 8월 이후 1백2천만 명이 넘는 인구가 식량 위기를 겪었으며 2015년 말 우기에 비가 내리지 않아 이러한 가뭄이 지속되었다(GLIDE, 2016). 국가재난관리기관인 BNPB는 발리 지역에 가뭄 경고를 내렸으며(ADRC, 2016), 2015년에 16개도의 102개 구역/시, 721개 소구역이 물부족을 겪은 것으로 알려졌다(DMCDD, 2015). Ministry of Agriculture에서는 자바 섬 지역의 가뭄이 가장 큰 것으로 보았으며 이 지역에서만 111,000ha의 지역이 농업적 가뭄을 겪고 8,000ha의 지역에서 농작물이 피해를 입었다(DMCDD, 2015). 집중적인 피해를 입은 곳은 인도네시아의 적도 남쪽 부분과 동부 지역으로 남부 수마트라, 자바, 서부 누사텐가라, 발리, 동부 누사 텐가라, 남부 술라웨시, 칼리만탄 일부와 동부 인도네시아 지역을 포함한다(DMCDD, 2015; Figure 3-17).




Figure 3-17 Indonesian region affected by drought in 2015 (Source: DMCDD, 2015).

본 연구의 대상 지역인 JB, SB, GO 지역 중 2015년 가뭄에 피해를 많이 입은 JB 지역에 대해 2015년 8월부터 12월까지 가뭄 예측을 실시하였다. 가뭄 정확도가 가장 높은 경우와 회귀 MAE가 가장 작은 다음의 경우에 따라 장기기후예측 값을 이용하거나 기계학습 모델을 구축하였고 산정된 SPI6 예측 값을 실제 관측 값과 비교하였다.

실제 가뭄예측 모델을 활용할 때 어느 선행시간에는 어느 모델을 이용하고 다른 선행시간에는 또 다른 모델을 이용하는 등 가뭄 정확도나 회귀 MAE의 조금의 차이에 따라 다른 모델을 적용하는 것은 적합하지 않을 수 있다. 그러나 본 보고서에서는 각 결과의 성능을 평가하고자 하므로 각 지역이나 선행시간에 대해서 가장 우수한 결과를 보인 방법론 및 모델의 결과를 중심으로 가뭄예측 결과를 살펴보았다.

3.3.1 가뭄지수 지도

가뭄예측 회귀 모델을 위해 선정된 방법론과 모델을 이용하여 JB 지역의 2015년 8월에서 12월까지 가뭄지수 예측 값을 생산하고(BEST) 관측 값과 비교해 보았으며, 기계학습 모델을 쓰지 않고 장기기후예측모델 결과를 그대로 사용한 경우(이하 FCST_ONLY)를 선행시간 2개월 이상에서도 비교하여 보았다(Figures 3-18 to 3-27).

가뭄 카테고리 분류 - BEST

- 1개월 선행시간: MSC_CanCM3 모델의 예측 값을 그대로 이용
- 2-3개월 선행시간: CLIM(기후값)을 이용한 기계학습 모델 이용
- 4-6개월 선행시간: NASA 모델의 예측값을 이용한 기계학습 모델 이용

가뭄지수 회귀 - BEST

- 1개월 선행시간: CLIM(기후값)을 그대로 이용
- 2-6개월 선행시간: NASA 모델의 예측값을 이용한 기계학습 모델 이용

가뭄 카테고리 분류 - FCST_ONLY

- 1-3개월 선행시간: MSC_CanCM3 모델의 예측 값을 그대로 이용
- 4-5개월 선행시간: MSC_CanCM4 모델의 예측 값을 그대로 이용
- 6개월 선행시간: NCEP 모델의 예측 값을 그대로 이용

가뭄지수 화귀 - FCST_ONLY

- 1개월 선행시간: CLIM(기후값)을 그대로 이용
- 2-5개월 선행시간: MSC_CanCM3 모델의 예측 값을 그대로 이용
- 6개월 선행시간: MSC_CanCM4 모델의 예측 값을 그대로 이용

