



Deep learning based Feature Selection Study

Sanghyuck Lee

2022. 01. 25.

To DO List

➤ Last Week

- Related Works Study and Implementation
- 갑상선 연구 보고 : 지속적 성능 향상 추진 (특징 하위 집합 탐색("세그먼트 단위"))
- 산학협력프로젝트 : 진행 보고

➤ This Week

- Related Works Study and Implementation
- 갑상선 연구 보고 : SFS를 통한 Best 슬라이스 Subset 탐색
- 산학협력프로젝트 : 진행 보고

Papers

- Chen, Jianbo, et al. "Learning to explain: An information-theoretic perspective on model interpretation." *International Conference on Machine Learning*. PMLR, 2018.
- Yoon, Jinsung, James Jordon, and Mihaela van der Schaar. "INVASE: Instance-wise variable selection using neural networks." *International Conference on Learning Representations*. 2018.
- Schwab, Patrick, and Walter Karlen. "Cexplain: Causal explanations for model interpretation under uncertainty." *arXiv preprint arXiv:1910.12336* (2019).
- Jethani, Neil, et al. "Have We Learned to Explain?: How Interpretability Methods Can Learn to Encode Predictions in their Interpretations." *International Conference on Artificial Intelligence and Statistics*. PMLR, 2021.
- Panda, Pranoy, Sai Srinivas Kancheti, and Vineeth N. Balasubramanian. "Instance-wise Causal Feature Selection for Model Interpretation." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021.

Implementation Progress

- INVASE (Completed):
 - Issues: Search proper “Lamda” for Various Datasets
 - Results:

Iteration	Predictor		Baseline		#Features (Total: 64)
	AUC	ACC	AUC	ACC	
1	0.918	0.738	0.917	0.765	64
2	0.919	0.752	0.907	0.734	64
3	0.652	0.192	0.915	0.758	21
4	0.92	0.745	0.914	0.724	64
5	0.922	0.725	0.912	0.77	64

CIFAR-10
(Lamda: 0.05)

Iteration	Predictor		Baseline		#Features (Total: 196)
	AUC	ACC	AUC	ACC	
1	0.943	0.866	0.986	0.899	196
2	0.916	0.814	0.978	0.916	160
3	0.932	0.827	0.969	0.899	167
4	0.929	0.842	0.911	0.815	196
5	0.874	0.599	0.978	0.91	196

Dogs vs Cats
(Lamda: 0.01)

Implementation Progress

- SCM (Completed):
 - Issues: Trade off between Performance and Interpretability
 - Results:

Iteration	Predictor		Baseline		#Features (Total: 64)
	AUC	ACC	AUC	ACC	
1	0.816	0.403	0.95	0.706	30
2	0.749	0.303	0.954	0.72	30
3	0.749	0.3	0.95	0.715	30
4	0.782	0.341	0.951	0.712	30
5	0.8	0.386	0.942	0.695	30


CIFAR-10
(#Features: 30 / 64)

Implementation Progress

- Real-X (Completed):
 - Issues: Validation with SOTA models
 - Results:

Iteration	Predictor		Baseline		#Features (Total: 256)
	AUC	ACC	AUC	ACC	
1	0.940	0.646	0.926	0.619	129.14
2	0.930	0.641	0.936	0.654	137.30
3	0.941	0.645	0.933	0.635	146.32

CIFAR-10
(Lamda: 0.5)



Further Research

- L2X, CXPlain Implements
- Summarizes Advantages and Limitations (모델 압축 관점에서)

방법론	장점	한계점
INVASE	- Prediction 모델을 함께 학습함으로써, 상황이 주어지면 Prediction 성능을 끌어올릴 수도 있음 (이론적으로는 Prediction 성능 유지가 쉬울 수 있음).	- 데이터셋별로 Lamda 값 서치가 필요함에 따라, 효과적인 서치 방식을 찾지 않으면, 성과를 얻어내는데 시간이 오래 걸릴 수 있음. - Tabular 데이터에 대한 방법론만 참고 가능하므로, 진행에 어려움이 있음.
SCM	- 선택 특징 수를 사전에 정의할 수 있음에 따라, 최고 실험 성능을 서치하기가 쉬움(직관적임). - 이미지 데이터셋이 중점인 연구이므로, 추가 연구가 쉬움.	- Prediction 모델과 함께 학습하지 않으므로, Selector-Predictor 성능 유지가 어려울 수 있음. - 해당 성능의 데이터셋 의존성이 클 수 있음.
Real-X	- 이미지 데이터셋이 중점인 연구이므로, 추가 연구가 쉬움. - INVASE 보다 Lamda 값 서치가 쉬울 것으로 생각됨.	- Lamda 값 서치 필요함.

