

2023 인재양성 프로그램
연구자 최종 결과보고서

통합평가모형의 불확실성을 고려한 기계학습분석을 통한
CCS 확대의 사회적 탄소비용 산정

Estimating the social carbon cost of CCS expansion through machine learning
analysis considering the uncertainty of the integrated assessment model

2024 02 02

세사리 데시
(특정주제 연구자)

제 출 문

재단법인 숲과나눔 이사장 귀하

본 보고서를 “통합평가모형의 불확실성을 고려한 기계학습분석을 통한 CCS 확대의 사회적 탄소비용 산정”의 최종 연구 결과보고서로 제출합니다.

2024년 02월 02일

연구 원 : 세사리 데시(특정주제연구자)

※ 본 보고서의 내용은 연구자의 의견이며, (재)숲과나눔의 공식적인 견해와는 다를 수 있습니다.

결과보고서 초록

연구원	세사리 데시	구분	특정주제연구자
연구제목	한글	통합평가모형의 불확실성을 고려한 기계학습분석을 통한 CCS 확대의 사회적 탄소비용 산정	
	영문	Estimating the social carbon cost of CCS expansion through machine learning analysis considering the uncertainty of the integrated assessment model	
연구기간	2022.3.1 ~ 2022.12.31		
색인어	한글	사회적 탄소비용, 탄소포집 및 저장, 통합 평가 모델, 기계학습	
	영문	Social cost of carbon (SCC), carbon capture and storage (CCS), Integrated assessment model, machine learning	

탄소 포집 및 저장(carbon capture and storage, CCS)의 활용은 잔여 배출량을 상쇄하여 지구 평균 표면 온도 2°C 상승 제한 목표를 달성할 수 있는 잠재적 해결책으로 모색되고 있다. 그럼에도 불구하고 CCS의 구현은 자금 조달 및 전반적인 비용 효율성과 관련된 문제에 계속 직면하고 있다. 따라서 CCS의 성장률이 계속 낮게 유지된다면 2100년에 예상되는 저장 용량이 목표치에 미치지 못할 수도 있다. 이 문제를 해결하기 위해서는 사회적 탄소 비용(social cost of carbon, SCC)과 CCS의 CO₂ 회피 비용을 비교하여 CCS의 비용편익을 분석하는 것이 필수적이다. 한편, SCC는 온도 상승으로 인한 사회적 피해를 측정하는 값으로, 일반적으로 통합 평가 모델(integrated assessment model, IAM)을 사용하여 추정한다. 그러나 IAM의 복잡성으로 인해 SCC 추정에 불확실성이 존재한다. 따라서 SCC에 내재된 불확실성을 특성화하는 것이 중요하다. 본 연구에서는 다양한 IAM의 차이점으로 인한 SCC 추정과 관련된 불확실성을 효과적으로 포착할 수 있는 일반화(generalized)화된 IAM을 개발하기 위해 기계학습(machine learning, ML)의 활용을 제안한다. 일반화된 IAM 기반 ML 모델은 SCC를 계산하고 SCC 범위의 확률 분포를 생성하는 데 사용한다. 또한, CCS CO₂ 회피 비용과 SCC 확률 범위를 비교하여 CCS의 비용편익 분석을 수행한다. 개발된 모델은 SCC 추정에 내재된 불확실성을 설명할 뿐만 아니라, 향후 다양한 잠재적 시나리오에 대한 SCC를 신속하게 추정할 수 있어 기후 정책 및 CCS 기술 확대와 같은 감축 노력에 유용한 참고 자료로 활용될 수 있다.

Abstract

The utilization of carbon capture and storage (CCS) is being explored as a potential solution to offset residual emissions thus achieving the target of limiting 2°C rise in global mean surface temperature. Nevertheless, the implementation of CCS continues to encounter challenges related to financing and the overall cost-effectiveness. Consequently, if the growth rate of CCS remains low, the projected storage capacity may fall short of the target set for the year 2100. In order to address this issue, it is essential to assess the cost-benefit analysis of CCS by comparing the social cost of carbon (SCC) with the CO₂ avoidance cost of CCS. On the other hand, SCC represents a value that measures social damages resulting from temperature rise and is commonly estimated using integrated assessment models (IAM). However, the complexity of IAM introduces uncertainties in the estimation of SCC. Therefore, it is crucial to characterize the uncertainties embedded in the SCC. This study proposes the utilization of machine learning (ML) in order to develop an automated generalized IAM that can effectively capture uncertainties associated with the estimation of SCC due to variations in different IAMs. The generalized IAM-based ML model is employed to calculate the SCC and generate a probability distribution of SCC ranges. Furthermore, a cost-benefit analysis of CCS is conducted by comparing CCS CO₂ avoidance cost with the SCC probability range. The developed model not only describes the embedded uncertainty in the SCC estimation, but also enables a rapid estimation of SCC for numerous potential scenarios in the future that can serve as a valuable reference for climate policy and mitigation efforts such as the expansion of CCS technology.

요약문

I. 제목

통합평가모형의 불확실성을 고려한 기계학습분석을 통한 CCS 확대의 사회적 탄소비용 산정

II. 연구의 목적 및 필요성

본 연구는 탄소포집 및 저장 기술 확대에 따른 사회적 탄소 비용(social cost of carbon, SCC) 영향을 평가하는 방법론을 개발하고자 한다. 이때, 사회경제적 조건과 통합평가모형(integrated assessment model, IAM)에서 선택가능한 여러 매개변수의 불확실성을 신속하게 고려한다. 이를 통해 최종적으로 기후 완화정책의 평가에 효과적으로 기여하고자 한다. 이러한 연구 목표의 달성을 위해 본 연구는 다음과 같은 두 가지 과업을 달성하고자 한다.

- (1) 통합 평가 모델(IAM) 고려한 사회경제적 시나리오
- (2) 기계학습을 활용한 탄소 사회적 비용 및 확률 계산 자동화 및 CCS 확대의 영향 분석

연구의 필요성 및 기대효과는 다음과 같다: 기후 완화 목표를 달성하려면 2050년까지 대규모 CCS 시설의 건설이 필요하지만 아직까지 대규모 CCS에 건설과 관련된 어려움, 가능성 및 기회를 분석한 연구는 부족한 실정이며 이에 대한 보완이 필요한 실정이다. 이번 연구를 통해 불확실성을 고려한 포괄적인 분석을 수행하여 CCS 확대에 의한 SCC의 확률적인 평가 결과를 제공할 것으로 기대된다. 또한, 빠르게 변화하는 사회에서 다양한 가능성을 포함한 예측 모델을 제공하여 신속하게 SCC 평가를 수행할 수 있을 것으로 기대된다.

III. 연구의 분석 방법 및 자료

- 통합 평가 모델(IAM) 고려한 사회경제적 시나리오

SCC 산정에는 통합평가모형(IAM)이 널리 사용되는데, 일반적으로 IAM은 사회경제적 모듈, 기후 반응 모듈, 피해/손실(damage) 및 미래 할인(future discounting) 모듈로 구성된다. IAM은 모듈 간의 상호 연결된 관계와 함께 지구 시스템 및 사회경제적 구성요소에 대한 지식을 바탕으로 SCC를 추정하는 모델이다. 많은 연구가 IAM을 이용해 SCC를 추정하였다. 가정한 사회경제적 조건에 따라, 인간 활동으로 인한 온실가스 배출량을 추정한다. 탄소 배출량은 탄소 순환을 고려해 대기 중 잔류하게 되는 배출량을 기반으로 온실가스의 대기 중 농도가 추정된다. 그 후에는 복사 강제력(radiative forcing, RF)과 기후 민감도(CS) 값을 바탕으로 온도 상승을 추정한다. SCC는 예상 온도 상승에 따른 순시간선호율(PRTP)로 추정된다. 세 가지 IAM의 최신 버전은 오픈 소스 모델을 사용한다: FUND, PAGE, and DICE. 본 연구에서는 탄소 배출량 데이터뿐만 아니라 사회경제적 조건, 인구 및 1인당 GDP를 포함한 각 IAM의 기본 데이터를 활용한다, 또한 각 IAM에 해당하는 SCC를 계산한다

- 기계학습을 활용한 탄소 사회적 비용(SCC) 및 확률 계산 자동화 및 CCS 확대의 영향

기계학습을 적용하여 SCC 분포 범위를 추정하는 과정은 크게 기계학습 모델을 학습시켜 일반화된 IAM 모델을 훈련하기 단계와 SCC의 확률 분포를 추정하는 단계로 나눌 수 있다. 또한 일반화된 IAM 모델은 향후 CCS 확대 시나리오를 고려할 때 SCC의 잠재적 변화를 분석하기 위해 활용된다. 본 연구는 기계 학습 방법중 서포트 벡터 회귀(support vector regression, SVR)를 활용하였

다. SVR은 지도 학습 방법이기 때문에 훈련 단계에서 입력 변수와 출력 변수가 필요하다. 일반화된 SVR-IAM 모델 학습하기 위해, IAM에서 불확실성의 주요 원인은 미래 사회경제적 시나리오와 선택된 PRTP 및 CS 값이기 때문에 이러한 매개변수를 입력 변수로 지정하고, SCC 값을 출력 변수를 지정한다. 다양한 PRTP과 CS 값을 선택하여 하나의 입력 사회경제 데이터 세트에 대한 CS 값과 PRTP 값을 결합 바탕으로 총 10개의 SCC 값이 추정된다. 평균 제곱근 오차(root mean squared error, RMSE)와 결정계수(coefficient of determination, R^2)의 평가 지표에 따라 최적의 성능 모델을 얻기 위해 SVR 하이퍼파라미터의 파인튜닝(fine-tuning)을 실행하였다.

학습된 일반화된 SVR-IAM은 다양한 미래 사회경제적 시나리오를 기반으로 SCC 값을 예측하는데 적용되며, 여기에는 세 가지 IAM뿐만 아니라 공통사회경제경로(Shared Socioeconomic Pathways, SSP) 기준 시나리오도 포함되었다. 사회경제적 데이터는 미래의 불확실성을 파악하기 위해 다양한 가능한 사회경제적 조건을 생성하는 몬테카를로 시뮬레이션을 적용하였다. 각 시나리오에 대해 일반화된 SVR-IAM 모델을 사용하여 SCC를 추정하고, 해당 비용 값의 발생 확률을 계산하고 SCC 값의 분포에 대한 분석을 수행하였다. 기준 시나리오 외에도 SSP 시나리오의 SCC를 산정하였는데, SSP 시나리오는 향상된 탄소 포집 기술을 포함한 완화 전략을 기반으로 한다. SSP-CCS 시나리오를 구축하고 몬테카를로 시뮬레이션을 통해 잠재적 미래 시나리오를 생성하여 일반화된 SVR-IAM과 추정된 SCC 값의 확률 분포를 사용하여 SCC를 추정하였다. CCS의 비용편익 분석은 CCS의 CO₂ 회피비용을 추정하여 얻는 SCC 확률 분포와 비교하였다.

IV. 연구 결과

인구, 1인당 GDP, 온실가스 배출량을 입력으로 활용하여 SCC를 예측하는 훈련 과정을 거친 후, RMSE와 R^2 지표를 사용하여 SVR 모델의 성능을 평가하였다. 평가 결과에 따르면 훈련, 검증 및 테스트 데이터의 낮은 RMSE 값 및 높은 R^2 값을 얻었다. 이는 SVR 모델의 SCC 예측이 실제 SCC 값과 거의 일치한다는 것을 의미하며 사용된 세 가지 IAM에서 일반화된 모델을 도출하였다. 일반화된 SVR-IAM 모델을 얻은 후, 이 모델을 활용하여 수많은 잠재적 미래 시나리오에서 SCC를 예측하고 SCC 범위의 확률 분포도 계산되었다. SCC 결과의 확률 분포는 long right-tail 형태 있으며, SCC 값이 높을수록 확률이 감소한다는 것을 나타냈다. 가장 높은 확률의 SCC 값은 소폭 감소하지만, 2020년에 비해 2100년에 높은 SCC 값이 발생할 확률이 증가한다는 것을 알 수 있다.

다음 단계에서는 일반화된 모델은 다양한 미래 잠재적 CCS 시나리오에서 SCC를 예측하는 데 사용되며, 기준 시나리오 외에도 미래 CCS 시나리오가 고려되어 SCC 값의 확률이 계산되었다. 기준 시나리오에서 관찰된 SCC 확률 분포를 비교하면, CCS 개발 시나리오를 통합한 결과 평균 SCC 결과가 감소하였다. 또한, 2100년에 높은 SCC 값은 발생할 확률도 감소하여 CCS 개발 확대가 향후 재난적 재해의 잠재력을 완화할 수 있음을 시사한다. CO₂ 회피 비용을 이용한 CCS 기술의 비용편익 분석 결과는 추정된 SCC 범위 값보다 낮다는 것을 알 수 있다. 이 결과는 CCS 기술 도입에 대한 투자의 비용 효율성을 나타내며, CCS가 탄소 배출과 관련된 피해를 완화함으로써 상당한 사회적 편익에 기여한다는 것을 시사하였다.

V. 연구 결과의 유용성

개발한 일반화된 SVR-IAM을 활용해 다음에 이용할 수 있다. 첫째, SCC의 확률 분포를 신속하고 자동으로 추정할 수 있으며 많은 정보를 바탕으로 강력한 기후 정책 의사결정을 내릴 수 있다. 모델 자동화를 통해 발생가능한 여러 미래 시나리오에서 SCC를 계산하고 이에 소요되는 시간을

단축하여 효율성을 높일 수 있다. 또한 일반화된 모델은 다양하고 복잡한 IAM 전반에 걸쳐 적응성을 발휘하여 SCC 계산과 관련된 불확실성을 포괄적으로 이해할 수 있다. 또한 이 모델은 확장성이 뛰어나 다양한 규모의 미래 시나리오에 적용할 수 있다.