2015년 8월의 관측 값을 보면 JB 북부 지역의 가뭄에도 불구하고 대부분의 지역에서 가뭄이 발생하지 않은 것으로 나타난다(Figure 3-18a). 가장 우수한 방법론과 모델을 이용한 BEST를 보면 1-4개월 선행시간까지 8월을 목표로 예측한 경우에는 어느 정도 차이는 있으나 일부 북부 지역의 가뭄과 다른 지역의 비 가뭄을 비교적 잘 예측하고 있다(Figure 3-18). 하지만 선행시간 2-6개월의 결과에서 볼 수 있듯 기계학습 모델을 이용한 경우 JB의 북쪽 지역에는 예측 값을 생산하지 못하였는데, 이는 기계학습 모델의 입력 변수 가운데 토양수분 자료가 이 지역에는 존재하지 않아 모델을 적용하지 못하였기 때문이다. 5-6개월 선행시간의 경우에는 전체 지역에 대해 Moderate Drought에 해당하는 가뭄지수 값으로 예측하고 있는데, 이로부터 기계학습 모델에 기반을 둔 가뭄예측의 경우 실제보다 가뭄을 과도하게 예측할 수 있음을 알 수 있다(Figure 3-18). 장기기후예측 모델 자료만 이용한 FCST_ONLY 결과를 보면 3-6개월 선행시간 예측의 경우 JB 북부 지역의 가뭄을 전혀 예측하지 못하고 있다(Figure 3-19).

2015년 9월의 경우 8월에 비하여 가뭄 발생 지역이 서부 지역으로 확장되어 대략적으로 JB 지역의 반 정도가 가뭄 상태에 놓이게 된다(Figure 3-20a). BEST의 경우 1-4개월 선행시간의 가뭄지수 예측은 관측에 상당히 가깝게 나타나나 5-6개월 선행시

간의 경우 8월의 경우와 마찬가지로 전체 지역에 대해 Moderate Drought에 해당하는 값만을 예측하고 있다(Figure 3-21). FCST_ONLY의 경우에는 1-2개월 선행시간에 대해서만 북서부의 가뭄을 잘 예측하며 3-6개월에 대해서는 대부분의 지역을 비 가뭄으로 예측하고 있다(Figure 3-21). 즉, 기계학습 모델과는 상반되게 장기기후예측 모델 결과만을 이용하는 경우 가뭄 상태를 실제보다 심각하지 않게 예측하였다.

2015년 10월에는 가뭄이 JB의 동부 일부 지역을 제외하고는 전반적으로 확대되었으며 특히 북서쪽 지역의 가뭄은 더욱 심화되어 Severe Drought에서 Extreme Drought에 해당하는 값을 보여준다(Figure 3-22a). BEST의 경우에는 2-6개월 선행시간 예측의 경우 전체 지역에 대한 가뭄 상태를 예측하고 있는데 다만 Moderate Drought이나 Severe Drought에 해당하는 값을 중심으로 예측하고 있어 Extreme Drought에 해당하는 극심한 가뭄을 예측하고 있지는 않다(Figure 3-22). 1개월 선행시간의 경우 CLIM을 그대로 사용한 것인데, 1개월의 자료만을 기후 값으로 대체했음에도 불구하고 가뭄의 심화를 예측하지 못하였다(Figure 3-22). FCST_ONLY를 보면 2-3개월 선행시간으로 MSC_CanCM3 모델 결과를 그대로 이용한 경우가 관측 값에 매우 가깝다(Figure 3-23). 하지만 4-6개월의 경우 중앙에서 동쪽으로 확장된 가뭄 상태와 심화된 북서부의 가뭄을 예측하지는 못하였다(Figure 3-23).

