

# 迁移学习之异构域适应简介

姚远

2018.5.24

# 目录

迁移学习

异构域适应

代表性方法

总结

# 目录

迁移学习

异构域适应

代表性方法

总结

# 什么是迁移学习？

❖ **动机：**人类可以举一反三，触类旁通。

计算机可以举一反三，触类旁通吗？？？

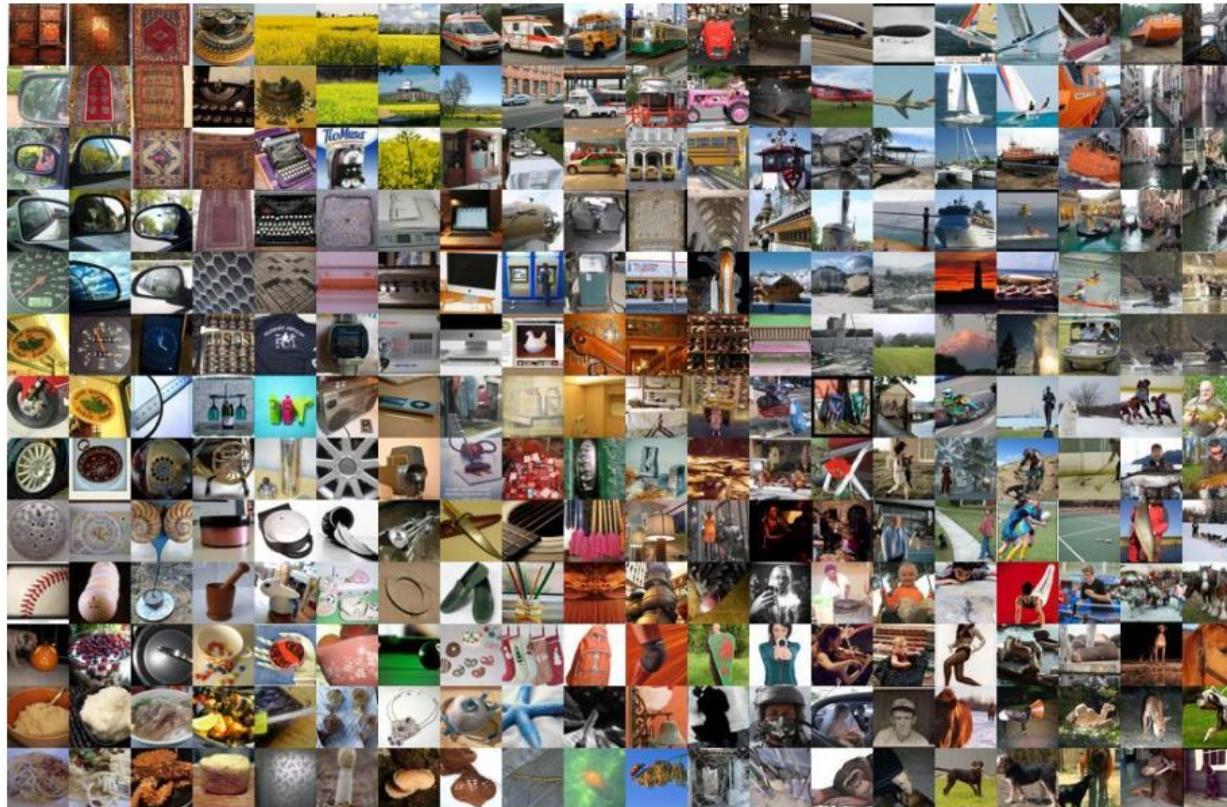


❖ **定义：**迁移学习旨在从源域中抽取知识，并将其运用于目标域的学习。

# 为什么研究迁移学习？

## ❖ 问题：

- 标记大量的数据费时费力



# 为什么研究迁移学习？

## ❖ 问题：

- 标记大量的数据费时费力
- 存在许多已有的公开数据集

### 图像数据

#### 综合图像

[Visual Genome 图像数据](#)

[Visual7w 图像数据](#)