일반화된 모델은 다양한 미래 시나리오에서 SCC를 추정함으로써 탄소 배출을 줄이기 위한 비용 효율적인 전략을 식별할 수 있다. 이 정보는 정책 입안자가 현재 기후 정책의 관련성과 효과를 평가하고 다양한 탄소 감축 전략의 잠재적 경제적 영향을 적시에 평가할 수 있게 해주기 때문에 정책 입안자에게 유용하다. 또한 기업과 투자자는 이 모델을 활용하여 탄소 관련 정책 및 전략의 잠재적 재정영향을 평가함으로써 저탄소 미래를 위한 의사결정에 도움을 받을 수 있는 것이다. 또한, 시민사회에게는 탄소 배출의 경제적 결과에 대한 명확한 증거를 제공함으로써, 대중의 인식을 높이고 탄소 감축 노력의 시민의 지지 확보 정당성을 강화할 수 있다 탄소 감축 전략에는 탄소 포집 및 저장, 재생 에너지 등 다양한 접근 방식이 포함된다. 이 모델의 활용은 정책 입안자, 기업, 투자자, 시민사회에 혜택을 제공하여 강력한 기후 정책 개발과 지속 가능한 미래로의 전환에 기여할 수 있다.

목차

초록	3
요약문	5
목차	8
표 목차	9
그림 목차	10
I. 서론	11
1.1. 연구의 배경.....	11
1.2. 연구의 목적.....	13
1.3. 연구 구성.....	13
II. 문헌 검토	14
2.1. 사회적 탄소 비용 및 통합평가모델 불확실성	14
2.2. 에너지 및 기후변화 분야에서 기계학습 적용	15
III. 분석 방법 및 자료	16
3.1. 통합 평가 모델(IAM) 고려한 사회경제적 시나리오	16
3.2. 기계학습을 활용한 탄소 사회적 비용(SCC) 및 확률 계산 자동화 및 CCS 확대의 영향	19
3.2.1 일반화된 SVR-IAM 및 SCC 확률 범위 추정	20
3.2.2 SCC 확률 범위 추정 CCS 확대의 영향	23
IV. 분석 결과	26
4.1 일반화된 SVR-IAM 및 SCC 확률 범위 추정	26
4.2 SCC 확률 범위 추정 CCS 확대의 영향	29
4.3 연구 시사점 및 한계	31
V. 결론	33
부록	34
참고문헌	36

표 목차

표 2.1. IAM의 불확실성 관련 매개변수 요약	14
표 3.1. PRTP와 CS 값의 조합을 고려한 SCC 값	21
표 3.2. SSP-CCS 시나리오에 대한 설명	24
표 3.3. 다양한 출처에서 얻은 CCS 유무에 따른 CAPEX, O&M, 연료비 데이터	25
표 4.1. 학습된 SVR-IAM 모델의 RMSE 결과	26
표 4.2. 학습된 IAM-SVR 모델의 R^2 결과	26
표 4.3. 그림 4.2의 SCC 확률 분포 범위의 요약 결과	29
표 4.4. 그림 4.3의 SCC 확률 분포 범위의 요약 결과	30
표 4.5. CCS 기술의 LCOE 및 CO ₂ 회피 비용 요약 결과	31

그림 목차

그림 1.1. 전 세계 기온을 보면 특정 지역의 기온이 1.5°C를 초과한 것으로 나타났다 (IPCC, 2018)	11
그림 1.2. 2100년까지의 지구 온도 변화 전망 (IPCC, 2022)	11
그림 3.1. IAM 모듈의 개략도	16
그림 3.2. a) FUND, b) PAGE 및 (c) DICE 모델의 개략도	17
그림 3.3. 각 IAM에서 얻은 사회경제적 데이터: PAGE(주황색), FUND(녹색), DICE(파란색). 데이터에는 (a) 인구, (b) 1인당 GDP, (c) 탄소 배출량 및 (d) 해당 SCC	18
그림 3.4. 연구 개략도	19
그림 3.5. (a) PRTP 및 (b) CS 값 고려 사항	20
그림 3.6. 각 IAM에서 얻은 SCC 결과: PAGE(주황색), FUND(녹색), DICE(파란색). SCC는 (a) 1% PRTP, (b) 1.5% PRTP 및 (c) 3% PRTP. 각 PRTP에 다양한 CS 값을 얻는 SCC 값	21
그림 3.7. 데이터 분할이 포함된 SVR 모델을 사용한 학습 및 평가 과정의 개략도	22
그림 3.8. 사회경제적 시나리오에 대한 몬테카를로 시뮬레이션 결과: (a) 인구, (b) 1인당 GDP, (c) 온실가스 배출량. 왼쪽은 DICE(파란색), PAGE(주황색), FUND(녹색)의 3가지 IAM 결과이고, 오른쪽은 SSP 시나리오 결과	23
그림 3.9. CCS 시나리오가 적용된 SPP 1부터 SSP5까지의 사회경제적 시나리오에 대한 몬테카를로 시뮬레이션 결과: (a) 인구, (b) 1인당 GDP, (c) 온실가스 배출량	24
그림 4.1. 세 가지 IAM에 대한 SVR 예측값과 SCC의 실제값 비교	26
그림 4.2. 총 400개의 미래 사회경제적 시나리오에 따른 (a) 2020년과 (b) 2100년의 SCC 확률 분포 결과	28
그림 4.3. 총 1100개의 미래 CCS 시나리오를 포함한 사회경제적 시나리오에 따른 (a) 2020년과 (b) 2100년의 SCC 확률 분포 결과	29
그림 4.4. 석탄 발전소 (a) CCS 미적용 및 (b) CCS 기술 적용 시 LCOE 결과	31

I. 서론

1.1 연구의 배경

인간 활동으로 인한 지구 온난화로 지구 표면온도는 2017년에 산업화 이전 수준 대비 약 1° 상승했다. 이미 다수의 지역에서는 상당한 수준의 온난화를 겪고 있으며, 특히, 전 세계 인구의 20~40%가 가장 더운 계절에 1.5°C가 넘는 온도 상승을 경험하고 있다(그림 1.1; IPCC, 2018). 이러한 기후변화로 인해 가뭄, 홍수 및 극한 기상현상(extreme weather)의 증가, 해수면 상승, 생물 다양성 감소를 포함하여 인간과 자연 시스템에 심각한 변화가 발생했다. 또한 인구 증가와 경제 활동으로 인한 직접적인 CO₂ 배출량 증가로 인해 2100년 지구 온도는 산업화 이전 대비 약 3.7~4.8°C 상승할 것으로 예측된다(그림 1.2; IPCC, 2022).

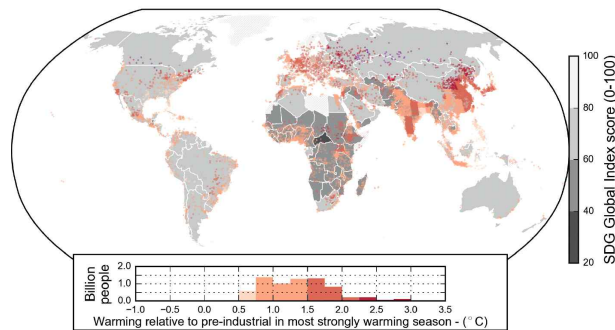


그림 1.1. 전 세계 기온을 보면 특정 지역의 기온이 1.5°C를 초과한 것으로 나타났다(IPCC, 2018).

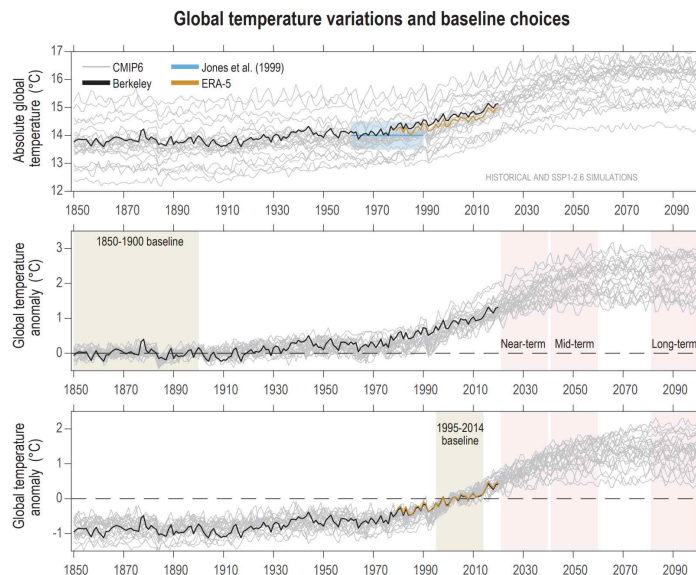


그림 1.2. 2100년까지의 지구 온도 변화 전망(IPCC, 2022).

탄소 포집 및 저장기술(carbon capture and storage, CCS)은 특히 전환이 어려운 부문에서 잔여 배출량을 상쇄할 수 있는 방법으로 고려되고 있다. 2022년에 발간된 IPCC 6th WGIII 평가 보고서는 파리협정 상의 온난화 제약 목표를 달성할 수 있는 배출경로 시나리오그룹(C1-C3)을 제시하고 있는데, 이 시나리오들은 잔여 이산화탄소 배출량의 감소를 위해 이산화탄소 제거 기술(carbon

dioxide removal)의 활용을 상정하고 있다. IPCC 시나리오(IPCC, 2018의 P2, P3, P4)에 따르면 2100년 총 CO₂ 지중저장은 약 348 Gt, 687 Gt 및 1218 Gt로 전망된다. 해당 보고서의 평가 결과에 따르면, 기후변화 완화는 화석연료 관련 산업의 붕괴를 야기하며, 특히 석탄 산업은 2030년 이전에, 석유 및 가스의 경우는 2050년 이전에 붕괴 위험이 높아질 것으로, 또한 그 비용이 2° 제한 경로에서 약 1~4조 USD에 이를 것으로 전망하고 있다. 이러한 비용을 줄이기 위해서 해당 보고서는 CCS의 역할을 강조하였다.

한국은 2011년 7월 효율적인 CCS 기술개발을 통해 온실가스 배출을 줄이고 신성장동력을 창출하기 위해 ‘국가 CCS 종합 추진계획(National CCS Comprehensive Plan)’을 수립하였다. 이와 관련하여, 2011년부터 2013년까지 기간 동안 1단계 CCS 기술의 개념을 검증하기 위해 노력했으며, 신소재 추가 및 공정 모델링을 통해 4종 이상의 CO₂ 포집 기술을 확보하였다. 2014년부터는 bench-scale CCS 기술 개발을 목표로하였으며, 2017년부터 2019년까지는 앞선 성과를 기반으로 대규모 배출원에 대한 CCS 기술 효과에 대한 시범 검증을 진행하고 있다(Koh et al., 2018).

그러나 CCS 기술은 아직까지 논란이 존재한다. CCS 구현의 주요 어려움은 크게 기술적 및 경제적 측면으로 구분된다. 기술적인 측면에서, 지질학적으로 저장된(geological carbon storage) CO₂는 지하 단층을 통해 저류층(reservoir)에서 누출 가능성이 있으며 지하수층을 오염시키고 결국 대기에 배출될 수 있다(Caesary et al., 2020). 경제적인 측면에서, CCS는 자본 집약적인 장기투자(long-term investment)를 필요하다. 관련 자산에는 포집 발전소와 공장 외에도 CO₂ 수송 파이프라인과 지질학적 저장 저류층이 포함되며, 이를 평가, 구축 및 개발하는 데 큰 비용이 소요되는 것으로 나타났다. 이러한 상황에서 CCS 확대 정책에 대한 평가가 필요한 것으로 확인되고 있다. 이때, 이러한 확인 방법 중 하나는 CCS 확대에 따른 사회적 탄소 비용(social cost of carbon, SCC)의 변화를 살펴보는 것이다. CCS의 비용편익분석(cost-benefit analysis)은 SCC를 사용하여 평가할 수 있으므로, CCS 기술이 SCC보다 적은 비용으로 CO₂ 배출을 방지할 수 있다면 CCS는 비용-편익 평가를 통과한 것으로 간주되며, 이는 CCS와 같은 대체 탄소 저감 전략에 투자하는 것이 유리하다는 의미다(Heyes and Urban, 2019).

SCC는 온도 상승으로 인한 사회적 피해를 측정하는 값으로, 탄소 1톤이 추가로 배출될 때마다 금전적 가치로 평가하고 정의하다. 부정적인 외부효과는 오염자나 소비자가 책임을 지지 않는 온실가스 배출로 인해 발생하는 사회 전반적인 비용을 의미다(Remeur, 2020). 이를 평가함으로써, 특정 시점에서 기후 정책에 대한 올바른 평가가 가능하다(Anthoff et al., 2009; Tian et al., 2019). SCC의 산정에는 지구 시스템 및 사회경제적 구성요소에 대한 지식을 결합한 통합평가모델(Integrated Assessment Model, IAM)이 주로 사용되는데, 이 결과로 산정되는 SCC 값은 불확실성을 내포하고 있어, 이에 대한 정보도 함께 제공될 필요가 있다. IAM 모델 중 가장 많이 사용되는 모델은 Climate Framework for Uncertainty, Negotiation, and Distribution (FUND) (Anthoff & Tol, 2014), Policy Analysis of the Greenhouse Effect (PAGE) (Hope 2006; Yumashev et al., 2019) 및 Dynamic Integrated Climate Economy (DICE) (Nordhaus & Sztorc, 2013) 이다. 세 모델 간의 주된 차이점은 모델 내에서 사회경제적 데이터를 어떻게 수학적으로 처리하는지에 있다(Caesary et al., 2023).

1.2. 연구의 목적

본 연구는 탄소포집 및 저장(CCS) 기술 확대에 따른 사회적 탄소 비용(SCC) 영향을 평가하는 방법론을 개발하고자 한다. 이때, 사회경제적 조건과 통합평가모델(IAM)에서 선택가능한 여러 매개 변수의 불확실성을 신속하게 고려한다. 이를 통해 최종적으로 기후 완화정책의 평가에 효과적으로 기여하고자 한다. 이러한 연구 목표의 달성을 위해 본 연구는 다음과 같은 두 가지 과업을 달성하고자 한다. (1) 통합 평가 모델(IAM) 고려한 사회경제적 시나리오, (2) 기계학습을 활용한 탄소 사회적 비용(SCC) 및 확률 계산 자동화 및 CCS 확대의 영향 분석. 기계학습은 다양한 IAM의 변화로 인한 SCC 추정과 관련된 불확실성을 효과적으로 포착할 수 있는 자동화된 일반화 IAM을 개발하기 위해 활용한다. 일반화 IAM 기반 기계학습 모델은 SCC를 계산하고 SCC 범위의 확률 분포를 산정한다. 또한 CCS의 비용편익분석은 CCS CO₂ 회피 비용과 SCC 확률 범위를 비교하여 수행한다.