2015년 11월에는 JB 지역에서 가뭄이 먼저 시작되어 심화되었던 북서부 지역에서는 전반적으로 가뭄 상태가 완화되며 대신 가뭄이 확장된 동부의 가뭄은 여전히 10월보다 심화되었다(Figures 3-24a). BEST의 1개월 선행시간 예측은 이러한 급격한 변화를 예측하지 못하고 오히려 북서부의 심한 가뭄과 남동부의 비 가뭄 상태를 예측하고 있으며 2-6개월 기계학습에 기반을 둔 가뭄 예측도 공간적인 분포 차이를 예측하지 못하였다(Figure 3-26). FCST_ONLY는 2-6개월 선행시간 가뭄예측에서 MSC_CanCM3 및 MSC_CanCM4 모델 결과로 전반적으로 극심한 가뭄을 예측하고 있다. 특히 이미 완화된 서부의 상태를 예측하지 못하였다(Figure 3-25).

2015년 12월은 11월과 비슷한 가뭄 상황인데, BEST의 경우 1개월 선행시간의 경우만 비 가뭄으로 해소되는 가뭄 상황을 예측하고 있으며 8월의 경우처럼 2-6개월 가뭄예측의 경우는 가뭄 상태를 전체 지역에 대해 과도하게 예측하고 있다(Figure 3-26). FCST_ONLY의 2-6개월 선행시간 가뭄예측은 11월보다도 더욱 극심한 가뭄

을 JB 지역 전반에 걸쳐 예측하고 있다(Figure 3-26). 이러한 극심한 가뭄에 대한 예측이 모든 장기기후예측 모델에서 나타난 것은 아니고 여기에서 선정된 MSC_CanCM3 및 MSC_CanCM4 모델에서 나타난 것으로 보인다(자료 미제시).




Figure 3-18 Observed and forecasted SPI6 using BEST methods for August 2015 in the JB region.




Figure 3-19 Observed and forecasted SPI6 using FCST_ONLY methods for August 2015 in the JB region.




Figure 3-20 Observed and forecasted SPI6 using BEST methods for September 2015 in the JB region.




Figure 3-21 Observed and forecasted SPI6 using FCST_ONLY methods for September 2015 in the JB region.




Figure 3-22 Observed and forecasted SPI6 using BEST methods for October 2015 in the JB region.




Figure 3-23 Observed and forecasted SPI6 using FCST_ONLY methods for October 2015 in the JB region.




Figure 3-24 Observed and forecasted SPI6 using BEST methods for November 2015 in the JB region.




Figure 3-25 Observed and forecasted SPI6 using FCST_ONLY methods for November 2015 in the JB region.




Figure 3-26 Observed and forecasted SPI6 using BEST methods for December 2015 in the JB region.




Figure 3-27 Observed and forecasted SPI6 using FCST_ONLY methods for December 2015 in the JB region.

3.3.2 지역 평균 비교

JB 지역에 있어 가뭄지수 값의 지역 평균(Zonal Mean)을 구하여 실제 가뭄에 가까운 상황이 발생하였을 때 기계학습 모델이나 장기기후예측 모델 결과가 가뭄을 어떻게 예측하였는지 살펴보았다. 앞서 언급하였듯이 기계학습 모델을 훈련시킬 때 Near Normal과 Moderate Drought의 중간 값인 -0.5 이하인 관측 자료만을 이용하여 모델을 훈련시켰으므로 기계학습 모델의 경우 그보다 습윤한 상황은 거의 제시하지 못한다. 모델의 예측 성능을 평가하는 경우에도 가뭄 상황만을 고려하므로 역시 가뭄 지수 상태가 -0.5 이하인 경우만을 이용하여 비교·평가하였다.

앞서 2015년 8월부터 12월의 가뭄을 살펴보았을 때, 특히 선행시간이 긴 경우에 대해 기계학습 모델이 공간적인 변이를 크게 보이지 않고 전반적으로 Moderate Drought에 가까운 가뭄 상태를 예측하였으므로, 2015년 뿐 아니라 다른 가뭄 상황에서도 같은 현상이 발생하는지 살펴보기 위해 2003년 1월부터 2015년 12월에 대해 -0.5 이하의 가뭄 지수 값에 해당하는 자료를 이용하여 NASA 모델 예측 값(FCST), NASA 모델 예측 값을 기계학습 모델에 적용한 경우(ML), 관측 값(OBS)에 대해 4개월 및 6개월 선행시간에 대해 지역 평균을 구하여 비교하였다(Figures 3-28, 3-29).

