

Transfer Learning via Learning to Transfer(2018)

Ying Wei, Yu Zhang, Junzhou Huang, Qiang Yang, Proceedings of the 35 th International Conference on Machine Learning,. 2018.

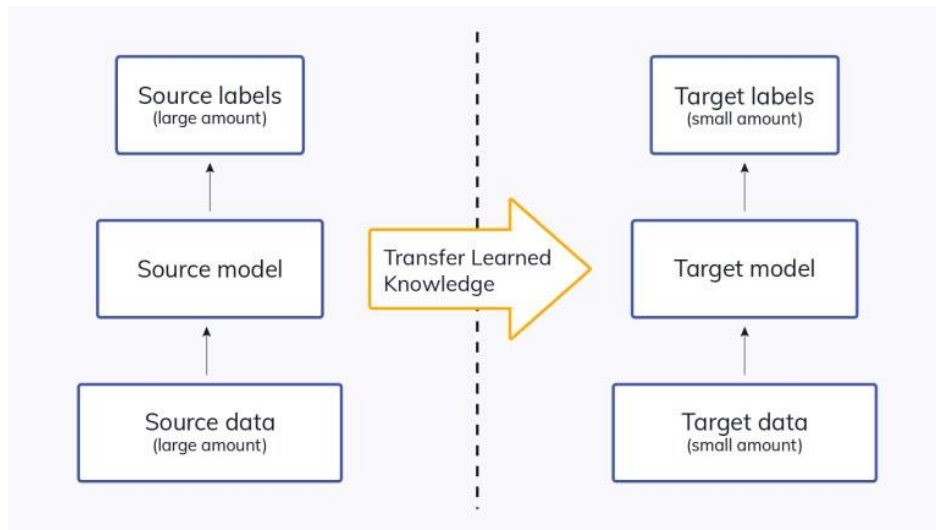
II E8557-01 동적계획법과 강화학습
시스템 인텔리전스 연구실 김민식

Table of Contents

- Background
- Introduction
- Proposed
- Experiment
- Conclusion

Transfer learning

- 한 분야의 문제(Source task)를 해결하기 위해서 얻은 지식과 정보를 다른 문제(Target task)를 푸는데 사용하는 학습 방식
 - 사전 훈련(Pre-trained)된 모델을 새로운 작업에 대한 모델의 시작점으로 재사용하는 기계 학습 방식
 - 효율적, 적은 데이터 세트를 사용해 높은 성능을 낼 수 있음




Transfer learning

Traditional ML

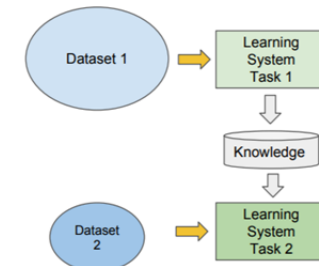
vs

Transfer Learning

- Isolated, single task learning:
 - Knowledge is not retained or accumulated. Learning is performed w.o. considering past learned knowledge in other tasks



- Learning of a new tasks relies on the previous learned tasks:
 - Learning process can be faster, more accurate and/or need less training data



Tradition Machine learning vs Transfer learning

Transfer learning

- 본 논문에서 전이 학습(Transfer learning) 과정 자체를 학습하는 방향(learning to transfer)에 대해서면 관련 연구는 아래와 같음

분야	설명	Training	Testing	
Transfer Learning	<ul style="list-style-type: none"> 하나의 Task를 해결하기 위해 얻은 지식을 다른 Task를 푸는데 사용 레이블 샘플의 수가 적은 작업에서 유용함 	Task 1	Task 2	
Multi-task Learning	<ul style="list-style-type: none"> 하나의 모델이 여러가지 서로 다른 Task을 모두 수행하는 학습 방법 모든 Task에 대한 지식을 공유해, 일반화 성능을 향상을 지향 Training과 Testing의 샘플이 분포가 같아야 한다라는 가정 	Task 1 ... Task N	Task 1 ... Task N	
Lifelog Learning	<ul style="list-style-type: none"> 학습하는 방법을 학습하는 것(Learning to learn)으로 Meta learning 불림 Task-sharing knowledge 관점으로 과거 Task 간에 학습된 지식을 공유해 <u>새로운 Task 적용</u> 	Task 1 ... Task N	Task N+1	
Learning to Transfer	<ul style="list-style-type: none"> 이전의 전이 학습의 경험을 기반으로, 현재 Source와 Target task 간 전이 학습할 내용과 방법을 최적화하는 학습 방법 (Lifelog learning과 달리) <u>전이 학습 기술을 학습하는 것</u> 	Task 1 ▼ Task 2	Task 2N-1 ▼ Task 2N	Task 2N+1 ▼ Task 2N+2