[COCO 图像数据](#)

[SUFR 图像数据](#)

[ILSVRC 2014 训练数据 \(ImageNet的一部分\)](#)

[PASCAL Visual Object Classes 2012 图像数据](#)

[PASCAL Visual Object Classes 2011 图像数据](#)

[PASCAL Visual Object Classes 2010 图像数据](#)

[80 Million Tiny Image 图像数据](#) 【数据太大仅有介绍】

[ImageNet](#) 【数据太大仅有介绍】

### 物体分类图像

[COIL-20 图像数据](#)

[COIL-100 图像数据](#)

[Caltech-101 图像数据](#)

[Caltech-256 图像数据](#)

[CIFAR-10 图像数据](#)

[CIFAR-100 图像数据](#)

[STL-10 图像数据](#)

### 自然语言处理

[RCV1 英语 新闻数据](#)

[20news 英语新闻数据](#)

[First Quora Release Question Pairs 问答数据](#)

[JRC Names 各国语言专有实体名称](#)

[Multi-Domain Sentiment V2.0](#)

[LETOR 信息检索数据](#)

[Yale Youtube Vedio Text 斯坦福问答数据](#) 【Kaggle数据】

[美国假新闻数据](#) 【Kaggle数据】

[NIPS会议文章信息数据 \(1987-2016\)](#) 【Kaggle数据】

# 为什么研究迁移学习？

## ❖ 问题：

- 标记大量的数据费时费力
- 存在许多已有的公开数据集



利用一些大型公开数据集训练  
一个模型，去预测另一个领域的  
未知样本？？？

不可行！！！

分布、特征空间、类标空间差异

# 为什么研究迁移学习？

## ❖ 问题：

- 标记大量的数据费时费力
- 存在许多已有的公开数据集



如何减少不同领域数据之间分布、  
特征空间、类标空间的差异？？？

迁移学习（Transfer Learning）

# 如何研究迁移学习？

## ❖ 三个主要的问题：

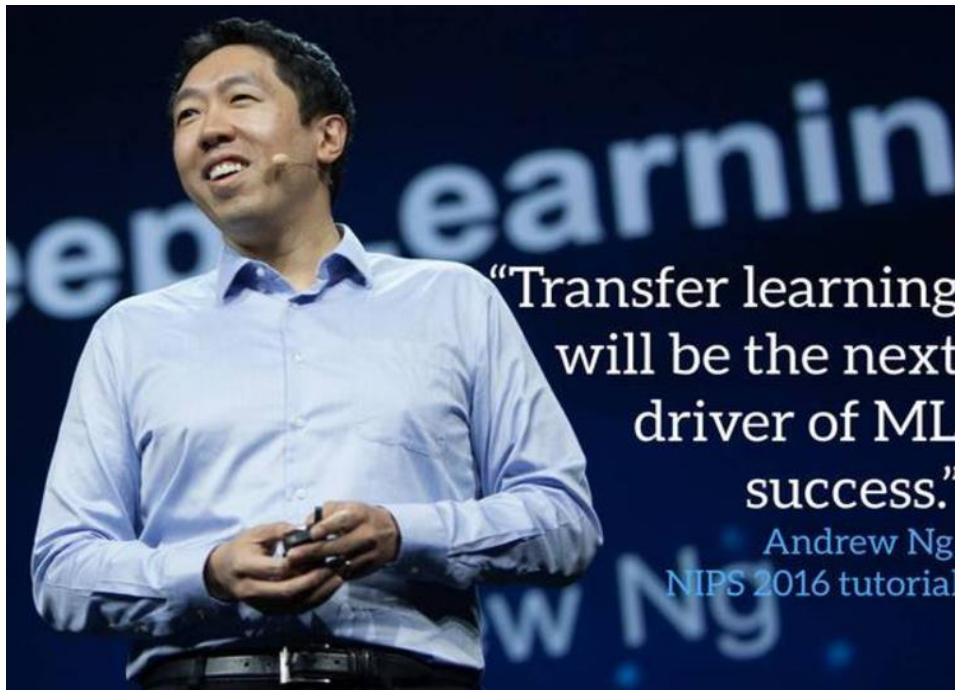
- 迁移什么？（**知识**）
- 如何迁移？（**算法**）
- 何时迁移？（**情景**）