연구의 필요성 및 기대효과는 다음과 같다: 기후 완화 목표를 달성하려면 2050년까지 대규모 CCS 시설의 건설이 필요하지만 아직까지 대규모 CCS에 건설과 관련된 어려움, 가능성 및 기회를 분석한 연구는 부족한 실정이며 이에 대한 보완이 필요한 실정이다. 이번 연구를 통해 불확실성을 고려한 포괄적인 분석을 수행하여 CCS 확대에 의한 SCC의 확률적인 평가 결과를 제공할 것으로 기대된다. 또한, 빠르게 변화하는 사회에서 다양한 가능성을 포함한 예측 모델을 제공하여 신속하게 SCC 평가를 수행할 수 있을 것으로 기대된다.

1.3. 연구 구성

본 연구는 다음과 같이 구성된다. 2장에서는 사회적 탄소 비용 및 통합평가모델 불확실성, 에너지 및 기후변화 분야에서 기계학습 적용에 대한 문헌을 검토하고 3장에서는 자료수집 및 분석 방법을 소개한다. 또한, 3장은 통합 평가 모델(IAM) 및 탄소 포집 및 저장(CCS) 확대 시나리오 및 기계학습을 활용한 탄소 사회적 비용(SCC) 및 확률 계산 자동화 및 CCS 확대의 영향 등 2가지 부분으로 구성된다. 4장에서는 일반화 IAM 기반으로 기계학습 모델 및 SCC 확률 범위 추정 결과 및 SCC 확률 범위 추정 CCS 확대의 영향 결과 대해 논의한다. 또한 연구의 시사점 및 한계를 살펴본다. 5장 결론에서는 연구 결과를 요약한다.

II. 문헌 검토

2.1. 사회적 탄소 비용 및 통합평가모델 불확실성

사회경제적 배출, 기후 모델링, 기후 피해 모델링의 구성 요소에 초점을 맞춘 세 가지 IAM을 검토한 결과, DICE는 SCC의 분포가 더 조밀하게 분포하는 반면에 PAGE 및 FUND 결과는 각각 긴 long right-tail를 가지고 있다(Rose et al., 2017). 기후 모듈 구성요소인 DICE, PAGE, FUND를 비교한 결과, 세 가지 IAM이 서로 다른 결과를 가져온다는 것을 발견하였다(Calel and Stainforth, 2017). 메타 분석 통해서 36개 IAM의 SCC 추정결과에 대한 SCC의 분포가 -13.36USD/tCO₂에서 2,386.91USD/tCO₂ (평균 54.7 USD/tCO₂)로 광범위하게 나타났다(Wang et al., 2019).

기후 민감도(climate sensitivity, CS), 지역-부문별 평가, 할인율을 분석한 결과, 이들 불확실성은 온도 변화 및 정책과 관련이 있으며, 그 결과 광범위한 범위의 SCC가 발생한다는 것을 발견했다(Downing et al., 2005). CS, 피해 함수, 재해 발생 처리, 할인율 변수를 기반으로 IAM 불확실성을 연구하고 IAM 사용에 대한 다섯 가지 대안을 제안했다(Metcalf and Stock, 2017). 두 연구 모두 정기적인 업데이트를 통해 SCC 추정치를 개선해야 한다고 제안했다. CS의 불확실성과 피해 함수에 대한 분석을 수행하여 두 변수 간의 결합 효과를 DICE에서 보여주었다(Menouy, 2020).

분석 결과는 기간 초반에는 낮은 추정 기온과 높은 CS의 사전 분산으로 인해 CS의 불확실성이 지배적인 반면, 시간이 지남에 따라 기온이 상승함에 따라 피해 함수의 불확실성이 더 큰 영향을 미치는 것으로 나타났다. 다양한 SCC 값은 IAM에서 고려하는 독립 변수가 다르기 때문에 예상되며, 이는 SCC 추정의 불확실성을 초래하였다. 불확실성은 주로 CS와 치명적 재해 가능성, 손실 함수, 순시간선호율(pure rate of time preference, PRTP) 등과 같은 매개변수를 포함하는 IAM 모델을 기반으로 분석하였다(표 2.1).

표 2.1. IAM의 불확실성 관련 매개변수 요약.

IAM 모듈	불확실성 매개변수	참고 논문
기후 모듈	기후 민감도(CS) 또는 치명적 재해	Calel and Stainforth, 2017; Metcalf and Stock, 2017; Weitzman, 2012
	기후 피드백(e.g., 기상이변)	Martinkova and Hanel, 2016; Ummenhofer and Meehl, 2017
	온도 함수	Calel and Stainforth, 2017
할인 모듈	순시간선호율(PRTP)	Downing et al., 2005; Metcalf and Stock, 2017)
통합	지역 수준	Li et al., 2014; Weyant, 2017

대부분의 IAM 모델은 정규확률밀도함수(probability density function) 결과를 기반으로 약 3°C의 CS 값을 약 3°C로 사용했다. 그러나 기후변화로 인해 향후 치명적 피해 발생 가능성을 고려하여 일부 연구(예시: Weitzman, 2012)에서는 Pareto 분포를 이용해 6°C 또는 12°C 더 높은 CS 값이 도출될 수 있음을 보여주었으며, CS값의 선택은 불확실한 매개변수 중 하나로 취급된다. 또한, 기상이변으로 인한 수증기 및 수계의 시스템 변화와 같은 예측하지 못한 기후 피드백으로 인해 치명적 재해의 불확실성이 존재한다(e.g., Martinkova and Hanel, 2016; Ummenhofer and Meehl, 2017). 온

도 함수는 일반적으로 대기 농도, CS 및 총 복사강제력(radiative forcing)로 구성되지만 각 IAM의 함수 구조는 상당히 다르다. 기후 손실을 추정하는 과정에서는 온도 변화에 따라 사용되는 다양한 손실 함수 구조와 고려되는 분야가 다르기 때문에 불확실성이 발생한다. 할인율 매개변수는 PRTP, 소비의 한계 효용 탄력성(η), 그리고 1인당 소비 증가율(g)을 포함한다. 각 IAM은 PRTP 값에 약간의 차이를 두는데, 이로 인해 불확실성이 나타난다.

2.2. 에너지 및 기후변화 분야에서 기계학습 적용

기계학습 방법 중 서포트 벡터 머신(support vector machine, SVM)을 사용하여 인도네시아 데이터의 전기 및 석탄 연소 투입자료를 활용해 CO₂ 배출량을 예측하였다(Saleh et al., 2016). 17개국(미국, 중국, 인도네시아, 한국 등)의 GDP, 도시 인구 및 무역 개방성으로 인한 CO₂ 배출량을 추정하기 위해 인공 신경 회로망(artificial neural network, ANN) 방법을 사용하였다(Jena et al., 2021). ANN은 시계열 데이터에 존재하는 비선형성을 포착하기 위한 효율성 때문에 선택되었다. Hybrid GRU (gated recurrent units) 및 XGBoost는 승객 수 및 기상 조건에 대한 추가 정보와 함께 실시간 버스의 배출량을 사용하여 운송 부문의 CO₂ 배출량을 예측하였다(Hu et al., 2021). Hybrid ARIMA-LSSVM (autoregressive moving average - least square SVM)은 각각 탄소 가격의 선형 및 비선형 성분을 포착하기 위해 사용되었다(Zhu & Wei, 2013). 입력 데이터 세트는 일일 가격의 3032개의 샘플로 포함되었다. 일일 거래 가격 2939개의 총 입력 데이터를 사용하여 미래의 탄소 가격을 예측하기 위해 ANN이 사용되었다(Yahşi, et al., 2019). 예측 결과는 투자 결정과 전략 결정에 있어 탄소 시장 거래자와 정책 입안자에게 중요한 의미를 가진다.

III. 분석 방법 및 자료

3.1. 통합 평가 모델(IAM) 고려한 사회경제적 시나리오

탄소의 사회적 비용(SCC)은 GHG 배출로 인한 사회적인 비용을 의미하며, 이는 오염자나 소비자가 직접적으로 부담하지 않아 발생하는 부정적인 외부효과에 기인된다(Remour, 2020). SCC는 온도상승으로 인한 피해량을 통해, 추가로 배출되는 탄소 1톤당 달러 가치로 표현된다. CO₂ 및 non-CO₂ GHG의 외부성 평가 값인 SCC는 탄소세 수준의 결정과 같은 기후 정책 수립에서 중요한 역할을 한다(Tian et al., 2019). 정부나 규제 기관은 SCC를 조사함으로써 추정된 SCC 금액을 고려하여 납세 등을 통해 오염자에게 부과할 수 있다(De, 2020).

SCC 산정에는 통합평가모델(IAM)이 널리 사용되는데. 일반적으로 IAM은 사회경제적 모듈, 기후 반응 모듈, 피해/손실(damage) 및 미래 할인(future discounting) 모듈로 구성된다(그림 3.1; Ricke et al., 2018). IAM은 모듈 간의 상호 연결된 관계와 함께 지구 시스템 및 사회경제적 구성요소에 대한 지식을 바탕으로 SCC를 추정하는 모델이다. 많은 연구가 IAM을 이용해 SCC를 추정하였다. 가정한 사회경제적 조건에 따라, 인간 활동으로 인한 온실가스 배출량을 추정한다. 탄소 배출량은 탄소 순환을 고려해 대기 중 잔류하게 되는 배출량을 기반으로 온실가스의 대기 중 농도가 추정된다. 그 후에는 복사 강제력(radiative forcing, RF)과 CS 값을 바탕으로 온도 상승을 추정한다. SCC는 예상 온도 상승에 따른 순시간선호율(PRTP)로 추정된다.

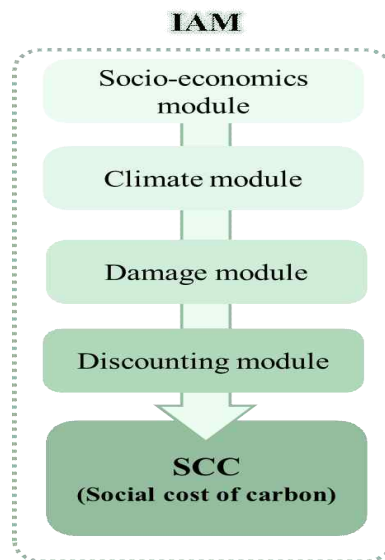


그림 3.1. IAM 모듈의 개략도.

세 가지 IAM의 최신 버전은 오픈 소스 모델을 사용한다: FUND, PAGE, and DICE¹⁾ (그림 3.2). 사회경제적 모 경우, DICE는 총요소생산성(total factor productivity, TFP), 자본, 인구의 함수에 성장률을 더한 총생산량 변수를 사용하여 사회경제적 상황을 설명한다(Krichene, 2019). 인구 증가율은 5년간 13.4%로, 2050년 인구 전망치는 UN의 전망치와 동일하고 2010년 세계 총생산으로 보정

1) FUND3.9는 [http://www.fund-model.org/ documentation/](http://www.fund-model.org/documentation/) 및 <https://github.com/fund-model/MimiFUND.jl> (Anthoff & Tol, 2014); PAGE2020는 <https://github.com/openmodels/MimiPAGE2020.jl> (Kikstra et al., 2021); DICE2013는 <https://github.com/anthofflab/MimiDICE2013.jl> (Anthoff et al., 2015).

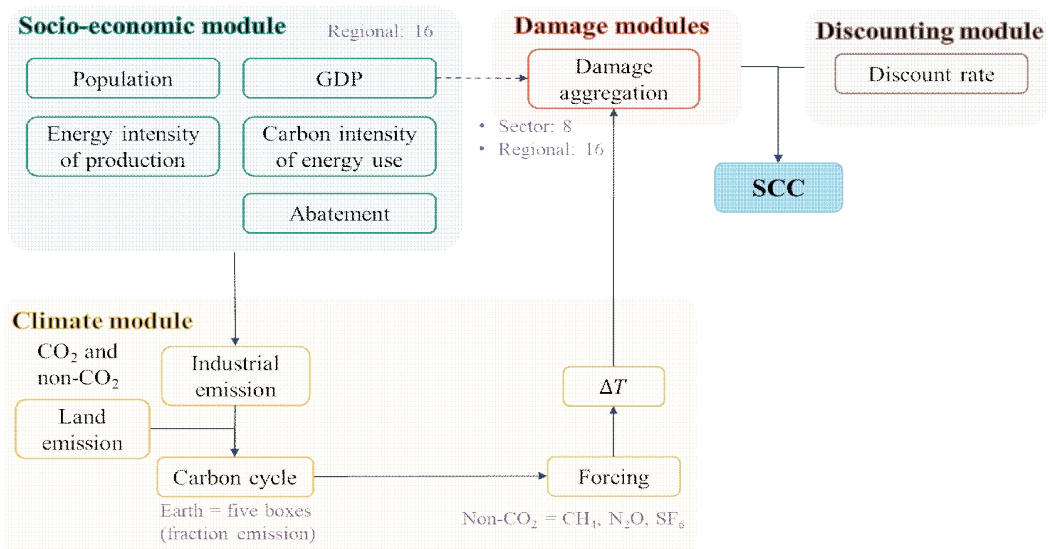
하여 5년마다 0.5%씩 감소하는 것을 기준으로 한 TFP의 초기 성장률은 7.6%였다. 인위적 CO₂ 배출량은 TFP, 자본/투자, 인구, 탄소 집약도, 배출 통제율(배출량 감소)로부터 추정된다. 탄소 집약도는 2015년을 기준으로 1.52%의 초기 성장률과 5년마다 0.1%씩 감소하는 것으로 가정한다.

FUND는 에너지 모델링 포럼-14(EMF-14; Energy Modeling Forum, 1995)의 인구 및 소득 데이터 변수를 사용하였다. CO₂ 배출량(M)은 인구, 1인당 GDP, 탄소 집약도, 에너지 집약도로 구성된 카야 항등식을 사용하여 추정하였다.

$$M = P \left(\frac{Y}{P} \right) \left(\frac{E}{Y} \right) \left(\frac{M}{E} \right) = P y e f$$

P는 인구, Y는 GDP, E는 에너지 사용량을 뜻한다. 1인당 GDP 혹은 y는 GDP와 인구의 비, 에너지 집약도(e)는 에너지 사용량과 GDP의 비, 탄소 집약도(f)는 탄소배출량과 에너지 사용량의 비로 정의하였다.