Transfer learning

- Transfer learning 주요 연구 이슈
 - 전이 학습의 세 가지 주요 연구 이슈는 아래와 같음
 - [1] when to transfer: Source task -> Target task 으로 전이 학습이 이점을 가져다 줄 때
 - [2] how to transfer : 알고리즘(Algorithm, Model)
 - [3] what to transfer : 서로 다른 Task 사이의 전이 가능한 지식(Transferable knowledge)
 - 알고리즘이 다를 경우, **서로 다른 전이 가능한 지식을 발견**할 것이며, **불균형한 전이 학습 성능**이 나옴
 - 완전 탐색(Brute-force exploration) 방법은 계산 비용이 많이 들고, 실현 불가능
 - 휴리스틱한 탐색(Heuristically selective exploration) 방법은 전문 지식이 필요하며, 최적의 해결책(sub-optimal improvement) 이 아
님

Learning to Transfer

- Learning to Transfer
 - 인간은 다양한 **전이 학습 경험**(Transfer learning experience)을 통해 **전이 학습 능력**(Transfer ability: what to transfer, how to transfer)을 갖추춤
 - 예를 들어 어린아이가 체스에서 배운 수학 능력, 의사결정 기술을 각각 산술 문제, 농구 경기에 활용(전이)할 수 있음
 - 이런 전이 학습 경험을 시간이 지나서 시장 투자 문제에도 쉽게 적용할 수 있음
 - Learning to Transfer(L2T)의 프레임워크를 제안
 - 이전 전이 학습 경험을 통해 , 새롭게 들어온 Source와 Target task 간의 **전이할 내용과 방법을 최적화하여 전이 학습 효과를 향상**
 - 1단계: Reflection function를 학습하여, **Domain 쌍**과 그들 사이로 **전이된 지식을 성능 향상 비율로 Mapping**
 - 2단계: 새로운 Domain 쌍을 받으면, **학습된 Reflection function의 값을 최대화하는 방향으로 전이 학습 방향 최적화**