## ❖ 四种策略（**知识**）：

- 基于**实例**的迁移学习
- 基于**特征**的迁移学习
- 基于**参数**的迁移学习
- 基于**关系**的迁移学习

# 迁移学习的前（钱）景？

- ❖ “**迁移学习**非常有前（钱）景！” ~姚远
- ❖ “**迁移学习**将成为机器学习在工业上成功应用的下一个驱动力！”



# 目录

迁移学习

异构域适应

代表性方法

总结

# 什么是异构域适应？

## ❖ 迁移学习与域适应（Domain Adaptation）

(DA) is a particular case of transfer learning (TL) that leverages labeled data in one or more related *source* domains, to learn a classifier for unseen or unlabeled data in a *target* domain. In general it is assumed that the task is the same, i.e. class labels are shared between domains. The source domains are assumed to be

Csurka G. Domain adaptation for visual applications: A comprehensive survey[J]. arXiv preprint arXiv:1702.05374, 2017.

## ❖ 异构域适应（Heterogeneous Domain Adaptation）： 当 $\mathcal{X}_s \neq \mathcal{X}_t$ 时的域适应（Domain Adaptation）问题<sup>[1]</sup>。

### ❖ 类型：

- 无监督异构域适应
- 监督异构域适应
- 半监督异构域适应

[1] Csurka G. Domain adaptation for visual applications: A comprehensive survey[J]. arXiv preprint arXiv:1702.05374, 2017.

# 为什么研究异构域适应？

- ❖ 许多迁移学习方法假设 $X_s = X_T$ ，因此它们无法直接应用于 $X_s \neq X_T$ 的场景。

然而，异构的场景也是较为普遍的。

- ❖ 应用：
  - 跨分辨率图像分类
  - 跨语言文本分类
  - 跨仪器医疗影像识别
  - . . .

# 如何研究异构域适应?

❖ 两类策略:

- 对称特征转换
- 非对称特征转换

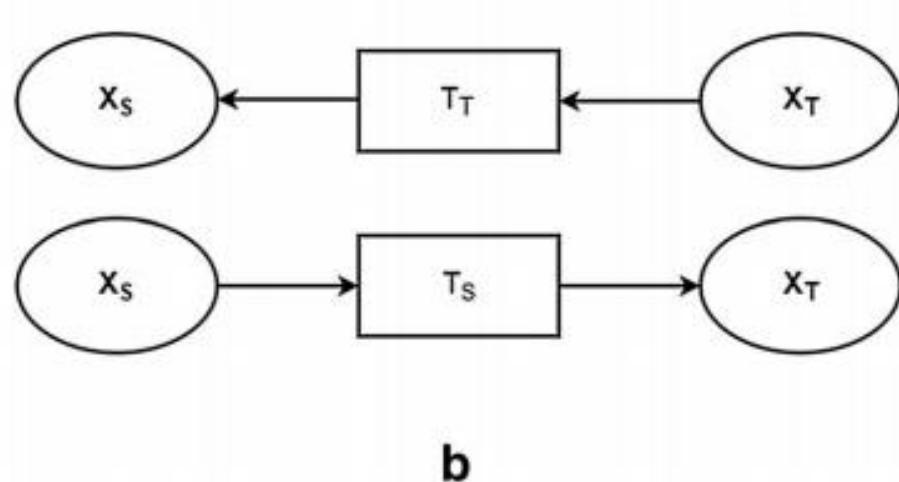
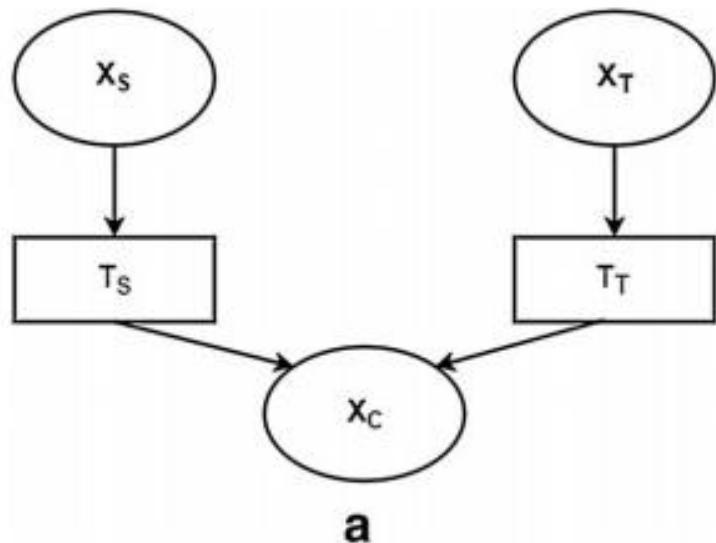


