

학제간 연구의 동향 분석: 국외 농업 공학 분야 사례 연구

Analysis and Prospect of Interdisciplinary Research: Foreign Case Studies of Agricultural Engineering



장 원 석

Postdoctoral Research Associate
Sustainability Innovation Lab at
Colorado (SILC)
University of Colorado Boulder
won.jang@colorado.edu



Jason Neff
Professor and
SILC Faculty Director
Sustainability Innovation Lab at
Colorado (SILC)
University of Colorado Boulder
Jason.C.Neff@colorado.edu

1. 서론

21세기 들어와서 접하게 된 다양한 키워드 중에서 학제간(interdisciplinary)이라는 용어는 필자가 속해있는 연구분야 뿐만 아니라 다양한 연구분야에서도 자주 접하게 되는 용어 중 하나이다. 미국에 다양한 대학에서도 학제간 프로그램(interdisciplinary program or studies)(통합학문 또는 융합학문 이라고도 불림)란 이름의 학위과정으로 다양한 관심과 능력을 가진 학생들을 유치하고 있다. 또한 교수 임용 공고에도 학제간 연구(interdisciplinary research)라는 용어는 빠지지 않고 등장하고 있다. 학제간 연구가 무엇이고, 왜 우리는 학제간 연구에 관심을 갖고 있을까? 그리고 학제간 연구가 우리에게 주는 혜택은 무엇인가? 라는 질문을 던지지 않을 수 없다.

미국 상무부(Department of Commerce) 산하의 정부 기관인 국립과학재단(National Science Foundation, NSF)에서는 학제간 연구를 다음과 같이 정의한다(National Academy of Sciences, National Academy of Engineering, and Institute of Medicine, 2005). “학제간 연구는 개인이나 연구팀이 전문성이 있는 두개 이상의 연구분야의 정보, 데이터, 기술, 이론 등을 통합하여 새로운 연구 분야를 만듦으로써 주어진 문제들을 해결하거나 문제들의 근본적인 이해를 증진 시키기 위한 연구 방식이다.” 즉 학문적으로 기존의 고유 영역 구분에 머무르지 않고 학문간의 경계가 없어지는 새로운 학문 분야라고 말할 수 있다. 세계적인 학술지 네이처(Nature) 특별지(Special issue)에서는 “Why interdisciplinary research matters”(학제간 연구가 왜 중요한가?)라는 제목의 글이 실렸다(Nature, 2015). “자연과학자들과 사회과학자들은 함께 연구하면서 에너지, 물, 기후, 식량, 보건 등과 같은 커다란 사회적 이슈를 해결해야 하고, 정부, 대학, 연구재단 등은 학제간 연구의 활성화를 위한 시스템을 잘 구축하여야 한다.”로 간략하게 요약할 수 있다.

본 기사에서는 최근 농업 공학 분야에서 에너지, 물, 식량 등과 같은 사회적인 이슈를 해결하기 위해 학제간 연구가 어떻게 진행되고 있는지를 국외 지역을 중심으로 농업 공학 분야에 적용된 연구 사례 소개 및 동향 분석을 하려고 한다. 빅데이터(Big data)와 기계 학습(Machine learning)을 이용하여 농작물 생산량을 예측하고, 관개용수량 계획 수립시 효과적인 의사 결정을 할 수 있게 하였다. 병렬 컴퓨팅(Parallel computing)을 이용하여 고해상도/대용량의 농업 시스템 모델링을 단시간에 처리할 수 있게 하였다. 클라우드 컴퓨팅(Cloud computing)을 이용하여 토양 습도(Soil moisture)를 실시간 모니터링 하고 측정할 수 있는 클라우드 기반의 안드로이드 시스템을 개발함으로써 농업 기술 발전에 기여를 하였다. 좀 더 구체적인 연구 사례들은 2. 빅데이터(Big data) / 기계 학습(Machine Learning)과 농업 공학, 3. 병렬 컴퓨팅(Parallel Computing) / 클라우드 컴퓨팅(Cloud Computing)과 농업 공학 섹션에서 다루도록 하겠다.