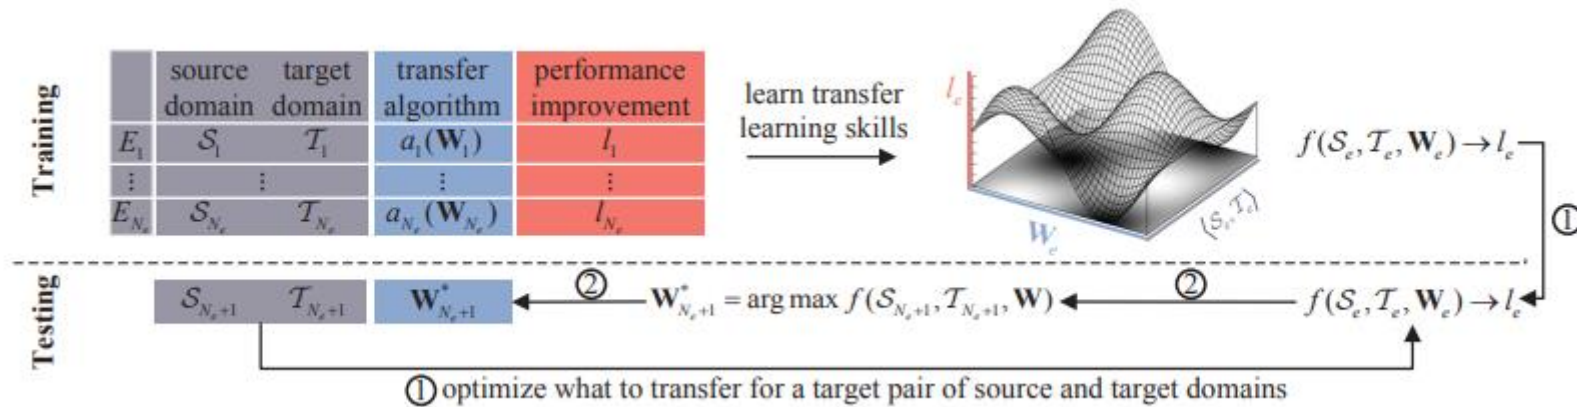
본 논문의 Key Idea

- **Key Idea(Contribution)**
 - **전이 학습 경험을 통해, 전이할 내용과 방법을 모델링하는 전이 학습 프레임워크를 제안**
 - 전이 학습 경험: Source-Target task의 쌍, Latent feature의 파라미터로 표현된 전이 가능한 지식
 - L2T 방법을 통해 전문 지식이 필요하지 않고, **체계적·자동적인 방식**으로 더 많은 전이 가능한 지식을 발견할 수 있음
 - 포괄적인 실험을 통해 최근 전이 학습 알고리즘에 대비 효과적인 성능을 확인
 - Target task에서 라벨이 된 샘플이 적을 경우 효과적임

L2T Framework

- 본 실험에서는 환경 Setting은 다음과 같음: $\chi_e^s = \chi_e^t / y_e^s \neq y_e^t$
- [Training stage] N_e 번의 전이 학습 경험($\{E_{N_1} \dots E_{N_e}\}$)을 통해서 L2T을 전이 학습의 Reflection function을 성능 향상 비율에 근사하도록 학습
 - Reflection function: 전이 학습 능력(what to & how to transfer)을 암호화(**Domain 쌍과 그들 사이로 전이된 지식을 성능 향상 비율 Mapping**)
 - Performance improvement ratio($l_e = p_e^{st} / p_e^t$): 전이 학습 적용 전 학습 성능(p_e^{st}) 대비 학습 알고리즘(W_e)을 적용할 때의 성능(p_e^t) 비율
- [Test stage] 새!

이 지식을 최적화함



Detail meaning: Parameterizing what to Transfer

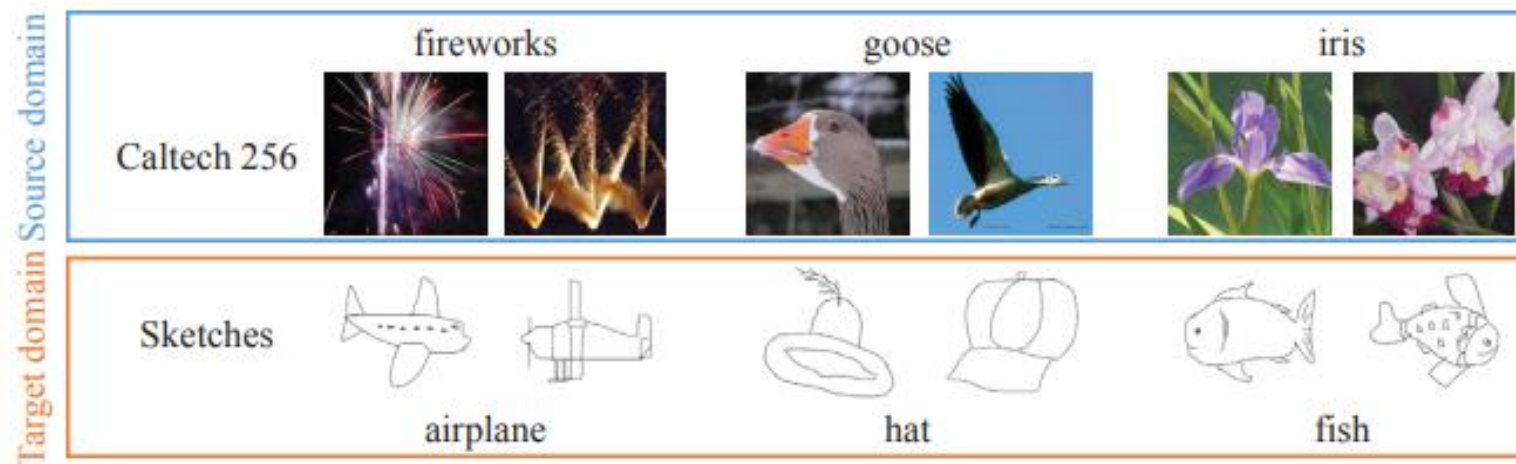
- (Latent feature factor) algorithm은 **Domain 간의 동일한 특징 요소(feature factors) 학습**
 - 예를 들어, 개 사진(Source)과 고양이 사진(Target) 간의 독립적으로 전달할 특징 요소는 “눈, 코, 꼬리“
- Domain 간 공유할 특징 요소(Domain-invariant feature factor)를 결정하는 것이 알고리즘
 - 무엇을 전이할지(What to transfer)를 **Latent feature factor matrix(W)로 파라미터화**로 표현