PAGE는 IPCC가 최근 평가 보고서의 중요한 입력 자료로 사용한 공통사회경제경로(Shared Socioeconomic Pathways, SSP)와 대표 농도 경로(Representative Concentration Pathways, RCP)를 참조하였다(Kikstra et al., 2021). SSP와 RCP는 전 세계 인구 및 GDP와 같은 사회경제적 추세를 제공한다. 배출량 증가율은 RCP 시나리오로 가중치를 부여한 값을 사용하며(가중치 증가율은 2020년에 1.02에서 시작하여 2040년에 1.11로 최고치를 기록한 후 2300년에 0.005로 감소), 인구 및 GDP 증가율 가중치는 SSP를 참조하였다.



(a)

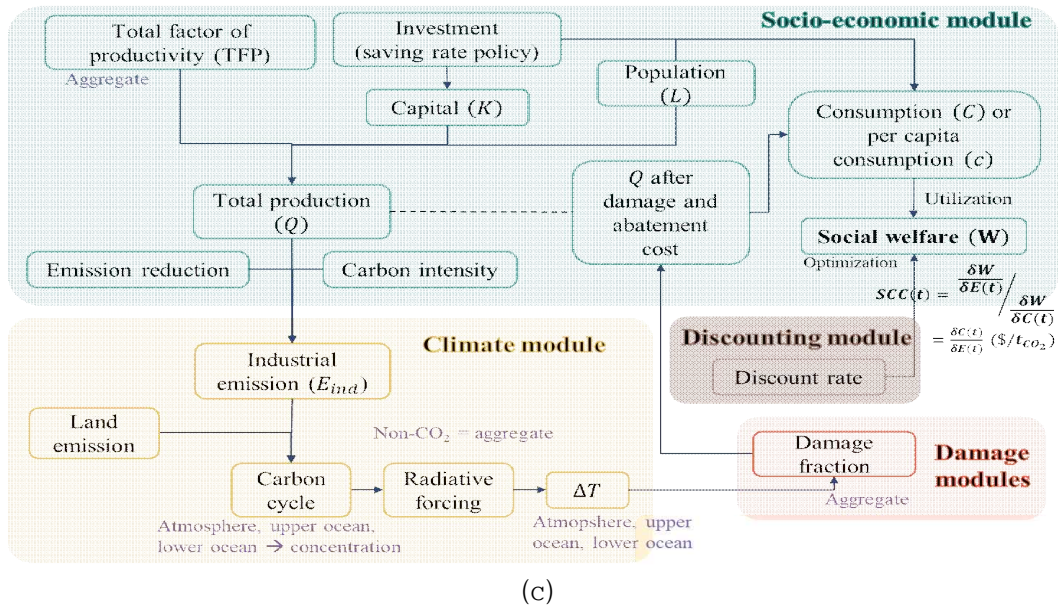
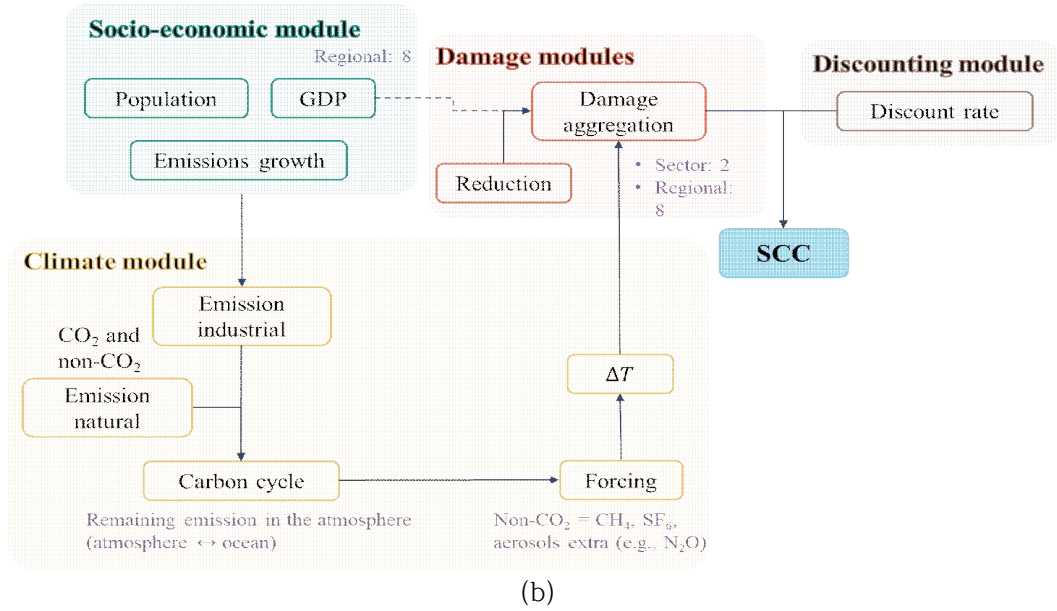




그림 3.2. a) FUND, b) PAGE 및 (c) DICE 모델의 개략도.

본 연구에서는 탄소 배출량 데이터뿐만 아니라 사회경제적 조건, 인구 및 1인당 GDP를 포함한 각 IAM의 기본 데이터를 활용한다, 또한 각 IAM에 해당하는 SCC를 계산한다(그림 3.3).



(a)



(b)

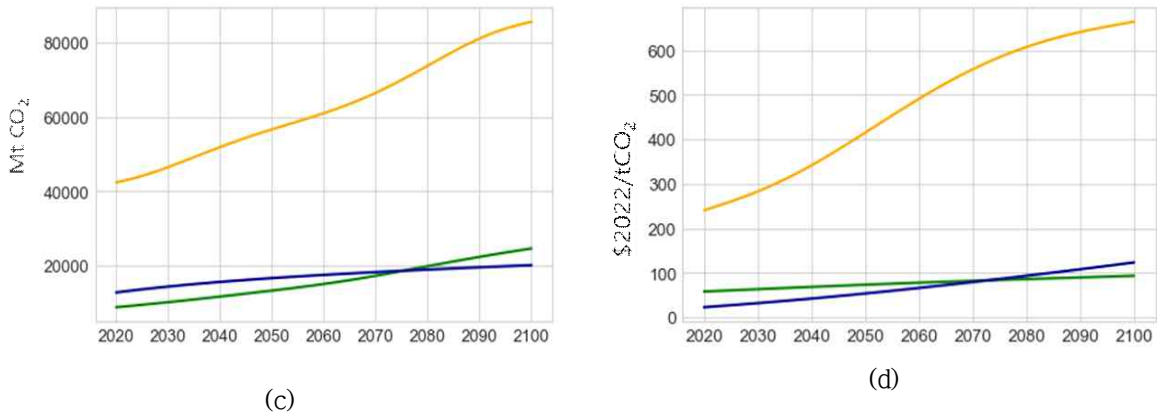


그림 3.3. 각 IAM에서 얻은 사회경제적 데이터: PAGE(주황색), FUND(녹색), DICE(파란색). 데이터에는 (a) 인구, (b) 1인당 GDP, (c) 탄소 배출량 및 (d) 해당 SCC.

3.2. 기계학습을 활용한 탄소 사회적 비용(SCC) 및 확률 계산 자동화 및 CCS 확대의 영향

기계학습을 적용하여 SCC 분포 범위를 추정하는 과정은 크게 기계학습 모델을 학습시켜 일반화된 IAM 모델을 훈련하기 단계와 SCC의 확률 분포를 추정하는 단계로 나뉘었다. 또한 일반화된 IAM 모델은 향후 CCS 확대 시나리오를 고려할 때 SCC의 잠재적 변화를 분석하기 위해 활용된다(그림 3.4).

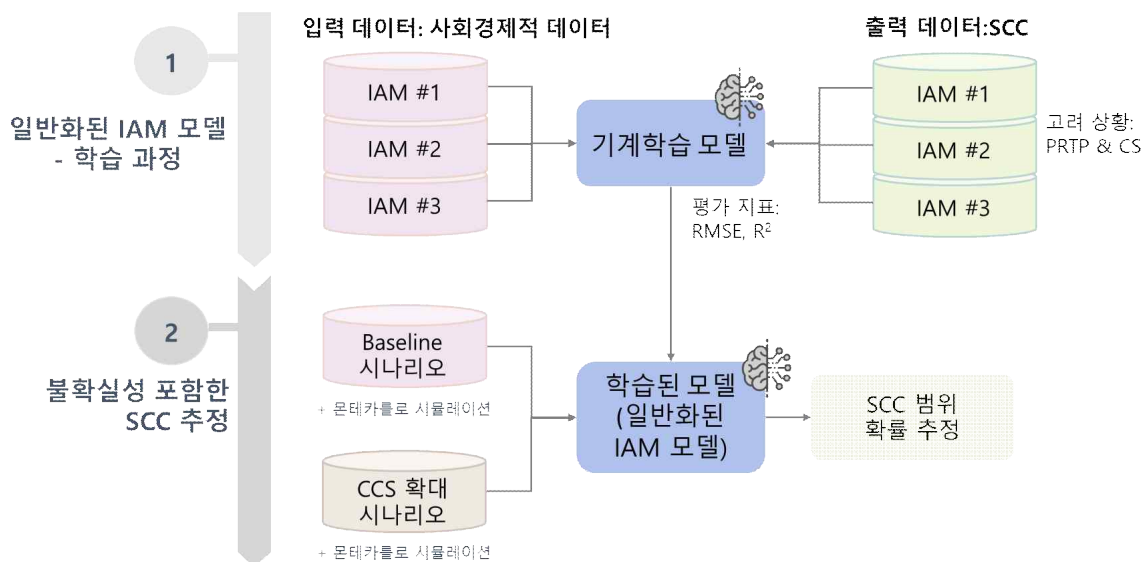


그림 3.4. 연구 개략도.

3.2.1 일반화된 SVR-IAM 및 SCC 확률 범위 추정

본 연구는 기계학습 방법중 서포트 벡터 회귀(support vector regression, SVR)를 활용하며 이 모델은 상대적으로 작은 데이터셋에서도 분류, 회귀 및 예측에서 우수한 학습 성능을 보인다는 장점이 있다(Drucker et al., 1997; Moura et al., 2011; Pedregosa et al., 2011; Wang et al., 2017; 부록 A). SVR은 지도학습 방법이기 때문에 훈련 단계에서 입력 변수와 출력 변수가 필요하다. 일반화된 SVR-IAM 모델 훈련하기 위해, IAM에서 불확실성의 주요 원인은 미래 사회경제적 시나리오와 선택된 PRTP 및 CS 값이기 때문에 이러한 매개변수를 입력 변수로 지정하고, SCC 값을 출력 변수로 지정한다.

다양한 PRTP과 CS 값을 고려하기 위해 PRTP를 3가지 경우로 구분하였으며, 선택한 PRTP 값은 SCC 메타 분석 연구에서 가장 많이 사용된 값인 1%, 1.5%, 3%이다(Wang et al., 2019; 그림 3.5). CS값은 기후변화에 따른 치명적 재해 가능성을 반영하기 위해 CS Pareto 분포에 근거하며 3°C, 3.83°C, 6.71°C 및 11°C를 적용하였다. 하나의 입력 사회경제 데이터 세트에 대한 CS과 PRTP 값을 결합하여 총 10개의 SCC 값이 도출된다(그림 3.6, 표 3.1). 사회경제적 데이터는 2020년부터 2100년까지 연간 데이터로 구성되며, 각각 70%, 20%, 10%의 비율로 훈련(train), 검증(validation), 테스트(test)의 세 가지 데이터 세트로 나눈다. 훈련 과정은 훈련 데이터 세트를 사용하여 수행되었으며, 검증 및 테스트 데이터 세트는 훈련된 모델을 검증하는 단계에서 사용된다(그림 3.7). 평균 제곱근 오차(root mean squared error, RMSE)와 결정계수(coefficient of determination, R^2)의 평가 지표에 따라 최적의 성능 모델을 얻기 위해 SVR 하이퍼파라미터(hyper-parameter)의 파인튜닝(fine-tuning)을 실행한다.




그림 3.5. (a) PRTP 및 (b) CS 값 고려 사항.

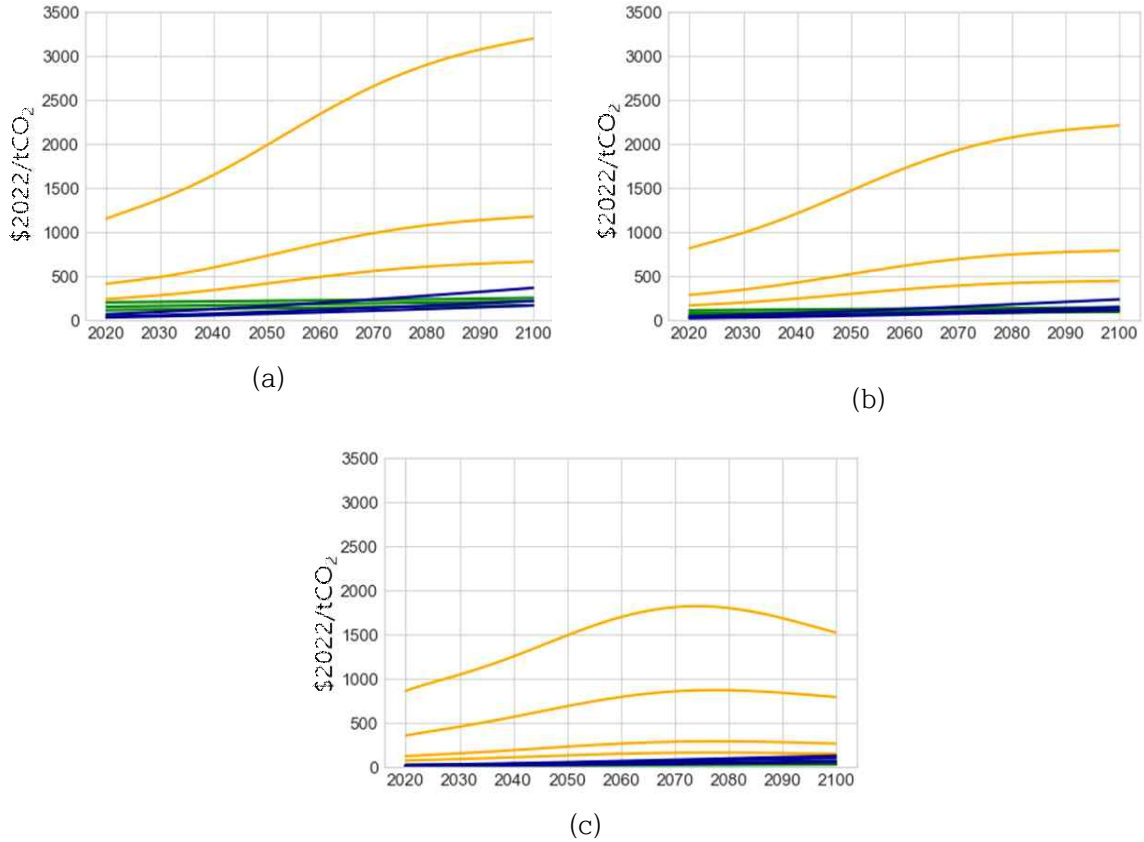


그림 3.6. 각 IAM에서 얻은 SCC 결과: PAGE(주황색), FUND(녹색), DICE(파란색). SCC는 (a) 1% PRTP, (b) 1.5% PRTP 및 (c) 3% PRTP. 각 PRTP에 다양한 CS 값을 얻는 SCC 값.