2. 빅데이터(Big data)/기계 학습(Machine Learning)과 농업 공학

농업 계획 수립시 중요한 부분은 다양한 농작물의 생산량을 정확하게 예측하는 것이다. 따라서 작물 성장에 필요한 환경 변수의 정확한 예측과 환경 변수와 농업 생산량의 관계성을 증명하는 것이 농작물 생산량을 정확하게 예측할 수 있는 요건이 아닐까 한다. Gonzalez-Sanchez et al.(2014)는 기계 학습(Machine learning)을 이용하여 실제적이고 효과적인 솔루션을 제시하

고자 하였다. 7종류의 농작물과 10개의 데이터셋(Dataset) 그리고 8개의 환경 변수(표 1)를 사용하여 농작물 생산량을 예측하였고, 다양한 기계 학습 모델을 비교하여 농작물 생산량 예측을 위한 최적의 기계 학습 모델을 제시하였다. 연구 대상 지역은 멕시코 Sinaloa 지역이다.

Gonzalez-Sanchez et al.(2014)는 기계 학습 모델로 다중 선형 회귀(Multiple linear regression), M5 회귀 모형 알고리즘(M5-Prime regression trees), 다계층 퍼셉트론 신경망(Perceptron multilayer neural networks), 서포트 벡터 알고리즘(Support vector regression), k-최근접 이웃 알고리즘(k-nearest neighbor methods), 이렇게 총 5개의 기계 학습 모델을 사용하였다. 각 모델의 정확도를 판단하기 위해서 RMSE(루트 평균 제곱 오차, Root Mean Square Error), RRSE(상대적 평균 오차, Root Relative Square Error), MAE(평균 절대 오차, Mean Absolute Error), R(상관 계수, Correlation Factor), 이렇게 총 4가지의 데이터 검증을 위한 평가방법을 사용하였다. 표 2와 3에서 알 수 있듯이 M5 회귀 모형 알고리즘과 k-최근접 이웃 알고리즘이 가장 낮은 RMSE, RRSE, MAE 수치를 나타내었고, 가장 높은 R

표 1. 농작물 생산량 예측을 위한 기계 학습 환경 변수

코드명	변수명	변수 단위
PA	자배 면적	ha
IWD	관개수심	cm
SR	태양 복사량	kWhm ⁻²
RF	강우량	mm
MaxT	최고 온도	°C
AvgT	평균 온도	°C
MinT	최저 온도	°C
SDC	계절별 품종	-

표 2. 기계 학습 모델 검증 평가 결과 1(RMSE, RRSE)

ID	RMSE(%)					RRSE(%)				
	MLR	ANN	M5-Prime	kNN	SVR	MLR	ANN	M5-Prime	kNN	SVR
CD01	9.64	9.67	8.54	9.38	8.83	90.59	90.44	80.62	91	83.39
CD02	0.25	0.26	0.26	0.23	0.26	76.71	77.23	78.42	70.48	77.82
CD03	0.49	0.47	0.5	0.64	0.5	66.05	65.34	63.79	84.32	66.91
CD04	1.07	1.09	0.97	1.05	1.09	93.18	95.02	83.08	92.12	96.41
CD05	1.28	1.26	1.25	1.37	1.29	85.71	84.76	83.73	91.62	86.21
CD06	4.45	4.54	3.97	4.36	4.2	92.84	95.19	82.06	90.06	84.97
CD07	5.32	5.29	4.97	4.4	4.91	83.68	82.99	76.96	64.27	76
CD08	15.8	16.03	16.2	12.87	13.16	83.97	85.32	86.49	68.91	70.34
CD09	10.1	11.77	10.03	10.54	10.3	82.24	94.2	80.75	84.23	83.43
CD10	5.66	5.61	4.7	4.26	5.61	96.44	95.56	79.89	71.97	95.67
Average	5.41	5.6	5.14	4.91	5.02	84.54	86.18	79.46	79.78	81.97

MLR: multiple linear regression
 ANN: artificial neural network
 kNN: k-nearest neighbor
 SVR: support vector regression

표 3. 기계 학습 모델 검증 평가 결과 2(R, MAE)