Detail meaning: Learning from experiences

- Reflection function을 학습 목표는 **성능 개선 비율(Performance improvement ratio, ι_e) 근사화** 하는 것, 아래 2가지 측면을 고려해서 학습해야 함
- [1] The Difference between a Source and a Target Domain
 - RKHS(Reproduction kernel Hilbert space)에 두 Domain을 Mapping 후 **MMD(Maximum mean discrepancy) 거리**를 구함: \hat{d}_e
 - MMD 만으로 Domain 간의 차이를 측정하는 데 부족하여, 모든 instance pair 사이의 **distance variance**을 구함: $\sigma_e^2 = \text{tr}(Q_e - \beta Q_e \beta^T)$ covariance matrix
- [2] The Discriminative Ability of a Target Domain
 - 판별 능력(Discriminative Ability)은 Latent space에서 **1) 유사한 sample 사이는 가까이 있어야 하고 2) 유사하지 않을 경우는 멀리 있어야 함**
 - 수식: $\tau_e = \frac{\text{tr}(W_e^T S_e^N W_e)}{\text{tr}(W_e^T S_e^L W_e)}$
 - S_e^L : local scatter covariance matrix with the neighbor information / τ_e 를 최대화하기 위해서 S_e^L 최소: 이웃 샘플끼리 거리가 가까워야 함
 - S_e^N : non-local scatter covariance matrix / τ_e 를 최대화하기 위해서 S_e^L 최대: 아닐 때는 거리가 멀어야 함