표 3.1. PRTP와 CS 값의 조합을 고려한 SCC 값.

PRTP	기후 민감도(CS) (° C)	비고
1.5%	2.8	SCC_1
	3.8	SCC_2
	6.7	SCC_3
1.0%	2.8	SCC_4
	3.8	SCC_5
	6.7	SCC_6
3.0%	2.8	SCC_7
	3.8	SCC_8
	6.7	SCC_9
	11	SCC_10

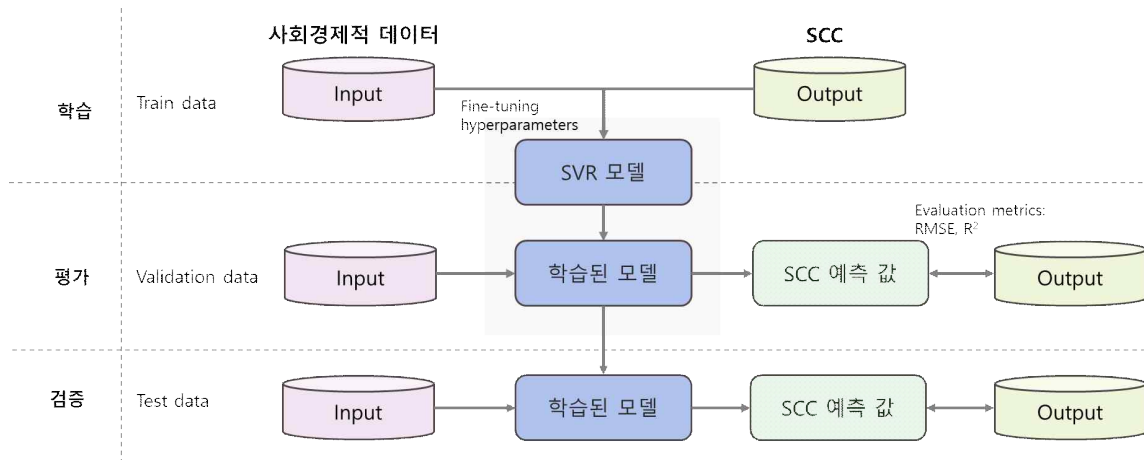


그림 3.7. 데이터 분할이 포함된 SVR 모델을 사용한 학습 및 평가 과정의 개략도.

학습된 일반화 SVR-IAM은 다양한 미래 사회경제적 시나리오를 기반으로 SCC 값을 예측하는 데 적용되며, 여기에는 DICE, PAGE, FUND의 세 가지 IAM뿐만 아니라 공통사회경제경로(Shared Socioeconomic Pathways, SSP)²⁾ 기준(baseline) 시나리오도 포함된다. SSP는 SSP1에서 SSP5까지, 다양한 사회경제적 시나리오에 대한 설명(narrative)을 포함하고 있다(Riahi et al., 2017). SSP1은 지속 가능한 발전 경로, SSP2는 중도 성장 경로로 큰 변화 없는 역사적 패턴, SSP3은 국가가 지역적 관심사에 집중하는 불균형 성장 경로, SSP4는 국가 간 격차가 벌어지는 양극화 성장 경로, 그리고 SSP5는 화석 연료에 의존하는 고속 성장 경로를 표현한다.

사회경제적 데이터는 미래의 불확실성을 파악하기 위해 다양한 가능한 사회경제적 조건을 생성하는 몬테카를로 시뮬레이션을 적용한다. 몬테카를로(Monte-Carlo) 시뮬레이션은 입력 데이터를 기반으로 임의의 값을 선택하여 시뮬레이션을 수행하는 방식이며 이때, 최소값 및 표준편차 매개변수를 지정할 수 있다. 이러한 방법을 통해 미래의 다양한 가능성을 반영하고, 그에 따른 결과의 불확실성을 추정할 수 있다. 몬테카를로 시뮬레이션은 400여 개의 잠재적 미래 시나리오를 추가로 생성하기 위해 IAM 및 SSP 데이터 모두에 대해 각 사회경제적 시나리오에 적용된다(그림 3.8). 각 시나리오에 대해 일반화 SVR-IAM 모델을 사용하여 SCC를 추정하여 각 빈에 대한 발생 확률을 계산하고 SCC 값의 분포에 대한 분석을 수행한다.

2) SSP 데이터는 다음 링크에서 획득 <https://tntcat.iiasa.ac.at/SpDb/dsd?Action=htmlpage&page=10>,

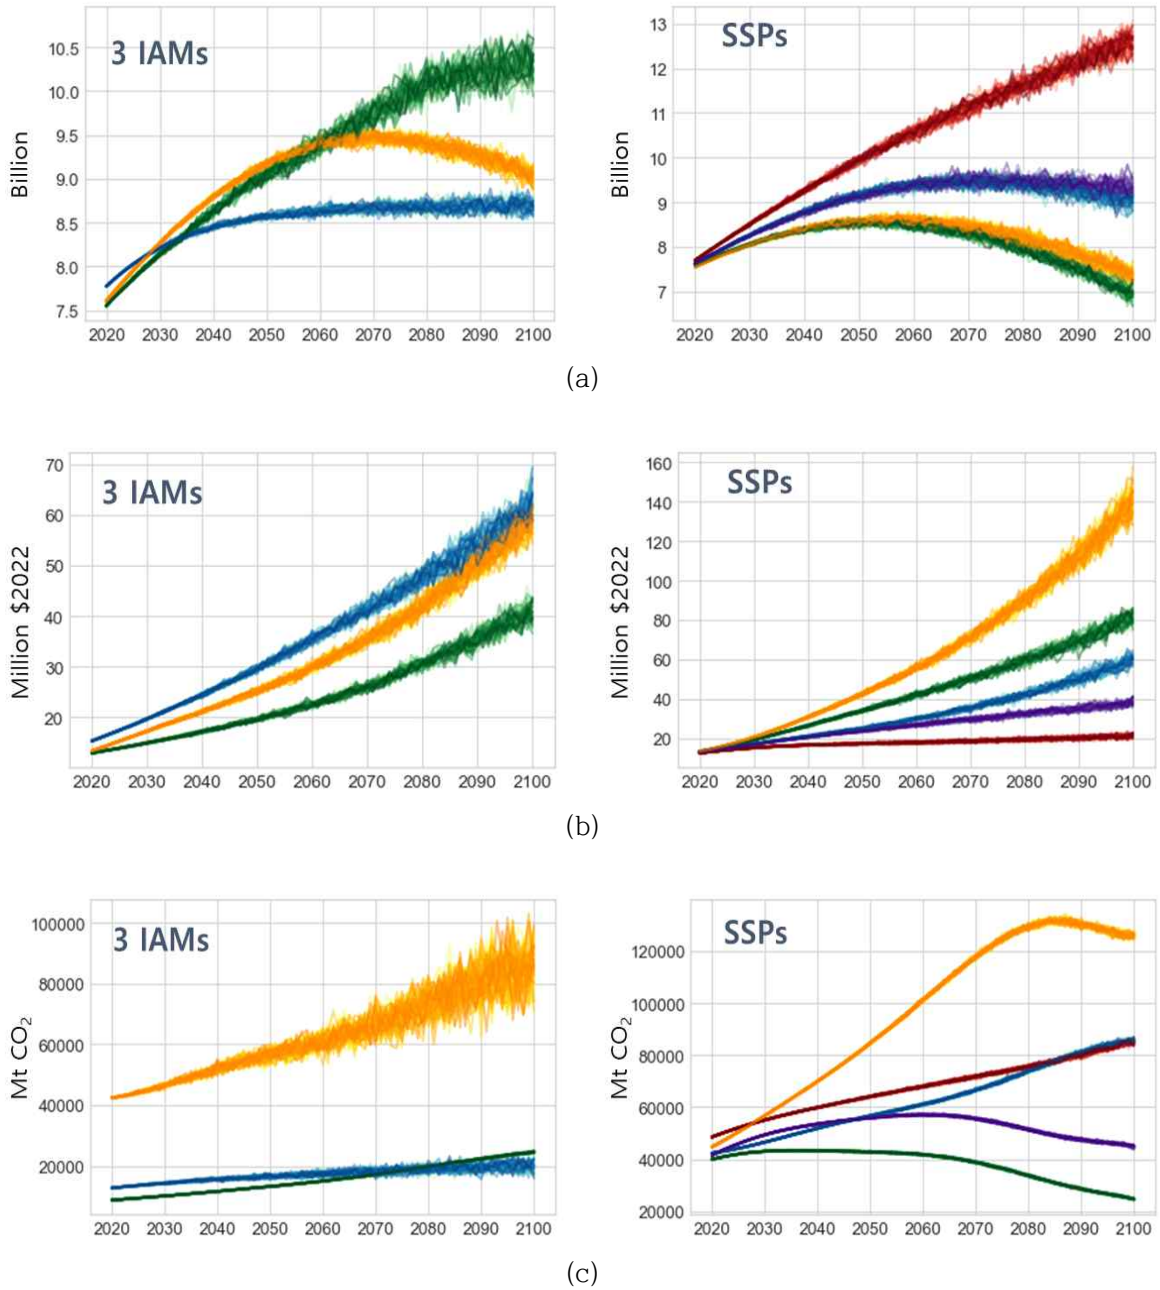


그림 3.8. 사회경제적 시나리오에 대한 몬테카를로 시뮬레이션 결과: (a) 인구, (b) 1인당 GDP, (c) 온실가스 배출량. 왼쪽은 DICE(파란색), PAGE(주황색), FUND(녹색)의 3가지 IAM 결과이고, 오른쪽은 SSP 시나리오 결과.

3.2.2 SCC 확률 범위 추정 CCS 확대의 영향

기준 시나리오 외에도 SSP 시나리오는 향상된 탄소 포집 기술을 통합한 완화 시나리오를 포함한다(Riahi et al., 2017). 이러한 완화 시나리오는 1.9, 2.6, 3.4, 4.5, 6.0과 같은 RCP 프레임워크에 부합하는 다양한 RF 수준을 고려하여 수립된다. 14개의 SSP-CCS 시나리오를 도출하고 몬테카를로 시뮬레이션을 통해 700개의 잠재적 미래 시나리오를 생성하여 일반화된 SVR-IAM과 추정된 SCC 값의 확률 분포를 사용하여 SCC를 추정한다(표 3.2, 그림 3.9).

표 3.2. SSP-CCS 시나리오에 대한 설명

SSP	RCP와 관련된 완화 시나리오
SSP 1	1.9, 2.6, 3.4
SSP 2	1.9, 2.6, 3.4, 4.5
SSP 3	3.4, 4.5
SSP 4	2.6, 3.4
SSP 5	1.9, 2.6, 3.4, 4.5

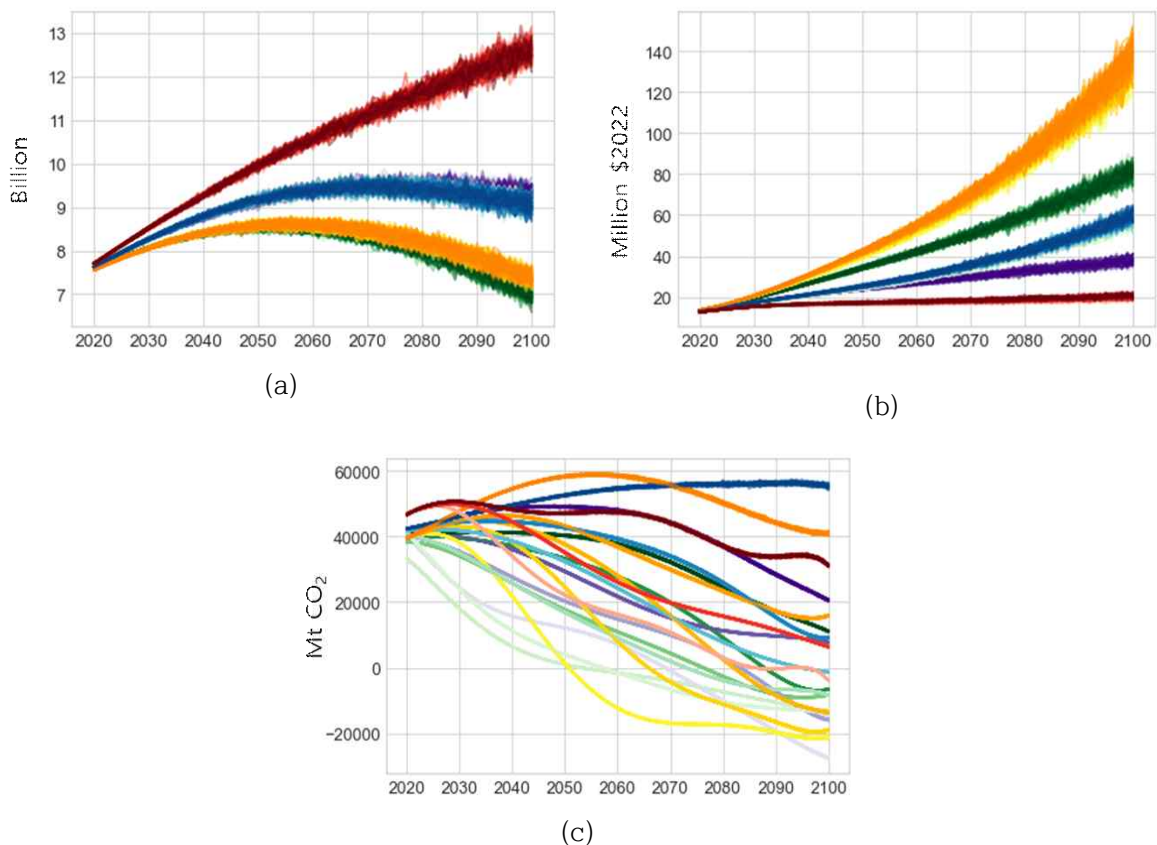


그림 3.9. CCS 시나리오가 적용된 SSP 1부터 SSP5까지의 사회경제적 시나리오에 대한 몬테카를로 시뮬레이션 결과: (a) 인구, (b) 1인당 GDP, (c) 온실가스 배출량.