4개월 선행시간의 경우 FCST는 관측에 비하여 가뭄심도를 과소추정(가뭄지수 값을 크게)하고 있으며(Figure 3-28a) ML은 대략적인 가뭄지수 값의 범위는 OBS와 유사하나 더 작은 범위 안에서 예측하고 있음을 알 수 있다(Figure 3-28b). 즉 관측의 경우 -2.5 이하의 극심한 가뭄에서부터 의도적으로 단절시킨 -0.5에 이르는 값을 보이는데 반해 FCST는 -1.5 이하의 Severe Drought에서 1.0 이상의 Moderately Wet 상황까지 보이고 있으며(Figure 3-28a) ML은 -1.5에서 -2.0 사이의 Severe Drought에서 -1.0에 가까운 Moderate Drought의 범위를 예측하고 있다(Figure 3-28b). 6개월 선행시간의 경우는 이러한 특성이 더욱 크게 나타났다(Figure 3-29).

기계학습 모델의 예측 결과가 이와 같이 고려할 수 있는 다양한 가뭄심도의 영역에 나타나지 않고 그 안쪽의 좁은 범위에 대해 많이 나타나고 있다. -2.0에서 -3.09에 이르는 극심한 Extreme Drought을 제대로 예측하지 못하는 것은 실제 해당 가뭄 카테고리의 훈련 자료의 표본 수가 상대적으로 적기 때문으로 보인다. 또한 -0.5에 가까운 Near Normal값이 잘 나타나지 않는 것은 기계학습 모델의 매개변수 등을

선정할 때 -1.0 이하의 가뭄 카테고리에서만 성능 평가 기준이 적용되기 때문이다. 기계학습 모델 훈련 설계의 개선을 통해 이러한 단점을 보완할 필요가 있다.




Figure 3-28 Scatterplots (a) between FCST and OBS and (b) between ML and OBS based on NASA model for 4-month lead time.




Figure 3-29 Scatterplots (a) between FCST and OBS and (b) between ML and OBS based on NASA model for 6-month lead time.

4. 결론

4.1 요약 및 결론

상이한 강우 특성을 가지는 인도네시아의 세 지역을 선정하여 각 지역에 대해 기계학습을 기반으로 한 가뭄예측 모델을 개발하였다. 기상학적 가뭄지수인 6개월 시간 스케일의 표준강수지수(SPI6)를 목표 변수로 설정하여 이의 예측 성능을 가뭄 정확도와 회귀 오차의 측면에서 장기기후예측 모델 예측 값을 그대로 사용한 경우를 기준 값으로 삼아 비교하였다. 인도네시아의 가뭄 발생은 지역적 차이는 있지만 ENSO의 변동과 깊은 관련이 있으며 몬순, 국지적인 SST, IOD, SPCZ 등 해양과 대기의 상호작용 뿐 아니라 지형 및 고도 등의 지역적인 요인의 영향도 크게 받는다. 따라서 기계학습 모델의 입력 변수로 장기기후예측 모델의 예측 값 뿐 아니라 국지 및 원격 SST, 가뭄의 초기 조건을 나타내는 원격 탐사 정보 등을 포함시켜 가뭄예측의 성능을 높이하고자 하였다.

서부 자바, 서부 수마트라, 고론탈로의 세 지역을 대상으로 MSC_CanCM3, MSC_CanCM4, NCEP, NASA, PNU, POAMA의 6개 장기기후예측 모델과 위성 기반의 강우 합성장을 활용하여 과거 기후 값을 구한 CLIM을 포함한 7개 모델, 그리고 1-6개월의 예측 선행시간에 대해 총 126개의 기계학습 모델을 구축하였다.