Experiment

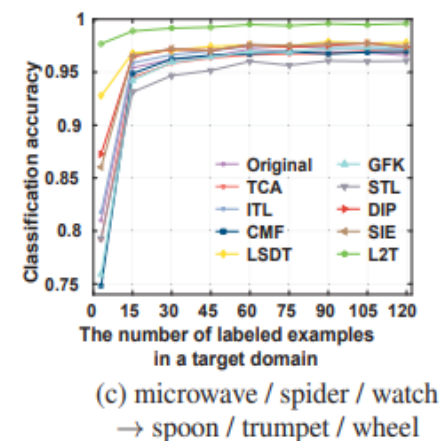
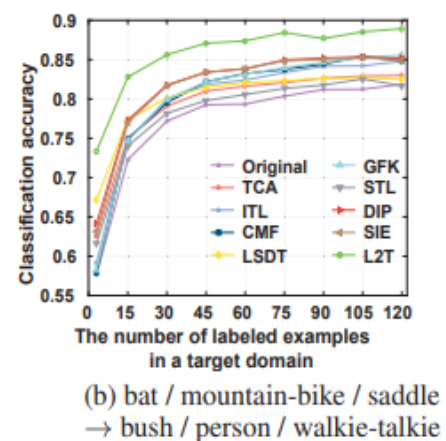
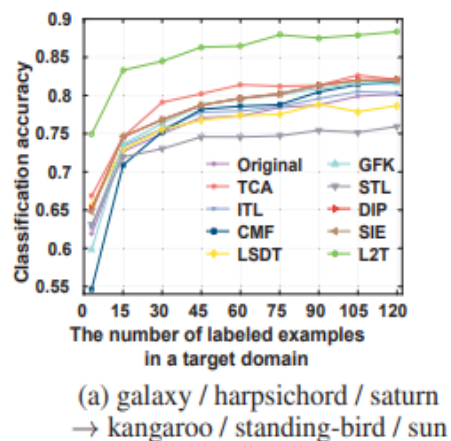
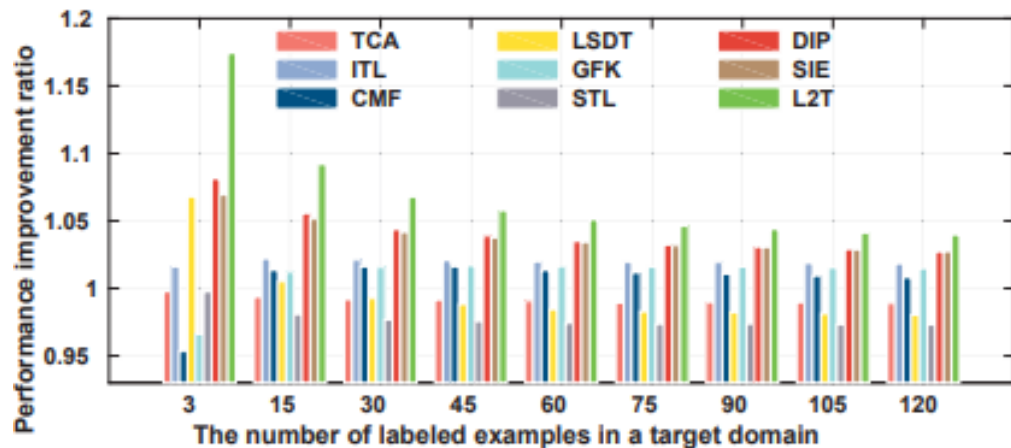
- Source domain 데이터는 Caltech-256, Target domain 데이터는 Sketches 활용하였고, Source-domain 쌍을 구성하기 위해 무작위 샘플링 진행
- 본 실험에서는 **전이 학습 데이터셋을 자체 제작**
 - 본 논문은 전이 학습 경험을 고려한 최초의 실험으로 사용 가능한 사전 제작된 데이터셋이 없음
- 실제 환경을 모방하기 위해, **전이 학습 알고리즘과 레이블이 달린 샘플의 수를 무작위로 설정**
 - Target task의 레이블 달린 샘플의 수, 전이 학습 알고리즘의 종류는 실제 환경에서는 매우 유동적으로 달라짐



<Dataset example>

Experiment (1): Performance Comparison

- 다양한 환경(Target domain의 레이블이 달린 샘플의 수) 제안된 L2T Framework의 성능이 **Baseline 대비해서 성능이 최소 10% 향상**
 - **레이블 달린 샘플의 수가 많아질수록**, 전이 학습하지 않는 모델의 정확도가 높아지는 경향이 있어 **성능 개선 비율이 감소**
- (Test 쌍 중 무작위로 선택한) **Source-domain 쌍마다의 알고리즘 분류 정확도** 역시 L2T Framework이 일관되게 **Baseline 성능을 능가**
 - 레이블이 달린 샘플의 수가 적고 두 domain 간의 유사성이 클 경우, 전이 가능한 지식을 더 많이 찾아내 개선을 크게 기여함




<Performance Comparison / left: Average performance improvement, right: classification accuracy>

Experiment (2): Varying the Experiences

- 전이 학습 경험(Algorithm, 학습 수)이 학습에 미치는 영향력을 확인하기 위한 실험
- 전이 학습 경험의 수를 고정(1,000) 후 **알고리즘**에 따른 성능을 보면, L2T에서 **reflection function** 학습하는 것이 **유의미한 성능 개선**을 보임
 - 더 많은 알고리즘을 포함할 경우 전이 학습 경험은 Source-target의 다양한 상황과 지식을 다룸으로 성능 향상 정도가 개선됨
- 기본 알고리즘 집합을 고정 후, 훈련에 사용되는 **전이 학습 경험 수를 늘릴 때 성능 향상이 증가하는 경향**