SCC의 비용편익 분석은 CO₂ 회피비용을 산출하는 방식으로 진행되었으며, 이는 발전소 간 균등화발전비용(levelised cost of electricity, LCOE)과 발전량 단위당 배출량(tCO₂/MWh)을 비교하는 방식으로 수행하였다. 특히, 석탄화력발전소에 CCS 기술을 설치했을 때 얻을 수 있는 비용 절감 효과를 파악하기 위해 배출량 차이에 대한 LCOE 차이의 비율을 계산하였다. 본 연구의 목적상 석탄화력발전소만을 고려했다는 점에 유의해야 한다.

$$CO_2 \text{ 회피 비용} = \frac{LCOE_{CCS} - LCOE_{ref}}{(t_{CO_2}/MWh)_{ref} - (t_{CO_2}/MWh)_{CCS}} \quad (Eq3.1)$$

LCOE는 일반적으로 발전소의 전체 수명(t) 동안 가능한 발전량(E)에 대한 발전소의 총 비용 간의 비율로 정의한다.

$$LCOE = \frac{\sum_{t=1}^n \frac{C_{t=0} + OM_t + F_t}{(1+r)^t}}{\sum_{t=1}^n \frac{E_t}{(1+r)^t}} \quad (Eq3.2)$$

총비용에는 자본 비용(C), 운영 및 유지 관리 비용(operation and maintenance, O&M), 연료 비용(F)이 포함된다. 자본 비용 자체에는 발전소 시설의 설계, 조달, 및 건설(engineering, procurement, and construction; EPC) 비용, 도로, 토지 사용 및 소유자의 프로젝트 파이낸싱 비용 등을 포함한다(U.S. Energy Information Administration, 2016). O&M 비용은 고정O&M과 변동 O&M으로 구분하며, 고정 O&M에는 직원의 급여, 관리, 세금, 일상적인 유지 관리 및 플랜트 지원 장비 요구 사항까지 포함된다(U.S. Energy Information Administration, 2016). 변동O&M에는 발전소 운영 중에 필요한 자재가 포함된다. 발전소 발전량은 발전소의 이용률(capacity factor, CF)에 발전소의 발전용량(MW)을 곱한 값으로 정의된다. 용량 계수CF는 발전소의 성능 및 가동 시간과 관련이 있으며, 할인율r은 발전소의 수명 동안 총 비용을 현재 가치로 환산하는데 이용한다(U.S. Department of Energy, 2015). LCOE는 발전소 수명을 30년으로 가정하여 자본, O&M, 연료비, 할인율에 대한 다양한 연구(표. 3.3, EIA, 2016, NREL, 2022)의 데이터를 수집하여 계산한다.

표 3.3. 다양한 출처에서 얻은 CCS 유무에 따른 CAPEX, O&M, 연료비 데이터.

		석탄 발전소	
		CCS 미적용	CCS 적용
CAPEX	\$2022/kW	2901 - 4435	5529 - 6202
O&M	\$2022/kW-year	100 - 162	161 - 289
연료 비용	\$2022/kW-year	159 - 205	203 - 227

참고: U.S. Energy Information Administration (2016); NREL (2022)에서 수집

IV. 분석 결과

4.1 일반화된 SVR-IAM 및 SCC 확률 범위 추정

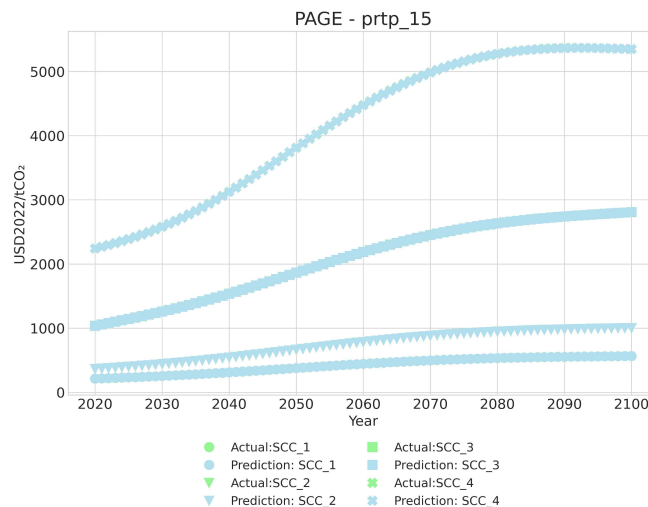
인구, 1인당 GDP, 온실가스 배출량을 입력 값으로 활용하여 SCC를 예측하는 훈련 과정을 거친 후, RMSE와 R^2 지표를 사용하여 SVR 모델의 성능을 평가한다. 평가 결과에 따르면 훈련, 검증 및 테스트 데이터의 RMSE 값은 $4.4E-04 \sim 1.01E-02$ 범위 내에 있으며(표 4.1), R^2 는 약 $9.9E-01$ 이다(표 4.2). 이는 SVR 모델의 SCC 예측이 실제 SCC 값과 거의 일치한다는 것을 의미하며(그림 4.1), 따라서 사용된 세 가지 IAM에서 일반화된 모델을 도출할 수 있다. 또한, 세 가지 모델의 훈련, 검증, 테스트 데이터 세트에 대한 RMSE 및 R^2 값을 비교하면 유사한 값을 나타내며 이는 모델이 과적합 문제를 효과적으로 해결한다는 것을 의미한다.

표 4.1. 학습된 SVR-IAM 모델의 RMSE 결과

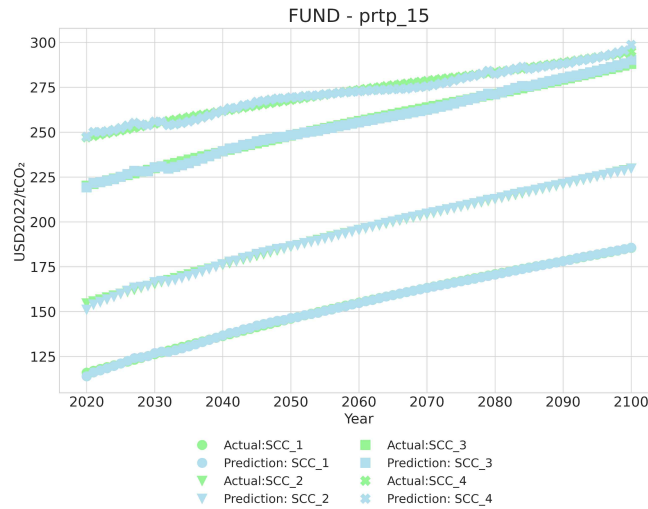
Data	RMSE		
	SVR Model 1 (PRTP1.5%)	SVR Model 2 (PRTP1%)	SVR Model 3 (PRTP3%)
Train	1.70E-03	3.01E-03	3.78E-04
Validation	2.36E-03	4.15E-03	3.84E-04
Test	5.95E-03	1.01E-02	4.4E-04

표 4.2. 학습된 IAM-SVR 모델의 R^2 결과

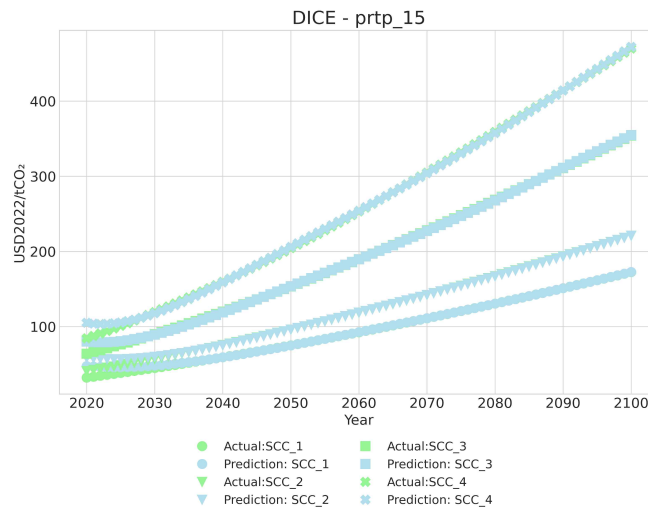
Data	R^2		
	SVR Model 1 (PRTP1.5%)	SVR Model 2 (PRTP1%)	SVR Model 3 (PRTP3%)
Train	9.99967E-01	9.9989E-01	9.99998E-01
Validation	9.99933E-01	9.9976E-01	9.99998E-01
Test	9.99463E-01	9.97294-01	9.99998E-01



(a)



(b)



(c)

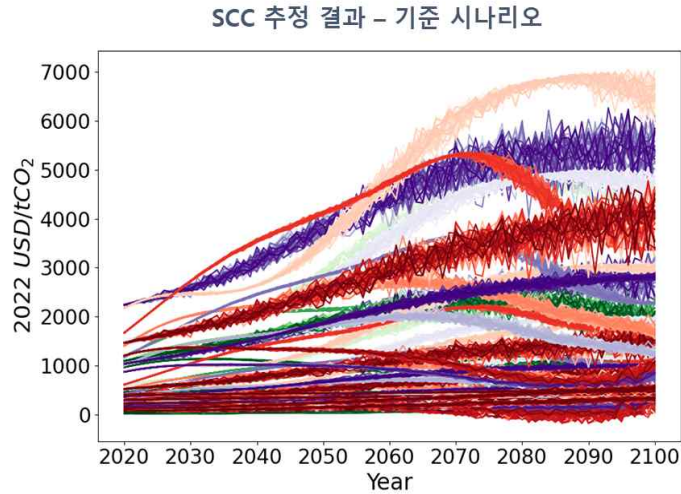
그림 4.1. 세 가지 IAM에 대한 SVR 예측값과 SCC의 실제값 비교.

일반화된 SVR-IAM 모델을 얻은 후, 이 모델을 활용하여 수많은 잠재적 미래 시나리오에 대한 SCC를 예측한다. 이를 위해 SSP 및 몬테카를로 시뮬레이션의 추가 데이터를 통합하여 총 400개의 시나리오를 생성한다.


각 파라미터 값 변화에 따른 SCC는 다음과 같이 변화하였다. PRTP 값이 낮다는 것은 기후변화로 인한 피해를 현 세대가 책임져야 한다는 것을 의미하며, 즉각적인 기후 정책 결정을 강조한다. CS 값이 높을수록 기후변화로 인해 기온이 더 많이 상승하고 피해의 강도가 더 커질 것임을 의미한다. PRTP 값이 0.5% 감소하면 SCC 값이 약 1.5배 증가하였으며, CS 값이 두 배로 증가하면 동일한 PRTP 값에 대해 SCC 값이 1.5배에서 1.9배 범위에서 증가한다.

SCC 범위의 확률 분포도 계산되었다. SCC 결과의 확률 분포는 오른쪽 꼬리가 길게 뻗어져 있으며, 이는 SCC 값이 높을수록 해당 SCC 값의 발생 확률이 감소한다는 것을 나타낸다. 예를 들어, 2020년 평균 SCC 값은 482 USD2022/tCO₂로 추정되며, 가장 높은 확률을 가진 SCC 값은 210


USD2022/tCO₂이다(그림 4.2b; 표 4.3). 반면, 2100년에는 평균 SCC 값이 1039 USD2022/tCO₂로 상승하고, 가장 높은 확률을 가진 SCC 값은 180 USD2022/tCO₂로 추정되었다(그림 4.2c; 표 4.3). 기준 시나리오에서 가장 높은 확률의 SCC 값은 소폭 감소하지만, 2020년에 비해 2100년에 높은 SCC 값이 발생할 확률이 증가한다는 것을 알 수 있다.



(a)



(b)



(c)

그림 4.2. 400개 미래 사회경제적 시나리오에 따른 (a) 2020년과 (b) 2100년의 SCC 확률 분포 결과.

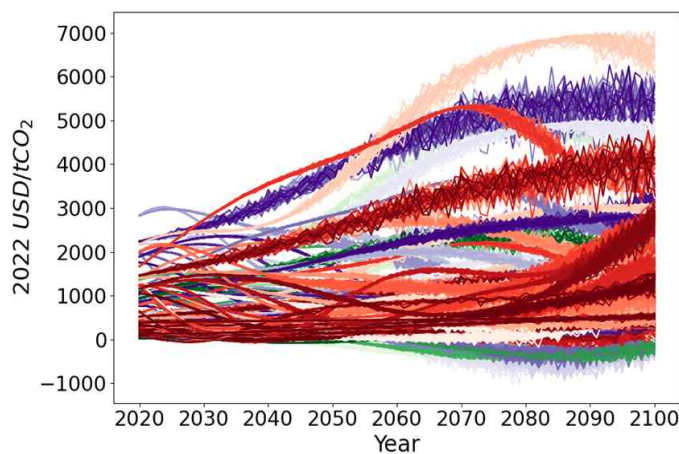
표 4.3. 그림 4.2의 SCC 확률 분포 범위의 요약 결과.