Figure 1. Illustration of **symmetric** (a) and **asymmetric** (b) feature transformation [1]

# 目录

迁移学习

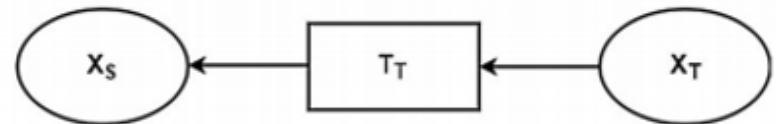
异构域适应

代表性方法

总结

# MMDT

- ❖ Max-Margin Domain Transforms [1].
- ❖ Type: **asymmetric** transformation.
- ❖ Objective function:

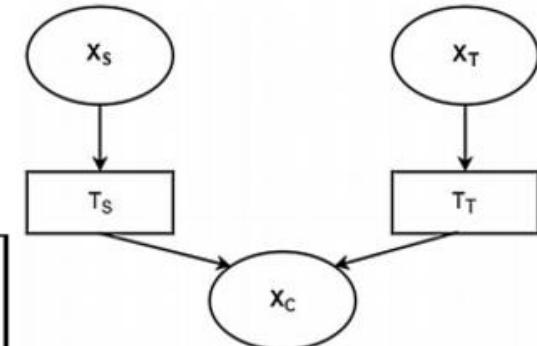


$$\begin{aligned} \min_{W, \theta, b} \quad & \frac{1}{2} \|\theta\|_2^2 \\ \text{s.t.} \quad & y_i^s \left( \begin{bmatrix} x_i^s \\ 1 \end{bmatrix}^T \begin{bmatrix} \theta \\ b \end{bmatrix} \right) \geq 1 \quad \forall i \in \mathcal{D}_S \end{aligned}$$

# HFA, SHFA

- ❖ Heterogeneous Feature Augmentation [1].
- ❖ Type: **symmetric** transformation.
- ❖ Feature augmentation:

$$\varphi_s(x^s) = \begin{bmatrix} x^s \\ x^s \\ 0_d \end{bmatrix}, \varphi_t(x^t) = \begin{bmatrix} x^t \\ 0_d \\ x^t \end{bmatrix} \quad \varphi_s(x^s) = \begin{bmatrix} Px^s \\ x^s \\ 0_{d_t} \end{bmatrix}, \varphi_t(x^t) = \begin{bmatrix} Qx^t \\ 0_{d_s} \\ x^t \end{bmatrix}$$



- ❖ Objective function:

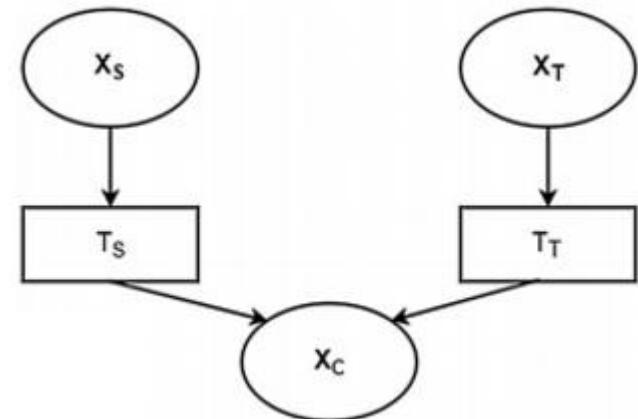
$$\begin{aligned} & \min_{\mathbf{P}, \mathbf{Q}} \min_{\mathbf{w}, b, \xi_i^s, \xi_i^t} \frac{1}{2} \|\mathbf{w}\|^2 + C \left( \sum_{i=1}^{n_s} \xi_i^s + \sum_{i=1}^{n_t} \xi_i^t \right), \\ \text{s.t. } & y_i^s (\mathbf{w}' \varphi_s(\mathbf{x}_i^s) + b) \geq 1 - \xi_i^s, \xi_i^s \geq 0; \\ & y_i^t (\mathbf{w}' \varphi_t(\mathbf{x}_i^t) + b) \geq 1 - \xi_i^t, \xi_i^t \geq 0; \\ & \|\mathbf{P}\|_F^2 \leq \lambda_p, \|\mathbf{Q}\|_F^2 \leq \lambda_q, \end{aligned}$$

# HFA, SHFA

❖ Semi-supervised Heterogeneous Feature Augmentation [1].

- ❖ Type: **symmetric** transformation.
- ❖ Objective function:

$$\begin{aligned}
 & \min_{\substack{y_u, \mathbf{w}, b, \rho, \\ \mathbf{P}, \mathbf{Q}, \xi_i^s, \xi_i^t, \xi_i^u}} && \frac{1}{2} (\|\mathbf{w}\|^2 + b^2) - \rho \\
 & && + \frac{C}{2} \left( \sum_{i=1}^{n_s} (\xi_i^s)^2 + \sum_{i=1}^{n_t} (\xi_i^t)^2 \right) + \frac{C_u}{2} \sum_{i=1}^{n_u} (\xi_i^u)^2 \\
 \text{s.t. } & y_i^s (\mathbf{w}' \varphi_s(\mathbf{x}_i^s) + b) \geq \rho - \xi_i^s, \\
 & y_i^t (\mathbf{w}' \varphi_t(\mathbf{x}_i^t) + b) \geq \rho - \xi_i^t, \\
 & \underline{y_i^u (\mathbf{w}' \varphi_t(\mathbf{x}_i^u) + b) \geq \rho - \xi_i^u}, \\
 & \underline{\mathbf{1}' \mathbf{y}_u = \delta, \quad \|\mathbf{P}\|_F^2 \leq \lambda_p, \quad \|\mathbf{Q}\|_F^2 \leq \lambda_q},
 \end{aligned}$$



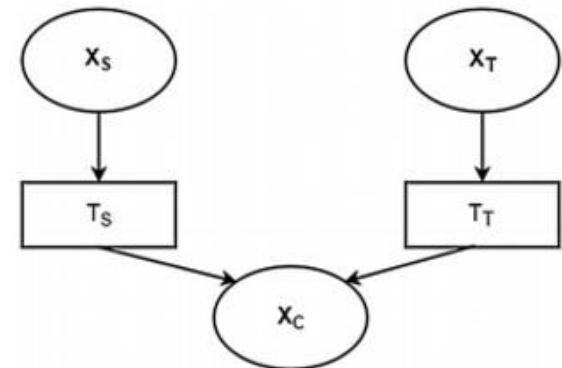
# G-JDA

- ❖ Generalized Joint Distribution Adaptation<sup>[1]</sup>.
- ❖ Type: **symmetric** transformation.
- ❖ Objective function:

$$\begin{aligned} \min_{\mathbf{A}_S, \mathbf{A}_T} \quad & E_{mar}(\mathbf{A}_S, \mathbf{A}_T) + \sum_{c=1}^C E_{cond}^{(c)}(\mathbf{A}_S, \mathbf{A}_T) \\ & + \lambda (\|\mathbf{A}_S\|^2 + \|\mathbf{A}_T\|^2) \end{aligned}$$