가뭄 정확도에 있어서 서부 자바와 고론탈로 지역은 선행시간별로 기계학습과 장기기후예측 결과를 비교한 결과 비슷한 양상을 보였는데, 선행시간이 1개월 정도로 짧은 경우는 장기기후예측 결과를 그대로 이용한 경우의 가뭄 정확도가 높았으나 대부분의 좀 더 긴 선행시간의 경우 기계학습을 적용한 경우의 가뭄 정확도가 높았다. 반면 서부 수마트라 지역은 다른 두 지역과는 다르게 대부분의 경우 장기기후예측 결과를 이용한 경우와 기계학습 모델을 적용한 경우 사이의 우열을 가리기 어려웠다. 회귀 오차의 경우는 세 지역 모두에서 특히 선행시간이 길어질수록 기계학습 모델을 적용한 경우가 장기기후예측 모델 결과를 그대로 이용한 것보다 낮은 오차를 보였다.

지역별 차이를 분석하면 고론탈로 지역의 기계학습 모델이 가뭄 정확도와 회귀 오차의 측면에서 가뭄예측 성능이 가장 우수하였다. 다른 두 지역에서는 모든 선행시간에서 가뭄 정확도는 서부 자바 지역에서 높게 나타났지만 회귀 오차에 있어서는 서부

수마트라 지역의 오차 값이 작게 나타났는데 이는 모델의 구축 및 성능 평가에 이용한 표본 수의 차이 때문인 것으로 보인다. 가뭄예측 성능의 지역별 차이는 각 지역이 ENSO에 영향을 받는 정도와 이로 인해 장기기후예측의 예측 성능이 달라지는 정도와 관련이 있다.

지역별 기계학습 모델의 입력 변수별 상대적 중요도를 평가하였는데, 모든 경우 특히 선행시간이 짧은 경우 개별 모델의 SPI6 예측 값의 중요도가 가장 높았다. 서부 자바 지역에서는 이어서 월(MONTH), NINO3 지역의 SST 예측값(NINO3_SST FCST)의 중요도가 높았으며 서부 수마트라 지역에서는 위도(LAT), 경도(LON) 등 지역의 위치적인 정보가 중요한 것으로 드러났다. 이는 해당 지역의 형태와 관련이 있는 것으로 보인다. 고론탈로 지역에서는 서부 자바 지역과 변수의 상대적 중요도가 유사하게 나타나나 SPCZ 지역 SST 예측 값의 중요도가 좀 더 부각된다. 서부 수마트라 지역에서 일부 비교적 높게 나타나기는 하지만 원격 탐사한 지표면온도, 식생지수, 토양수분 등의 가뭄 상태 초기 값의 중요도는 대부분의 경우 상대적으로 낮았다. 장기 기후예측 자료를 이용한 입력 변수의 중요도가 높게 나타나는 것은 기계학습을 적용 하더라도 기후모델의 예측 성능이 높아야 기계학습 모델의 예측 성능도 높아짐을 뜻한다.

서부 자바 지역에 대해 사례분석을 통해 장기기후예측 모델과 이 결과를 기계학습 모델에 적용한 결과를 비교하여 보았는데, 특히 NASA 모델을 이용하여 2003년에서 2015년 가뭄 사상에 대해 예측한 결과를 보면 장기기후예측 모델 결과를 바로 적용한 경우 가뭄 사상을 과소 추정하며 기계학습 모델을 적용한 경우 가뭄 발생의 폭을 좁게 예측 하는 경향이 있었다. 이러한 점은 기계학습 모델 훈련 설계의 시험을 통해 개선될 수 있을 것으로 보이며 후속 연구를 통해 해결책이 모색되어야 할 것이다.

가뭄 발생에 대한 정보가 사전에 주어진다면 가뭄 피해를 경감하기 위한 자원을 확보하고 효율적 배분을 위한 계획을 세워 가뭄 피해를 최소화할 수 있을 것이다. 가뭄 발생으로 인한 피해를 예방 및 저감하기 위해서는 구조적인 대책과 더불어 가뭄감시·예측시스템 개발과 같은 비구조적인 대응방안이 필수적이다. 본 연구를 통해 인도네시아 지역에 대해 개발된 가뭄예측 모델을 활용하여 기상학적 가뭄지수의 예측 성능을 향상시킬 수 있다. 이를 통해 인도네시아의 가뭄 재난 예방을 지원하여 가뭄 피해 최소

화에 도움이 될 수 있을 것이다.