연도	SCC (USD2022/tCO ₂)			
	최소	평균	최대	최고 확률
2020	15	482	2172	210
2100	-45	1039	7024	180

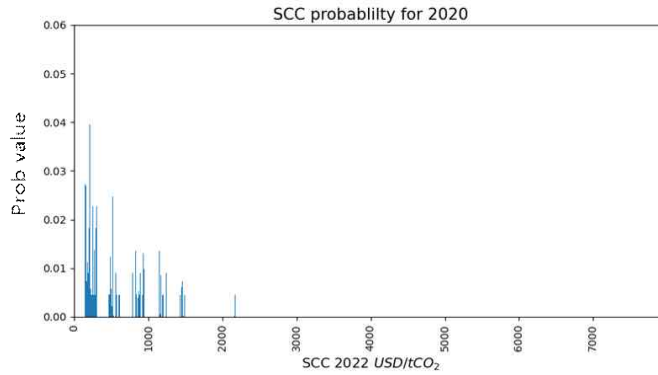
4.2 SCC 확률 범위 추정 CCS 확대의 영향

본 일반화된 모델을 다양한 미래 잠재적 CCS 확대 시나리오에 대해 SCC를 예측하는 데 적용하였다. 400개의 기준 시나리오 외에도 총 700개의 미래 CCS 확대 시나리오가 고려되어 SCC 값의 확률이 계산되었다. 2020년의 평균 SCC 값은 502 USD2022/tCO₂로 추정되며, 가장 높은 확률의 SCC 값은 80 USD2022/tCO₂로 추정되었다(그림 4.3b; 표 4.4). 2100년의 평균 SCC 값은 약 791 USD2022/tCO₂로 예상되며, 가장 높은 확률을 가진 SCC 값은 190 USD2022/tCO₂이다(그림 4.3c; 표 4.4). 기준 시나리오에서 관찰된 SCC 확률 분포를 그림 4.2와 표 4.3에서 비교하면, CCS 개발 시나리오를 통합한 결과 평균 SCC 결과가 약 23.8% 감소하였다. 또한, 2100년에 높은 SCC 값(>1000 USD2022/tCO₂)이 발생할 확률도 감소하여 CCS 개발 확대가 향후 치명적인 재해의 잠재력을 완화할 수 있음을 시사한다. 또한, 온실가스 배출량의 현저하고 지속적인 감축이 달성되는 미래 시나리오에서는 SCC가 마이너스 값이 될 것으로 예상되어 기후 관련 피해 감소, 환경 개선, 경제적 번영을 기대할 수 있다.


SCC 추정 결과 - 기준 & CCS 시나리오



(a)



(b)



(c)

그림 4.3. 총 1100개의 미래 CCS 시나리오를 포함한 사회경제적 시나리오에 따른 (a) 2020년과 (b) 2100년의 SCC 확률 분포 결과

표 4.4. 그림 4.3의 SCC 확률 분포 범위의 요약 결과

연도	SCC (USD2022/tCO ₂)			
	최소	평균	최대	최고 확률
2020	15	502	2172	80
2100	-360	791	7024	190

CCS를 적용하지 않은 석탄발전소의 LCOE는 6.5 ~ 14.3 cents/kWh 범위인 반면, CCS를 적용시 LCOE가 적용하면 10.5 ~ 20 cents/kWh 범위로 증가하였다(그림 4.4, 표 4.5). 발전소에 CCS를 도입 시 CO₂ 배출 강도를 약 80%까지 줄일 수 있는 것으로 알려져있다(Cebrucean et al., 2014). 결과적으로 CO₂ 회피 비용은 48.2~68.7 USD2022/tCO₂ 범위로 추정된다. 이러한 결과를 표 4.5에 제시된 SCC 범위와 비교하면 CO₂ 회피 비용이 추정된 SCC 범위 값보다 낮다는 것을 알 수 있다. 이 결과는 CCS 기술 도입에 대한 투자의 비용 효율성을 나타내며, CCS가 탄소 배출과 관련된 피해를 완화함으로써 상당한 사회적 편익에 기여한다는 것을 시사한다.




그림 4.4. 석탄 발전소 (a) CCS 미적용 및 (b) CCS 기술 적용 시 LCOE 결과.

표 4.5. CCS 기술의 LCOE 및 CO₂ 회피 비용 요약 결과

		석탄 발전소		차이 값
		CCS 미적용	CCS 적용	
LCOE	cents/kWh	6.5 - 14.3	10.5- 20	4.0 - 5.7
CO ₂ 배출 집약도	gr/kWh	975.2(a)	146.28(b)	828.92
CO ₂ 회피 비용	\$2022/tCO ₂			48.2 - 68.7

Note: ^(a)Hondo, 2005, ^(b)Cebrucean et al., 2014

4.3 연구 시사점 및 한계

개발한 일반화된 SVR-IAM은 다음과 같은 장점을 지닌다. 첫째, SCC의 확률 분포를 신속하고 자동으로 추정할 수 있으며 많은 정보를 바탕으로 강력한 기후 정책 의사결정을 내릴 수 있으며, 확장성이 뛰어나 다양한 규모의 미래 시나리오에 적용할 수 있다. 모델 자동화를 통해 발생가능한 여러 미래 시나리오에서 SCC를 계산하고 이에 소요되는 시간을 단축하여 효율성을 높일 수 있다. 또한, 일반화된 모델은 다양하고 복잡한 IAM 전반에 걸쳐 적응성을 발휘하여 SCC 계산과 관련된 불확실성에 대한 정보를 제공한다는 포괄적으로 이해할 수 있다. 성이 뛰어나 다양한 규모의 미래 시나리오에 적용할 수 있다.

본 연구에서 개발한 일반화된 모델은 다양한 미래 시나리오에서 SCC를 추정함으로써 탄소 배출을 줄이기 위한 비용 효율적인 전략을 식별할 수 있다. 이 정보는 정책 입안자가 현재 기후 정책의 관련성과 효과를 평가하고 다양한 탄소 감축 전략의 잠재적 경제적 영향을 적시에 평가할 수 있게 해주기 때문에 정책 입안자에게 유용하다. 또한, 기업과 투자자는 이 모델을 활용하여 탄소 관련 정책 및 전략의 잠재적 재정영향을 평가함으로써 저탄소 미래를 위한 의사결정에 도움을 받을 수 있다. 또한, 시민사회에는 탄소 배출의 경제적 결과에 대한 명확한 증거를 제공함으로써, 대중의 인식을 높이고 탄소 감축 노력의 시민의 지지 확보 정당성을 강화할 수 있다 탄소 감축 전략에는 탄소 포집 및 저장, 재생 에너지 등 다양한 접근 방식이 포함된다. 이 모델의 활용은 정책 입안자, 기업, 투자자, 시민사회에 혜택을 제공하여 강력한 기후 정책 개발과 지속 가능한 미래로

의 전환에 기여할 수 있다.

본 연구에는 몇 가지 한계가 있다. 첫째, 연구 수행 당시 2020년 이후의 데이터가 부족하여 코로나19의 영향을 조사하지 못하였다. 둘째, 이 연구는 입력 및 출력 변수에 대한 연간 데이터 측면에서 매크로 데이터만 활용하였다. 또한, 수많은 IAM 모델 중 단 3개의 IAM만이 고려되었다는 한계를 지닌다. 본 연구의 완화 시나리오는 온실가스 배출량을 입력 변수로 활용했기 때문에 따라서 재생에너지 확대, 탄소 가격 시장과 같은 다른 감축 전략을 직접적으로 모델링 하기 보다, 온실가스 감축 잠재력 측면에서 모델링 되었다.

이러한 한계를 해결하기 위해 최신 데이터를 비롯해 더 많은 IAM을 분석에 포함하거나, 학습 과정에 추가 입력 변수(feature)를 포함함으로써 모델을 업데이트할 수 있다. 또한, 본 연구의 SCC 추정은 전 세계 규모를 대상으로 했다는 점에 유의해야 한다. 따라서 향후 연구에서는 지역 또는 국가 수준에서 SCC 확률 분포 추정을 위한 모델의 개발을 고려해볼 필요가 있다.

V. 결론

본 연구에서는 기계학습 방법인 SVR을 활용하여 널리 사용되는 세 가지 IAM, 즉 PAGE, FUND, DICE모형을 통합 및 모델의 결과값을 학습자료로 활용해 일반화된 IAM을 개발하였다. SVR 모델은 인구, 1인당 GDP, 온실가스 배출량 등 다양한 사회경제적 요인을 기반으로 SCC를 예측하기 위해 학습을 수행하였다. 또한, IAM이 산출하는 SCC 값에 큰 영향을 미치는 주요 파라미터인 PRTP와 기후민감도의 여러 수준을 고려해 훈련하였다. 학습 결과 낮은 RMSE와 높은 R^2 및 과적합 이슈가 없는 모델을 구축했다. 취득한 훈련된 SVR-IAM 모델을 활용하여 400개의 기준 시나리오와 CCS 기술 확대에 따른 완화 시나리오를 포함한 700개의 시나리오 등 다양한 미래 사회경제적 시나리오 하에서 SCC를 추정하였다. SCC 추정은 신속한 방식으로 수행되어 탄소 배출과 관련된 잠재적 비용에 대한 중요한 통찰력을 제공하였다. 얻어진 SCC 결과는 기존과 CCS 시나리오를 적용한 모두 시나리오 대한 확률 분포 결과를 도출하기 위해 사용하였다. CCS 확대 시나리오를 추가로 포함하면 평균 SCC 값이 약 23.8% 감소하는 것 보였다. 또한, 2100년에 1000 USD₂₀₂₂/tCO₂를 초과하는 높은 SCC 값이 발생할 확률도 감소하여 CCS 기술의 발전이 미래의 재난 재해 위험을 효과적으로 완화할 수 있음을 해석하였다.

CCS의 비용편익 분석을 수행하기 위해 본 연구에서는 CO₂ 회피 비용과 가장 높은 확률의 SCC 값을 비교하였다. CO₂ 회피 비용의 추정치는 48.2~68.7 USD₂₀₂₂/tCO₂인 반면, 최고 확률 SCC 값은 80~210 USD₂₀₂₂/tCO₂이다. 이 분석에 따르면 CO₂ 회피 비용이 예상 SCC 값보다 낮은 것으로 나타나 CCS 기술 도입에 투자하는 것이 비용 대비 효율성이 높다는 것을 알 수 있다. 이 결과는 CCS가 탄소 배출과 관련된 피해를 완화함으로써 사회적 편익에 크게 기여할 수 있음을 시사하였다. 요약하자면, SCC 추정을 위한 일반화된 IAM의 개발은 기후 정책의 의사결정 지원을 강화하는 데 있어 주목할 만한 진전이다.

본 연구는 다양한 IAM을 통합하고 학습시킴으로써 포괄적이고 강력한 SCC 추정 도구를 제공하여 정책 입안자들이 기후 변화 완화 전략과 관련하여 정보에 기반한 의사 결정 수립을 지원한다. 이번 연구 결과는 정책 입안자, 기업, 일반 대중에게 아직 논란이 지속되고 있는 CCS 기술에 대한 시사점을 제공하였다

부록 A.

서포트 벡터 회귀(support vector regression, SVR)는 서포트 벡터머신(support vector machine, SVM)에 기초하여 회귀예측을 수행할 수 있도록 발전된 것이다(그림 2.6; Drucker et al., 1997). SVM은 지도학습 방법 중 하나로 입력값 또는 속성값(feature)과 레이블 또는 출력값이 데이터셋으로 포함된다. 초기 연구에 SVM은 고차원 또는 무한 차원의 공간에서 클래스 간의 최소거리를 최대화하는 초평면(hyperplane)을 찾아내(그림 A.1), 클래스를 분류하는데 주로 이용되었으며, 최적으로 분리하는 초평면의 탐지가 불가능할 경우, 데이터의 차원을 비선형적인 변수변환 함수를 활용해 이를 보다 고차원으로 변환해 새로운 초평면을 찾고 초평면을 판별한다(그림 A.2; Kim and Seo, 2010). 이러한 방식은, 상대적으로 적은 수의 데이터에 대해서도 분류, 회귀 및 예측 성능이 뛰어난 것으로 알려져 있을 뿐만 아니라(Smola and Schölkopf, 2004; Vapnik and Lerner, 1963; Moura et al., 2011; Pedregosa et al., 2011; Wang et al., 2017) 자료의 비선형관계의 규명과 빠른 계산을 가능케하는 장점이 있다. 이러한 방식을 회귀문제로 확장한 것이 SVR이다(Drucker et al., 1997).

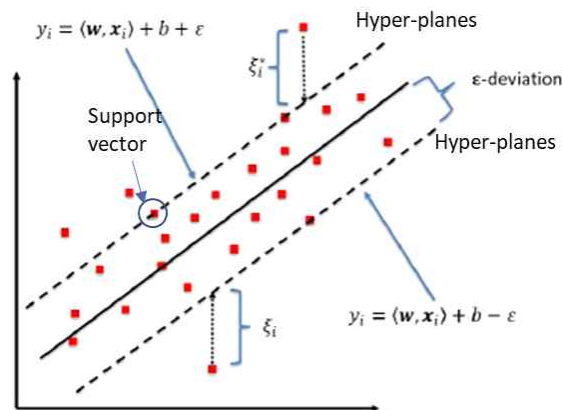


그림 A.1. 서포트 벡터 회귀(support vector regression, SVR) 모델(Kleynhans et al., 2017).




그림 A.2. SVRR의 고차 변환을 통한 고차원 평면 식별(Kim and Seo, 2010).

주어진 학습 데이터셋 $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ 에서 i 가 0에서 n 까지 변할 때의 입력값과 출력값을 x 및 y 라 하면, 이들의 관계는 다음과 같이 정의할 수 있다.

$$y = f(x) = (w, \Phi(x)) + b \dots \dots \dots \quad (Eq A.1)$$

여기서 w 는 가중치 벡터, b 는 상수, $\Phi(x)$ 는 비선형 입력을 고차원공간에서 선형 모델로 변환할 수 있는 커널함수이다. 서포트 벡터는 “가장자리(edge)”에 위치한 여러 데이터 포인트에 의해 “생성”되어 거리가 ϵ (오차허용률, epsilon width)인 초평면을 생성하는데, 이때, SVR은 실제 값과 예측 값의 차이를 최대한 ϵ 이내로 유지하는 것을 목표로 한다.