ID	R					MAE(%)				
	MLR	ANN	M5-Prime	kNN	SVR	MLR	ANN	M5-Prime	kNN	SVR
CD01	0.27	0.43	0.65	0.55	0.54	25.3	27.04	22.18	23.95	22.37
CD02	0.29	0.35	0.23	0.6	0.29	9.07	9.13	9.37	6.71	8.94
CD03	0.65	0.63	0.71	0.35	0.63	16.76	16.15	16.24	22.84	17.27
CD04	0.11	0.15	0.37	0.33	0.14	24.99	25.02	21.4	22.91	25.54
CD05	0.15	0.15	0.22	0.15	0.1	8.24	8	7.85	9.21	8.4
CD06	0.25	0.31	0.4	0	0.3	12.57	12.9	9.76	10.43	10.41
CD07	0.03	-0.06	0.4	0.37	0.35	13.07	14.06	13.48	9.97	12.15
CD08	0.38	0.54	0.44	0.72	0.66	44.37	45.88	39.76	35.33	34.8
CD09	0.4	0.03	0.45	0.39	0.33	19.04	21.77	17.57	16.61	18.74
CD10	-0.05	-0.18	0.54	0.74	-0.04	46.54	44.97	39.35	29.06	46.33
Average	0.25	0.21	0.42	0.41	0.31	21.63	21.99	19.42	18.12	20.29

MLR: multiple linear regression
 ANN: artificial neural network
 kNN: k-nearest neighbor
 SVR: support vector regression

수치를 보여주었다. 이 중에서 M5 회귀 모형 알고리즘이 최소의 오차로 가장 많은 작물 예측했기에 5개의 기계 학습 모델중 다양한 농작물 생산량을 예측하는데 있어 가장 적합한 모델로 선정되었다.

향후 실제적인 농업 계획 수립시 빅데이터와 M5 회귀 모형 알고리즘을 이용하여 다양한 농작물의 생산량을 정확하게 예측할 수 있을 것이라 사료된다.




그림 1. GBRT의 일부인 모범적 결정 트리 모델(An exemplary decision tree model)(Goldstein et al., 2017)

Goldstein et al. (2017)은 Jojoba Israel(호호바유(Jojoba) 관련 상품을 생산하는 세계 최대의 회사)의 빅데이터와 기계 학습을 이용하여 효과적인 관개 계획 수립을 위한 뚜렷한 지식을 제공하고, 농학자들이 경험에서 축적했던 관개(Irrigation) 관련 노하우(Know-how)와 암묵적인 지식(tacit knowledge)들을 좀 더 명확하게 밝혀내는 연구를 하였다. 호호바유는 호호바 나무 열매를 짠 기름으로 주로 화장품을 제조할 때 사용된다. Jojoba Israel이 소유한 농장에는 센서(Sensor)들이 설치되어 있고, 이 센서들은 식물들이 필요한 토양 습도를 실시간으로 모니터링을 한다. 그리고 기후, 관개, 생산량 데이터

는 기상 관측소와 관개 관련 부서 등과 같은 곳에서 제공받는다. 이 모든 데이터들을 기계 학습에 적용시켜 각 데이터들의 관계성을 파악하고, 최종적으로 생산량을 예측함으로써 관개 계획 수립시 필요한 관개용수량을 산정한다. 다양한 기계 학습 알고리즘 중에서 GBRT(경사 부스팅 회귀 알고리즘, Gradient Boosted Regression Trees)(그림 1)가 가장 낮은 에러율을 보여 주었고(표 4), GBRT를 이용해서 실제적이고 효과적인 관개 계획 수립을 위한 의사 결정 모델을 개발하였다.