4.2 가뭄예측 모델 활용 방안

본 연구를 통해 구축된 기계학습에 기반을 둔 가뭄예측 모델은 중장기의 선행시간에 대해 가뭄의 발생을 제대로 예측하지 못하는 장기기후예측 모델의 단점을 보완하여 가뭄 정확도를 증가시키고 회귀 오차를 줄여 좀 더 정확한 가뭄지수 예측에 다가설 수 있었다. 또한 서부 자바, 서부 수마트라, 고론탈로의 지역별로 가뭄예측 모델을 개발한 결과에서 볼 수 있듯이 각 지역마다 상대적으로 중요한 역할을 하는 변수들을 도출할 수 있었으며 이를 통해 기계학습 모델을 지역적으로 특화되게 구축할 수 있었다. 따라서 짧은 선행시간에 대해서는 장기기후예측 자료, 긴 선행시간에 대해서는 기계학습을 통한 가뭄예측 모델을 가뭄 감시 및 예측의 가장 기본이 되는 기상학적 가뭄의 예측에 활용할 것을 제안한다. 본 연구에서는 세 지역에 대한 모델만을 개발하였으나, 인도네시아 34개도에 대해 맞춤형 모델을 개발하여 전국에 대한 가뭄예측을 수행할 수 있다.

본 연구에서 직접적으로 예측 모델의 목표 변수 등으로 활용하지는 않았지만 가뭄예측 모델은 가뭄에서 파생되는 산불 발생의 예측이나, 농업적 가뭄 예측의 한 도구로 활용할 수도 있다. 예를 들어, 인도네시아는 워낙에 방대한 지역에 분포하므로 지역에 따라 다른 특성을 가지지만 본 연구에서 선정한 대상지역 중 쌀 생산이 매우 활발한 서 자바지역의 경우 기상학적 가뭄지수는 쌀 생산량, 쌀 수확 면적과 비교적 높은 양의 상관관계를 가진다. 상대적으로 건조한 시기의 강수량 및 가뭄 상태가 농업 생산량에 큰 영향을 미친다고 가정하고 서부 자바 지역의 9, 10, 11월 SPI6를 평균한 값과 연간 쌀 수확 면적과의 상관관계를 구해보면 피어슨 지수가 0.54 ($p = 0.01$)에 이른다. 물론 본 연구에서 개발한 모델 등을 농업 생산량 등에 적용하려면 예측하고자 하는 변수를 직접 목표 변수로 사용하는 것이 더 적합할 것이다. 그러나 이러한 높은 상관관계를 바탕으로 대략적인 쌀 생산량 1차 추정 등에 활용할 수 있을 것으로 보인다.

REFERENCE

- 이진영, 2015: 위성 및 장기예측자료의 기계학습을 통한 가뭄예측. APEC기후센터 연구보고서 2015-16. 129p.
- ADRC (Asian Disaster Reduction Center), 2012: Information on Disaster Risk REduction of the Member Countries – Indonesia Country Report 2012 (English Version), 36p.
- ADRC (Asian Disaster Reduction Center), 2016: Details of Disaster Information. URL: http://www.adrc.asia/nationframe.php?URL=./view_disaster_en.php?NationCode=&lang=en&KEY=2033. Last visited on 2 November 2016.
- Adrian, E., and R. D. Sustanto, 2003: Identification of three dominant rainfall regions within Indonesia and their relationship to sea surface temperature Internatioal Journal of Climatology, 23, 1435–1452.
- APA (American Planning Association), 2013. Plannning and drought. Ed., Schwab, J. C. Chicago, IL, USA. 93 p.
- Ashouri, H., K.-L. Hsu, S. Sorooshian, D. K. Braithwaite, K. R. Knapp, L. D. Cecil, B. R. Nelson, and O. P. Prat. 2015. PERSIANN-CDR: Daily precipitation climate data record from multisatellite observations for hydrological and climate studies. Bulletin of American Meteorological Society, doi: 10.1175/BAMS-D-13-00068.1.
- BPS (Statistics Indonesia). 2016: Agriculture and Mining. URL: <http://www.bps.go.id/Subjek/view/id/53#subjekViewTab3|accordion-daftar-subjek3>. Last Accessed: 20 October 2016.
- DMCDD (Disaster Management Center Compet Dhuafa). 2015: Situation Report – Drought in Indonesia 2015. 3p. Available online at: <http://reliefweb.int/sites/reliefweb.int/files/resources/Indonesia%20Sitrep%20DMC%20Domet%20Dhuafa%20Drought%20in%20Indonesia%20as%20%20of%2031%20August%202015.pdf>.
- EM-DAT. 2016: The OFDA/CRED International Disaster Database – www.emdat.be – Université Catholique de Louvain – Brussels – Belgium. Last Accessed: 18 October 2016.
- FAO (Food and Agriculture Organization of the United Nations). 2016: AQUASTAT website. Last Accessed: 18 October 2016.
- Geurts, P., D. Ernst, and L. Wehenkel. 2006: Extremely randomized trees. Machine Learning, 63, 3–42.
- GLIDE (Global Identifier Number). 2016. URL: <http://gs.adrc.asia/glide/public/search/>