또한, 이때 예측 성능을 나타내는 오차는 초평면과 실제 값과의 차이로 계산(예, ξ_i^*)된다. 모델의 예측 오차, 즉 손실을 최소화하는 평면을 찾아내기 위해 손실함수를 결합해 SVR의 최적화 문제를 식으로 구성하면 다음과 같다.

$$\text{minimize } C \frac{1}{n} \sum_{i=1}^n L_{\epsilon}(f(x_i), y_i) + \frac{1}{2} \|w\|^2 \dots \dots \dots \quad (Eq A.2)$$

여기 C 는 정규화(regularization) 상수, $\frac{1}{2} \|w\|^2$ 는 회귀 모델의 복잡성과 근사 정확도 사이의 균형(trade-off)을 제어하는 정규화된 용어(regularization term)이다. 이때, C 값이 큰 값으로 설정되면 편차에서 벗어난 값에 대한 패널티를 높게 산정한다. 즉, 편차 ϵ 에서 벗어나는 y 를 최대한 줄이는 것을 의미하며 SVR 학습에 과대적합(overfitting) 될 것이다(Lee and Kim, 2016). 반면, C 값을 작게 설정하면 편차 ϵ 를 벗어나는 y_i 가 허용되므로 SVR 모델이 과소적합(underfitting) 될 것이다. 그러므로 좋은 성능을 가진 일반화된 SVR 모델에 적합하도록 허용가능한 C 값을 선택하는 것이 중요하다.

커널함수의 예로는 선형, 다항식 회귀, 시그모이드(sigmoid), 방사형 기저함수(radial basis function) 등이 있다. 방사형 기저함수는 널리 사용되는 커널함수로

$$K(x_1, x_2) = \exp\left(-\frac{\|x_1 - x_2\|^2}{2\sigma^2}\right) \dots \dots \dots \quad (Eq A.3)$$

$$\text{혹은, } K(x_1, x_2) = e^{-\gamma \|x_1 - x_2\|^2} \dots \dots \dots \quad (Eq A.4)$$

로 정의된다. 식(A.4)에서 γ 는 분산과 관련된 감마 매개변수이다.

SVR의 하이퍼파라미터(hyperparameter)는 커널, w , ϵ 및 γ 이다. 하이퍼파라미터는 사용자가 정의하며 최고의 모델 성능을 위해 다양한 값을 넣어 시도하는 튜닝과정이 필요하다. SVR 모델은 Sklearn 라이브러리(Pedregosa et al., 2011)를 이용하였으며 하이퍼파라미터 튜닝은 파라미터의 배열목록을 조합한 후 반복 수행되었다. 반복된 튜닝을 통해 실제값과 예측값의 평균 제곱근 오차(root mean squared error, RMSE)가 작고 결정계수(coefficient of determination, R2)가 1 값에 가장 가까운 경우를 모델 해로 선택하였다.

참고문헌

- Anthoff, D., Tol, R.S.J., Yohe, G.W. (2009). Risk aversion, time preference, and the social cost of carbon. *Environmental Research Letters*, 4(2). doi:10.1088/1748-9326/4/2/024002.
- Anthoff, D., & Tol, R. S. J. (2014). *The Climate Framework For Uncertainty, Negotiation And Distribution (FUND), Technical Description, Version 3.9.*
<https://www3.nd.edu/~nmark/Climate/Fund-3-9-Scientific-Documentation.pdf>
- Caesary, D., Song, S. Y., Yu, H., Kim, B., & Nam, M. J. (2020). A review on CO₂ leakage detection in shallow subsurface using geophysical surveys. *International Journal of Greenhouse Gas Control*, 102, 103165. doi:10.1016/j.ijggc.2020.103165
- Caesary, D., Kim, H., & Nam, M. J. (2023). An alternative approach to capture uncertainties embedded in the estimation of social cost of carbon. *Wiley Interdisciplinary Reviews: Energy and Environment*, e475. DOI: 10.1002/wene.475
- Calel, R., Stainforth, D.A. (2017). On the physics of three integrated assessment models. *Bulletin of the American Meteorological Society*, 98(6), 1199-1216. doi:10.1175/BAMS-D-16-0034.1
- Cebucean, D., Cebucean, V., & Ionel, I. (2014). CO₂ capture and storage from fossil fuel power plants. *Energy Procedia*, 63, 18-26. <https://doi.org/10.1016/j.egypro.2014.11.003>
- De, A. (2020). *Essays on Nonlinear Environmental Dynamics and the Social Cost of Carbon.* University of Minnesota.
- Downing, T. E., Anthoff, D., Butterfield, R., Ceronsky, M., Grubb, M., Guo, J., ... Watkiss, P. (2005). *Social Cost of Carbon: A Closer Look at Uncertainty.*
- Drucker, H., Surges, C.J.C., Kaufman, L., Smola, A., Vapnik, V. (1996). Support vector regression machines. *Advances in Neural Information Processing Systems*, 155-161.
- Energy Modeling Forum (1995). *Second Round Study Design for EMF 14: Integrated Assessment of Climate Change.*
- Heyes, A., & Urban, B. (2019). The economic evaluation of the benefits and costs of carbon capture and storage. *International Journal of Risk Assessment and Management*, 22(3-4), 324-341. <http://dx.doi.org/10.1504/IJRAM.2019.103337>
- Hondo, H. (2005). Life cycle GHG emission analysis of power generation systems: Japanese case. *Energy*, 30(11-12), 2042-2056. <https://doi.org/10.1016/j.energy.2004.07.020>
- Hope, C. (2006). The Marginal Impact of CO₂ From PAGE 2002: An Integrated Assessment Model Incorporating the IPCC's Five Reasons for Concern. *The Integrated Assessment Journal*, 6(1), 16-56.
- Hu, L., Wang, C., Ye, Z., Wang, S. (2021). Estimating gaseous pollutants from bus emissions: A hybrid model based on GRU and XGBoost. *Science of the Total Environment*, 783. <https://doi.org/10.1016/j.scitotenv.2021.146870>
- IPCC, (2018). *Global Warming of 1.5° C. An IPCC Special Report on the impacts of global warming of 1.5° C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty [Masson-Delmotte, V., P. Zhai, H.-O. Pörtner, D. Roberts, J. Skea, P.R. Shukla, A. Pirani, W. Moufouma-Okia, C. Péan,*

- R. Pidcock, S. Connors, J.B.R. Matthews, Y. Chen, X. Zhou, M.I. Gomis, E. Lonnoy, T. Maycock, M. Tignor, and T. Waterfield (eds.]. Cambridge University Press, Cambridge, UK and New York, NY, USA, 616 pp., doi:10.1017/9781009157940.
- IPCC. (2022). Climate Change 2022 : Mitigation of climate change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [P.R. Shukla, K. Skea, R. Slade, A. Al Khourdajie, R. van Diemen, D. McCollum, M. Pathak, S. Some, P. Vyas, R. Fradera, M. Belkacemi, A. Hasija, G. Lisboa, S. Luz, J. Malley, (eds.)]. Cambridge University Press, Cambridge, UK and New York, NY, USA. doi: 10.1017/9781009157926.
- Jena, P.R., Managi, S., Majhi, B. (2021). Forecasting the CO2 emissions at the global level: A multi layer artificial neural network modelling. *Energies*, 14(19), 1-23. <https://doi.org/10.3390/en14196336>.
- Kikstra, J.S., Waidelich, P., Rising, J., Yumashev, D., Hope, C., Brierley, C.M. (2021). The social cost of carbon dioxide under climate-economy feedbacks and temperature variability. *Environmental Research Letters*, 16(9). <https://doi.org/10.1088/1748-9326/ac1d0b>.
- Kim, S. J., & Seo, I. Y. (2010). Modeling and Comparison for Auto-association using Support Vector Regression (SVR) and Partial Least Square Regression (PLSR) in Online Monitoring Techniques. *Journal of the Korean Institute of Intelligent Systems*, 20(4), 483-488.
- Kleynhans, T., Montanaro, M., Gerace, A., & Kanan, C. (2017). Predicting top-of-atmosphere thermal radiance using merra-2 atmospheric data with deep learning. *Remote Sensing*, 9(11), 1133. <https://doi.org/10.3390/rs9111133>.
- Koh, M., Shin, E., & Seo, W. (2018). Outline of Korean Integrated CCS Act Draft and Its Implication. *Energy Procedia*, 154, 15-21. doi:10.1016/j.egypro.2018.11.004.
- Krichene, H. (2019). PyDICE2016 : A Python solution for DICE 2016 model 1-8.
- Lee K. and Kim, W. J. (2016). Forecasting of 24_hours Ahead Photovoltaic Power Output Using Support Vector Regression, Thesis.
- Li, J., Mullan, M., Helgeson, J. (2014). Improving the practice of economic analysis of climate change adaptation. *Journal of Benefit-Cost Analysis*, 5(03), 445-467. <https://doi.org/10.1515/jbca-2014-9004>.
- Martin-Roberts, E., Scott, V., Flude, S., Johnson, G., Haszeldine, R.S., Gilfillan, S. (2021). Carbon capture and storage at the end of a lost decade. *One Earth*, 4(11), 1569-1584. <https://doi.org/10.1016/j.oneear.2021.10.002>.
- Martinkova, M., Hanel, M. (2016). Evaluation of Relations between Extreme Precipitation and Temperature in Observational Time Series from the Czech Republic. *Advances in Meteorology*, 2016. <https://doi.org/10.1155/2016/2975380>.
- Menoy, M.E. (2020). The social cost of carbon under uncertainty over climate sensitivity and damages. University of Oslo. <https://doi.org/10.1007/s10640-019-00389-w>.
- Metcalf, G. E., & Stock, J. H. (2017). Integrated assessment models and the social cost of carbon: A review and assessment of U.S. experience. *Review of Environmental Economics and Policy*, 11(1), 80-99. doi:10.1093/reep/rew014.

- Moura, M.D.C., Zio, E., Lins, I.D., Droguett, E. (2011). Failure and reliability prediction by support vector machines regression of time series data. *Reliability Engineering and System Safety*, 96(11), 1527–1534. <https://doi.org/10.1016/j.ress.2011.06.006>.
- Nordhaus, W.D., Sztorc, P. (2013). *DICE 2013R: Introduction and User's Manual*. Yale University Press, (1), 1–102.
- NREL (National Renewable Energy Laboratory). 2022. 2022 Annual Technology Baseline. Golden, CO: National Renewable Energy Laboratory.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Duborg, V., Vanderplas, J., Passos, A., Cournapeua, D., Brucher, M., Perrot, M., Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Remeur, C. (2020). Carbon emissions pricing. Some points of reference. Briefing document. European Parliamentary Research Service, (March).
- Riahi, K., Van Vuuren, D. P., Kriegler, E., Edmonds, J., O'neill, B. C., Fujimori, S., ... & Tavoni, M. (2017). The Shared Socioeconomic Pathways and their energy, land use, and greenhouse gas emissions implications: An overview. *Global environmental change*, 42, 153–168. <http://dx.doi.org/10.1016/j.gloenvcha.2016.05.009>
- Ricke, K., Drouet, L., Caldeira, K., Tavoni, M. (2018). Country-level social cost of carbon. *Nature Climate Change*, 8(10), 895–900. <https://doi.org/10.1038/s41558-018-0282-y>.
- Roussanaly, S. (2019). Calculating CO2 avoidance costs of carbon capture and storage from industry. *Carbon Management*, 10(1), 105–112. doi:10.1080/17583004.2018.1553435
- Rubin, E. S., Davison, J. E., & Herzog, H. J. (2015). The cost of CO2 capture and storage. *International Journal of Greenhouse gas control*, 40, 378–400.
- Saleh, C., Dzakiyullah, N.R., Nugroho, J.B. (2016). Carbon dioxide emission prediction using support vector machine. *IOP Conference Series: Materials Science and Engineering*, 114(1). <https://doi.org/10.1088/1757-899X/114/1/012148>.
- Smola, A.J., Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222. <https://doi.org/10.1023/B:STCO.0000035301.49549.88>.
- Tian, L., Ye, Q., Zhen, Z. (2019). A new assessment model of social cost of carbon and its situation analysis in China. *Journal of Cleaner Production*, 211, 1434–1443. doi:10.1016/j.jclepro.2018.11.117.
- Ummenhofer, C. C., & Meehl, G. A. (2017). Extreme weather and climate events with ecological relevance: A review. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 372(1723). doi:10.1098/rstb.2016.0135.
- U.S. Energy Information Administration. (2016). Capital cost estimates for utility scale electricity generating plants. US Department of Energy, Energy Information Administration. http://www.eia.gov/analysis/studies/powerplants/capitalcost/pdf/capcost_assumption.pdf.
- US Department of Energy. (2015). Levelized Cost of Energy (LCOE) [Slide show]. Department of Energy. <https://www.energy.gov/sites/prod/files/2015/08/f25/LCOE.pdf>
- Vapnik, V., Lerner, A. (1963). Pattern recognition using generalized portrait method. *Automation and Remote Control*, 24, 774–780.

- Wang, H., Xiong, J., Yao, Z., Lin, M., Ren, J. (2017). Research survey on support vector machine. *International Conference on Mobile Multimedia Communications (MobiMedia)*, 2017-July, 95-103. <https://doi.org/10.475/eai.13-7-2017.2270596>.
- Wang, P., Deng, X., Zhou, H., Yu, S. (2019). Estimates of the social cost of carbon: A review based on meta-analysis. *Journal of Cleaner Production*, 209, 1494-1507. doi:10.1016/j.jclepro.2018.11.058.
- Watkiss, P., Downing, T.E. (2008). The social cost of carbon: Valuation estimates and their use in UK policy. *The Integrated Assessment Journal Bridging Sciences & Policy*, 8, 20.
- Weitzman, M.L. (2012). GHG Targets as Insurance against Catastrophic Climate Damages. *Journal of Public Economic Theory*, 14(2), 221-244. doi:10.1111/j.1467-9779.2011.01539.x.
- Weyant, J. (2017). Some contributions of integrated assessment models of global climate change. *Review of Environmental Economics and Policy*, 11(1), 115-137. <https://doi.org/10.1093/reep/rew018>.
- Yahşi, M., Çanakoğlu, E., Ağralı, S. (2019). Carbon price forecasting models based on big data analytics. *Carbon Management*, 10(2), 175-187. <https://doi.org/10.1080/17583004.2019.1568138>.
- Yumashev, D. (2020). PAGE - ICE Integrated Assessment Models (June).
- Zahasky, C., Krevor, S. (2020). Global geologic carbon storage requirements of climate change mitigation scenarios. *Energy and Environmental Science*, 13(6), 1561-1567. <https://doi.org/10.1039/d0ee00674b>.
- Zhu, B., Wei, Y. (2013). Carbon price forecasting with a novel hybrid ARIMA and least squares support vector machines methodology. *Omega*, 41(3), 517-524. <https://doi.org/10.1016/j.omega.2012.06.005>.

본 연구보고서의 내용은 연구자의 의견이며,
(재)숲과나눔의 공식적인 견해와는 다를 수 있습니다.