$$\text{s.t. } \hat{\mathbf{X}} \mathbf{H} \hat{\mathbf{X}}^\top = \mathbf{I},$$

$$\hat{\mathbf{X}} = [\mathbf{A}_S^\top \mathbf{X}_S, \mathbf{A}_T^\top \mathbf{X}_T] \quad \mathbf{H} = \mathbf{I}_{n_S+n_T} - \frac{1}{n_S+n_T} \mathbf{1}_{n_S+n_T} \mathbf{1}_{n_S+n_T}^\top$$



# G-JDA

## ❖ Objective function:

$$\begin{aligned} \min_{\mathbf{A}_S, \mathbf{A}_T} \quad & E_{mar}(\mathbf{A}_S, \mathbf{A}_T) + \sum_{c=1}^C E_{cond}^{(c)}(\mathbf{A}_S, \mathbf{A}_T) \\ & + \lambda (\|\mathbf{A}_S\|^2 + \|\mathbf{A}_T\|^2) \\ \text{s.t. } \quad & \hat{\mathbf{X}} \mathbf{H} \hat{\mathbf{X}}^\top = \mathbf{I}, \end{aligned}$$

Applying the Maximum Mean Discrepancy (MMD) [1] to measure the distance between marginal distributions.

$$E_{mar}(\mathbf{A}_S, \mathbf{A}_T) = \left\| \frac{1}{n_S} \sum_{i=1}^{n_S} \mathbf{A}_S^\top \mathbf{x}_S^i - \frac{1}{n_T} \sum_{j=1}^{n_T} \mathbf{A}_T^\top \mathbf{x}_T^j \right\|^2$$

Applying the modified MMD to measure the distance between conditional distributions.

$$E_{cond}^{(c)}(\mathbf{A}_S, \mathbf{A}_T) = \left\| \frac{1}{n_S^c} \sum_{i=1}^{n_S^c} \mathbf{A}_S^\top \mathbf{x}_S^{i,c} - \frac{1}{n_T^c} \sum_{j=1}^{n_T^c} \mathbf{A}_T^\top \mathbf{x}_T^{j,c} \right\|^2$$

# G-JDA

## ❖ Algorithm:

---

### Algorithm 1 Generalized Joint Distribution Adaptation

---

**Input:** Source-domain data  $\mathcal{D}_S = \{\mathbf{x}_S^i, y_S^i\}_{i=1}^{n_S}$ , labeled target-domain data  $\mathcal{D}_L = \{\mathbf{x}_L^i, y_L^i\}_{i=1}^{n_L}$ , unlabeled target-domain data  $\{\mathbf{x}_U^i\}_{i=1}^{n_U}$ , dimension  $d_K$ , and parameter  $\lambda$

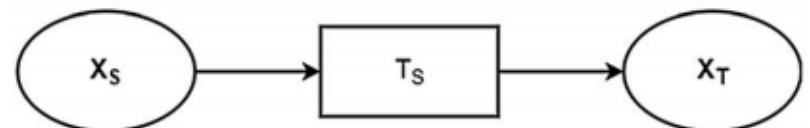
- 1: Initialize  $\mathbf{A}_S, \mathbf{A}_T$  in (7) using  $\mathcal{D}_S$  and  $\mathcal{D}_L$
- 2: **while** not converge **do**
- 3:   Learn linear SVMs using projected labeled cross-domain data
- 4:   Update pseudo labels  $\{\hat{y}_U^i\}_{i=1}^{n_U}$
- 5:   Calculate  $\{\mathbf{M}_i\}_{i=0}^c$  and solve (7) for updating  $\mathbf{A}_S, \mathbf{A}_T$
- 6: **end while**