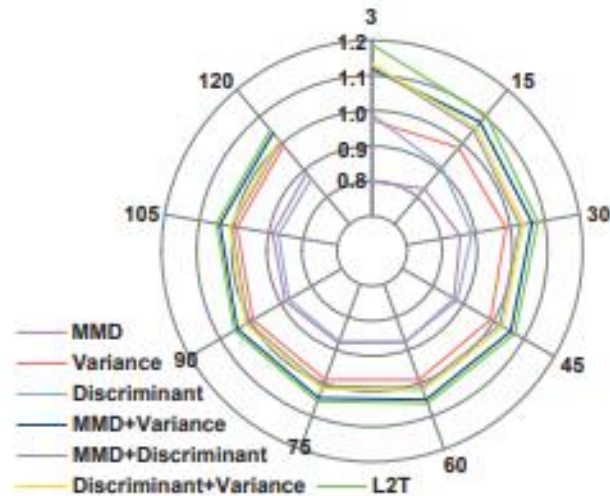
# of labeled examples	3	15	30	45	60	75	90	105	120
TCA	1.0181	1.0024	0.9965	0.9973	0.9941	0.9933	0.9938	0.9927	0.9928
ITL	1.0188	1.0248	1.0250	1.0254	1.0250	1.0224	1.0232	1.0224	1.0224
CMF	0.9607	1.0203	1.0224	1.0218	1.0190	1.0158	1.0144	1.0142	1.0125
LSDT	1.0828	1.0168	0.9988	0.9940	0.9895	0.9867	0.9854	0.9834	0.9837
GFK	0.9729	1.0180	1.0232	1.0243	1.0246	1.0219	1.0239	1.0229	1.0225
STL	0.9973	0.9771	0.9715	0.9713	0.9715	0.9694	0.9705	0.9693	0.9693
DIP	1.0875	1.0633	1.0518	1.0465	1.0425	1.0372	1.0365	1.0343	1.0317
SIE	1.0745	1.0579	1.0485	1.0448	1.0412	1.0359	1.0359	1.0334	1.0318
ITL + L2T	1.1210	1.0737	1.0577	1.0506	1.0456	1.0398	1.0394	1.0361	1.0359
DIP + L2T	1.1605	1.0927	1.0718	1.0620	1.0562	1.0500	1.0483	1.0461	1.0451
(LSDT/GFK /SIE) + L2T	1.1660	1.0973	1.0746	1.0652	1.0573	1.0506	1.0485	1.0451	1.0429
(TCA/ITL/CMF/GFK /LSDT/SIE) + L2T	1.1712	1.0954	1.0707	1.0607	1.0529	1.0469	1.0449	1.0421	1.0416
all + L2T	1.1872	1.1054	1.0795	1.0699	1.0616	1.0551	1.0531	1.0500	1.0502



<The performance improvement ratios / left: Algorithm set, right: the number of transfer learning experience>

Experiment (3): Varying the Reflection Function

- Reflection function의 구성 요소가 성능에 미치는 영향력을 확인하기 위한 실험
- L2T의 Reflection function 3가지 요소(MMD, variance, discriminant criterion) 모두 고려하는 것이 상호 보강이 되어 우수한 결과를 보임
- 사용되는 Kernel의 범위에 따른 결과를 보면 더 많은 Kernel 사용할 수 있도록 성능 향상이 됨
 - 더 많은 kernel은 reflection function에서 더 나은 전이 학습 기술을 학습



<The performance improvement ratios / left: the configurations of reflection function, right: kernel range>

Conclusion

- 본 논문은 이전 전이 학습 경험을 활용하여 **Source와 Target 도메인 간 무엇을(what), 어떻게(How) 전이할 지 자동으로 최적화**되는 framework 제안
 - Domain 쌍과 그들 사이로 전이된 지식을 성능 향상 비율로 Mapping 하는 reflection function
 - 새로운 Domain 쌍을 받으면, **학습된 Reflection function의 값을 최대화하는 방향으로 전이 학습 방향 최적화**
- 전이 학습 경험을 활용한 L2T framework는 전이 학습을 개선하는 새로운 방법론을 개척

Q & A