표 4. GBRT 모델 정확성 평가

Measure	Set1	Set2	Set3	Set4	Set5	Set6	Set7	Set8
RMSE	0,113	0,15	0,139	0,165	0,116	0,138	0,149	0,129
Maximal error	0,645	0,768	0,765	0,985	0,675	0,673	0,87	0,693
Maximal deviation rate	21,50%	26,10%	21,40%	26,00%	22,50%	21,70%	31,30%	23,20%
Success rate – total	92,70%	88,10%	90,80%	91,30%	92,20%	92,70%	90,80%	90,40%
Success rate – 1999 seeds	85,70%	82,10%	89,30%	82,10%	89,30%	85,70%	85,70%	85,70%
Success rate – 1999 clones	93,20%	89,80%	89,80%	93,20%	89,80%	93,20%	89,80%	91,50%
Success rate – 2002	96,00%	92,00%	94,70%	94,70%	94,70%	92,00%	94,70%	92,00%
Success rate – 2004 east	91,10%	83,90%	87,50%	89,30%	92,90%	96,40%	89,30%	89,30%

RMSE: Root Mean Squared Error

3. 병렬 컴퓨팅(Parallel Computing)/클라우드 컴퓨팅(Cloud Computing)과 농업 공학

식량 문제, 에너지 문제를 해결하기 위해서는 농업 시스템 관리 방안에 대한 정보를 보다 실질적으로 이용하고 분석하는 것이다. 무엇보다도 지역별 또는 전 지구적인 스케일로 고해상도의 시공간적인 데이터를 가지고 체계적인 분석을 한다면 좀 더 정확한 솔루션을 찾을 수 있을 것이다. 그러나 넓은 지역을 대상으로 고해상도 데이터를 이용하여 농업 관련 모델링을 할 때 문제가 될 수 있는 것은 컴퓨터의 처리능력의 한계이다. 너무 많은 시간과 인력이 투입되어 비효율적인 연구가 될 수 있다. Zhao et al.(2013)은 병렬 컴퓨팅(Parallel computing)과 그리드 컴퓨팅(Grid computing)을 이용하여 하이브리드 컴퓨팅(Hybrid computing) 시스템을 개발하였고, 하이브리드 컴퓨팅을 이용하여 호주 농업지역의 밀 생산량, 토양 탄소, 질소 거동을 고해상도로 모델링을 하였다. 또한 Zhao et al.(2013)은 122년동안의 모델링 기간을 두고 일별로 325개의 다양한 농업 방법 시나리오와 12,707가지의

기후-토양의 수문 응답 단위(HRU, Hydrologic Response Unit)에서 APSIM(Agricultural Production Systems SIMulator)을 이용하여 밀 생산량, 토양 탄소, 질소 거동등을 모델링을 하였다. 만약 한대의 컴퓨터를 이용했다면 약 30년 정도의 시간이 필요했지만, 고성능 컴퓨팅 시스템(HPC, High Performance Computing)을 이용하여 약 1000배 정도 빠르게 모델링을 하여 약 10일정도에 모든 계산 과정을 마칠 수 있었다. Zhao et al.(2013) 연구에서도 시사하는 바와 같이 자연과학과 테크놀로지의 만남은 상당히 효과적으로 연구를 가능하게 하고, 앞으로 농업 공학 분야에 발전적인 방안을 제시할 수 있을 것이라 기대한다.

토양 습도 정보는 농업 생산량과 밀접한 관련이 있어 농업 계획 수립시 핵심 정보 중 하나이다. 토양 습도 뿐만 아니라 농작물 성장에 있어서 중요한 변수가 되는 온도, 습도, 토양 산도 등도 농업 생산량 산정에 있어서 꼭 필요한 정보들이다. Vani and Rao(2016)는 사물인터넷(IoT, Internet of Things), 클라우드 컴퓨팅(Cloud computing), 모바일 컴퓨팅(Mobile computing) 기술을 이용하여 토양 습도를 모니터링하고 측

정할 수 있는 저가형 토양 습도 센서 인터페이스를 개발하였다. 특히 미국의 메이저 통신 회사인 AT&T(미국 2위 통신 회사)의 사물 인터넷 플랫폼인 AT&T M2X 클라우드 플랫폼을 이용함으로써 실시간으로(토양 습도 센서로 측정된) 토양 습도 정보를 스마트폰, 노트북, 데스크탑 등을 이용해서 자유롭게 접속 및 다운로드 받을 수 있게 하였다. 또한 사용자의 손쉬운 데이터 후처리(post-processing)을 위해서 엑셀 파일로 저장할 수 있게 하였다. 농업 관련 환경 변수들을 실시간으로 모니터링하고 측정하는 것은 농업 개발에 있어서 상당히 중요한 부분이다. Vani and Rao(2016)의 연구는 클라우드 사물인터넷 기술과 안드로이드 시스템을 이용하여 실시간으로 토양 습도를 모니터링하고 측정할 수 있게 인터페이스를 개발하여서 농업 생산성 부분에서 큰 기여를 할 수 있을 것이라 생각한다.