**Output:**  $\mathbf{A}_S, \mathbf{A}_T$ , and  $\{\hat{y}_U^i\}_{i=1}^{n_U}$

---

# LS-UP

- ❖ Label and Structure-consistent Unilateral Projection [1].
- ❖ Type: **asymmetric** projection.
- ❖ Objective function:



$$\begin{aligned} \min_{\mathbf{A}} \sum_{c=1}^C & \left\| \frac{1}{n_s^c} \sum_{i=1}^{n_s} \mathbf{A}^\top \mathbf{x}_s^{i,c} - \frac{1}{n_l^c} \sum_{i=1}^{n_l^c} \mathbf{x}_l^{i,c} \right\|^2 + \lambda \|\mathbf{A}\|^2 \\ & + \sum_{i=1}^{n_s} \sum_{j=1}^{n_s} w_{ij} \|\mathbf{A}^\top \mathbf{x}_s^i - \mathbf{A}^\top \mathbf{x}_s^j\|^2. \end{aligned}$$

$$w_{ij} = \begin{cases} \exp \left( - \|\mathbf{x}_s^i - \mathbf{x}_s^j\|^2 / \sigma^2 \right) & \text{if } \{\mathbf{x}_s^i, \mathbf{x}_s^j\} \in \mathbf{X}_S^c \\ 0 & \text{otherwise} \end{cases}$$

# 目录

迁移学习

异构域适应

代表性方法

总结

# 总结

- ❖ 迁移学习：从源域数据中抽取知识，并将其用于目标域数据的学习。
- ❖ 异构域适应：
  - $X_S \neq X_T$
  - 对称投影，非对称投影

# 总结

- ❖ Day O, Khoshgoftaar T M. A survey on heterogeneous transfer learning[J]. Journal of Big Data, 2017, 4(1): 29.
- ❖ Csurka G. Domain adaptation for visual applications: A comprehensive survey[J]. arXiv preprint arXiv:1702.05374, 2017.
- ❖ Weiss K, Khoshgoftaar T M, Wang D D. A survey of transfer learning[J]. Journal of Big Data, 2016, 3(1): 9.
- ❖ Shao L, Zhu F, Li X. Transfer learning for visual categorization: A survey[J]. IEEE transactions on neural networks and learning systems, 2015, 26(5): 1019-1034.
- ❖ Zhang J, Li W, Ogunbona P. Transfer Learning For Cross-Dataset Recognition: A Survey[J].
- ❖ Patel V M, Gopalan R, Li R, et al. Visual domain adaptation: A survey of recent advances[J]. IEEE signal processing magazine, 2015, 32(3): 53-69.
- ❖ Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on knowledge and data engineering, 2010, 22(10): 1345-1359.
- ❖ 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. 软件学报, 2015, 26(1): 26-39.
- ❖ 戴文渊. 基于实例和特征的迁移学习算法研究[D]. 上海: 上海交通大学, 2009.
- ❖ 龙明盛. 迁移学习问题与方法研究[D]. 清华大学, 2014.
- ❖ 王晋东. 迁移学习简明手册.

# 总结

机器学习：昨天，今天，明天

昨天

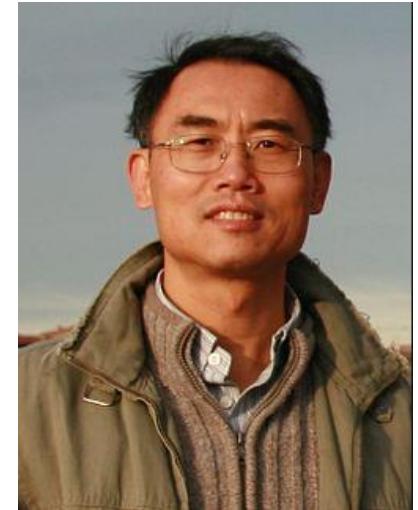
今天

明天

深度学习：  
大量数据  
特征  
准确性

强化学习：  
大量数据  
反馈  
策略

迁移学习：  
少量数据  
学习方法  
冷启动 /  
个性化



祝各位学(前)业顺利，  
谢谢！



更多分享请关注极市平台公众号



更多视觉算法合作请联系小助手