갑상선 연구

- Activity 논문 테이블 :

1) 실험에 포함되는 데이터셋 요약 테이블(이정규 교수님측)

2) CT가 Activity와 얼마나 연관이 있는지 확인하는 실험 : SFS 알고리즘에 의해 11개 슬라이스 중 Best 슬라이스 집합을 찾아내는 실험 테이블

- 비교 실험 방법 : 사람이 뽑아낸 Best 슬라이스 집합과 비교(AX1~6, CO1~3, SA를 모두 사용한 케이스 혹은 이번 보고 때 뽑은 AX2~4, 6, CO2, SA를 사용한 케이스)

3) CT와 2개 메타 데이터 조합이 Activity와 얼마나 연관이 있는지 확인하는 실험 : 나이, 성별을 포함하여 실험 테이블 뽑아냄

- 비교 실험 방법 : 실험 2)의 결과인 Best 슬라이스에 대해서 (나이), (성별), (나이, 성별)을 각각 포함해서 실험 진행, 사람이 뽑아낸 Best 슬라이스에도 동일하게 적용하여 비교

갑상선 연구

- 5회 SFS를 통한, 5개 Data-Split에 대한 5개 Subset 확인
- 실험 방식 :
 - 11개 슬라이스에 대해 SFS 수행 (1회 SFS당 9~12시간 정도 걸림)
 - 특징을 선택할 때마다, 선택된 특징과 남은 후보 특징 간의 조합을 고려하여, 특징 스코어 매번 재평가 (Multi-variate Feature Selection)
 - 최종적으로 AUROC값이 가장 높은 특징 Subset 추출
 - 10개의 Subset을 뽑아 다시 각각 10회 반복 실험 예정 (현재 5개 Subset 뽑기 완료)
 - 현재 완료된 SFS 알고리즘의 Subset :

	AX1	AX2	AX3	AX4	AX5	AX6	CO1	CO2	CO3	LT	RT
Subset 1			○					○	○		
Subset 2	○		○		○					○	○
Subset 3	○	○					○	○			○
Subset 4	○	○	○	○				○			
Subset 5	○	○	○	○	○	○				○	○

갑상선 연구

- 만약 30개 슬라이스 Subset을 뽑고, 각각 30회 반복 실험을 진행하면
- 남은 25회 SFS 시간 = 12(시간) × 3회 = 36 (시간)
- 25(분)(Worst Case) × 30(개 Subset) × 30(회) = 375 (시간)
- 9 (동시 사용 가능 실험 장비 수) = 18 (보유 3090 GPU) ÷ 2 (1회 실험시 사용하는 GPU)
- 375 (시간) ÷ 9 (동시 사용 가능 실험 장비 개수) = 41.67 (시간)
- 36+41.67= **77.67 (시간)**



산학프로젝트

- **SW 등록 3건(1~2월)**

- 기계 데이터를 위한 멀티모달 학습 연구 : 아성이 SW 제작, 태원이 등록 실무
- 보안 텍스트 데이터 분석을 위한 딥러닝 기법 연구 : 건일이 SW 제작, 수정이 등록 실무
- 임베디드 AI 기반 Scene Text Recognition 연구 : 건일이 SW 제작, 수정이 등록 실무

- **국제 학술대회 논문 2편 + 국내 특허출원 2건(6~8월)**

- 취향에 맞는 음악 추천을 위한 음악 장르 분류 프로젝트 : 아성+성현 KCI 논문 후속작(논문 1편 + 특허 1건)
- 의료 영상 분석을 위한 XAI 연구 : 상혁 졸업 논문 후속작(논문 1편 + 특허 1건)