4. 결론

(국적이) 서로 다른 요리들이 만나서 장점만을 조화시켜 색다른 맛을 제공하는 퓨전 요리와 서로 다른 두 개 이상의 학문들이 만나서 각 학문의 장점을 살리고 새로운 연구 분야를 만듦으로써 주어진 문제들을 해결하거나 문제들의 근본적인 이해를 증진 시키기 위한 연구 방식인 학제간 연구는 어쩌면 비슷한 이치인지 모른다. 학제간 연구를 통하여 직면한 문제를 해결하기 위해서 서로 다른 방식의 접근을 하고, 이를 통해 문제에 대한 다층적이고 다각적인 이해를 넓힐 수 있다. 그러므로 때로는 우리가 평소엔 생각하지도 못한 접근을 통해 문제를 해결 할 수 있게 된다. 물론 학제간 연구가 늘 좋은 결과만 보장

하지는 않는다. 각 연구 분야의 용어와 개념이 다르기에 의사 소통에 문제가 있을 수 있다. 학제간 연구의 전문가가 부족하기에 연구 전체 과정을 총괄/지도/모니터링을 할 수 있는 전문 인력이 부족 할 수 있다. 결과적으로 사전 준비가 철저하게 되지 않은 상태에서 학제간 연구가 이루어지면 오히려 역효과를 가져 올 수 있다는 것이다. 또한 적지 않은 시간과 수고가 필요 할 수 있다. 서로 다른 분야를 공부해야 하기에 어쩌면 많은 시간과 수고를 필요로 하는건 당연한 얘기 일 수 있다. 하지만 우리 대부분은(이 글을 읽는 독자들은 대부분 사회과학/자연과학/공학 분야에 종사하고 있을 거라 생각한다.) 연구를 통해서 작게는 우리 사회, 크게는 세상을 좀 더 살기 좋게 만드는 것에 대한 사명을 가지고 있을 것이다. 우리의 작은 수고는 세상을(바람직한 방향으로) 변화 시킬 수 있기에 가치 있는 수고가 되고 감사한 수고가 될 수 있을 것이다. 그런 수고는 언젠가 감당할 수 있는 수고일 것이다. “Scientists must work together to save the world”(Nature, 2015)라는 말을 다시 한번 상기시키면서 글을 마치겠다.

참고문헌

1. A. Goldstein, L. Fink, A. Meitin, S. Bohadana, O. Lutenberg, G. Ravid, 2017. Applying machine learning on sensor data for irrigation recommendations: revealing the agronomist's tacit knowledge, Precision Agric., DOI 10.1007/s11119-017-9527-4.
2. A. Gonzalez-Sanchez, J. Frausto-Solis, W. Ojeda-Bustamante, 2014. Predictive ability of machine learning methods for massive crop

- yield prediction, *Spanish Journal of Agricultural Research* 12(2): 313-328.
3. G. Zhao, B. A. Bryan, D. King, Z. Luo, E. Wang, U. Bende-Michl, X. Song, Q. Yu, 2013. Large-scale, high-resolution agricultural systems modeling using a hybrid approach combining grid computing and parallel processing, *Environmental Modelling & Software* 41: 231-238.
 4. National Academy of Sciences, National Academy of Engineering, and Institute of Medicine, 2005. *Facilitating Interdisciplinary Research*. Washington, DC: The National Academies Press. <https://doi.org/10.17226/11153>.
 5. Nature, 2015. Why interdisciplinary research matters, Special issue, 525(305): 291, doi: 10.1038/525305a.
 6. P. D. Vani, K. R. Rao, 2016. Measurement and Monitoring of Soil Moisture using Cloud IoT and Android System, *Indian Journal of Science and Technology*, 9(31): 1-8, DOI: 10.17485/ijst/2016/v9i31/95340