- search.jsp. Last visited: 2 November 2016.
- GRiSP (Global Rice Science Partnership). 2013: Rice almanac, 4th edition. Los Banos (Philippines): Internatinoal Rice Research Institute. 283p.
- Hendon, H. H., 2003: Indonesian rainfall variability: Impacts of ENSO and local air-sea interaction. *Journal of Climate*, 16, 1775–1790.
- Juneng, L., and F. T. Tangang, 2005: Evolution of ENSO-related rainfall anomalies in Southeast Asia region and its relationship with atmosphere-ocean variations in Indo-Pacific sector. *Climate Dynamics*, 25, 337–350.
- Kogan, F. N., 1995: Application of Vegetation Index and Brightness Temperature for Drought Detection. *Advances in Space Research*, **15**, 91–100.
- Makarim, A. K. 2000: Bridgng the rice yield gap in Indonesia. 112–121. In: Papademetriou, M. K., F. J. Dent, and E. M. Herath. Bridgin the rice yieldgap in the Asia-Pacific region. Food and Agriculture Organization of the United Nations Regional Office for Asia and the Pacific. Bangkok, Thailand, October, 2000. 222p.
- OCHA (UN Office for the Coordination of Humanitarian Affairs). 2015: Asia-Pacific Region: El Nino Snapshot (as of October 2015).
- Panuju, D. R., K. Mizuno, B. H. Trisasongko. 2013: The dynamics of rice production in Indoensia 1961–2009. *Journal of the Saudi Society of Agricultural Sciences*, 12, 27–37.
- Quan, X.-W., M. P. Hoerling, B. Lyon, A. Kumar, M. A. Bell, M. K. Tippet, and H. Wang, 2012: Prospects for dynamical prediction of meteorological drought. *Journal of Applied Meteorology and Climatology*, 51, 1238–1252.
- Rhee, J., J. Im, and G. J. Carbone. 2010: Monitoring agricultural drought for arid and humid regions using multi-sensor remote sensing data. *Remote Sensing of Environment*, 114(12): 2875–2887.
- Setiawan, A., W.-S. Lee, and J.Rhee. 2016. Spatio-Temporal Characteristics of Indonesian Drought Related to El Niño Events. *International Journal of Climatology*. In revision.
- Tabor, S., E. Ginting, and P. Aji. 2015: Preparing for El Nino: Policy Options. ADB Papers on Indonesia No. 01. 7p.
- WFP (World Food Programme). 2016: The impact of drought on households in four provinces in Eastern Indonesia. February 2016. 88p.

연구보고서 2016-26

원격탐사 및 기후자료를 이용한 아태지역
가뭄예측모델 개발: 인도네시아를 중심으로

Development of a drought forecasting model for the Asia-Pacific region
using remote sensing and climate data: Focusing on Indonesia

이진영



APEC 기후센터

48058 부산광역시 해운대구 센텀7로12

Tel: 051-745-3900 Fax: 051-745-3949

www.apcc21.org



ISBN 979-11-5698-177-0