

博士学位论文

迁移学习在文本分类中的应用研究

Research on the Application of Transfer Learning on Text Classification

作者姓名: 孟佳娜

学科、专业: 计算机应用技术

学号: 10709038

指导教师: 林鸿飞

完成日期: 2011.4.15

大连理工大学

Dalian University of Technology

大连理工大学学位论文独创性声明

作者郑重声明：所呈交的学位论文，是本人在导师的指导下进行研究工作所取得的成果。尽我所知，除文中已经注明引用内容和致谢的地方外，本论文不包含其他个人或集体已经发表的研究成果，也不包含其他已申请学位或其他用途使用过的成果。与我一同工作的同志对本研究所做的贡献均已在论文中做了明确的说明并表示了谢意。

若有不实之处，本人愿意承担相关法律责任。

学位论文题目： 迁移学习在文本分类中的应用研究

作者签名： _____ 日期： _____ 年 _____ 月 _____ 日

摘 要

迁移学习方法是一种新的机器学习框架，它不同于传统的监督学习、无监督学习和半监督学习，该方法通过将某一源领域的标注数据样本和目标领域的未标注样本或少量的标注样本中学习到一个紧凑的、有效的表示，然后将学习到的特征表示方法应用到目标领域中。迁移学习没有像传统的机器学习那样要求训练数据与测试数据必需服从相同的分布，因此，迁移学习能够有效地在相似的领域或任务之间进行信息的共享和迁移。目前，迁移学习逐渐成为信息检索、文本挖掘和自然语言处理的热点话题，引起学术界和企业界的高度重视。

本文以文本分类为研究背景，以迁移学习为研究内容，围绕文本分类面临的主要挑战，重点关注具体应用中不同的迁移信息和方法，展开了对迁移学习模式下的特征和样本重构方法的研究，并提出了几种适用于迁移学习的文本分类方法。主要研究成果包括：

1. 提出一种基于特征映射的迁移学习方法。特征和样本是文本分类的两个重要方面，综合考虑这两种因素是非常重要的。本文提出的方法结合了基于特征和基于样本两种迁移学习方法。首先，该方法构建两个领域的公共特征子空间，通过基于互信息的方法得到公共特征中与测试集的主题因子最相关的特征，然后，在新的特征子空间下学习一个新的特征映射函数，通过构建的特征映射函数来对源领域和目标领域的的数据重新赋权重，通过使用基于样本的方法完成了知识的迁移，从而降低了具有不同分布的数据之间的距离。实验中使用了为符合迁移学习要求所构造的三个文本分类的语料，实验结果显著的超过了一些传统的监督分类方法，从而验证了算法的有效性。

2. 提出一种自适应迁移学习方法。该方法以奇异值分解为基础，计算了目标领域的特有特征和公共特征之间的相似度，根据特征之间的相似度值对训练集和测试集的数据进行重构，通过建立的新的训练模型，给测试集数据一个预测的标签，并自适应的选择目标领域的合适的样本加入到原有的训练集中，从而解决了原有的训练集的数据偏置问题。本文将该方法应用到欧洲机器学习/数据挖掘竞赛 ECML/PKDD 2006 Discovery Challenge 语料库中，取得了较好的实验结果，也验证了该方法的有效性。

3. 提出一种基于图的迁移学习方法。基于图的方法具有谱图理论下的很好的性质，图方法种类很多，其中 PageRank 算法是一种被广泛使用的方法，这种排序策略已经被扩展到很多领域。本文以 PageRank 算法的思想为基本框架，通过使用源领域和目标领域的的数据建构一个融合的图模型。源领域的的数据可以用来取得目标领域数据的伪标签，目标领域的的数据可以用来更新标签，同时在迭代计算中保留了上一次预测的标签信息，当算法收敛时，目标领域数据的预测标签为最终的结果。理论上，文中给出了算法收敛

的证明，并且进行了模拟实验。实验中使用了 Web 文本分类、文本倾向性分析和垃圾邮件过滤的相关迁移学习语料，与监督和半监督方法相比，实验结果有显著的改善，也证明了该算法的有效性和普适性。

关键词：迁移学习；文本分类；特征选择；自适应；图排序

Abstract

Transfer learning is a new machine learning framework, it differs from traditional machine learning methods, such as supervised learning, unsupervised learning and semi-supervised learning. This method learns a compact and effective representation through labeled samples from a source domain and unlabeled samples or few of labeled samples from a target domain, and then applies the obtained feature representation methods to the target domain. Transfer learning does not make the identical distribution assumption as traditional machine learning. Therefore, transfer learning can be effectively share and transfer information between similar domains or tasks. At present, transfer learning gradually becomes the hot topic in information retrieval, text mining and natural language processing, at the same time causes the highly attentions of academic and corporate.

Based on the text classification as a background and the transfer learning as a research content, around the main challenges of text classification, this dissertation focuses on the specific application of different transferring information and method, discusses the reconstructing methods of features and samples at the transfer learning mode, and proposes several text classification methods suitable for transfer learning. The main research results include:

1. Transfer learning method based on feature mapping is proposed. Features and samples are two important aspects of text classification. It is very important that the two factors are considered comprehensively. The feature-based and sample-based methods are combined. Firstly, the common features subspace of the source domain and the target domain is constructed. Based on mutual information the most interrelated feature is got between a common feature and a subject factor in the target domain. Then, a new feature mapping function is learned on the new feature subspace. Finally, the data of the source domain and the target domain are re-weighted. Knowledge transferring is finished through the sample-based method; as a result the distances between the data coming from different distributions are reduced. In the experiment, three constructed text classification corpora fitting with transfer learning are used. Experiment results exceed several traditional classification methods, which verify the effectiveness of the proposed method.

2. Adaptive transfer learning method is proposed. The similar degree between the specific features in the target domain and the common features is computed based on the singular value decomposition method. Then the data of the training and the test are reconstructed according to the computed similar degree values. The test data are predicated a

label based on the new constructed model and the suitable target domain data are selected and added to the original training set adaptively that solve the data biased problem of original training data. The proposed method is applied to the ECML/PKDD 2006 Discovery Challenge corpus. The preferable experiment results are gained, the effectiveness of the proposed method is demonstrated.

3. Graph-based transfer learning method is proposed. The graph-based method has excellent properties at the spectral graph theory. There are many graph-based methods. PageRank algorithm is known as an extensive method and is expanded to many areas. The proposed method takes the PageRank algorithm as a basic framework. A fusion graph model is constructed through the source domain data and the target domain data. The pseudo labels of the target domain data are obtained by the source domain data and updated by the target domain data. At the same time the last predicted labels are retained in the iterative computations. When the algorithm converges, the predicted labels of the target domain data are the final results. Theoretically, the convergence of the algorithm is proved and the simulated experiments are also given. The web text classification, sentiment classification and spam filtering corpora related to transfer learning are used. Compared with the supervised learning and semi-supervised learning, the experiment results show the significant improvements and demonstrate the effectiveness and universality of this method.

Key Words: Transfer Learning; Text Classification; Feature Selection; Adaptive; Graph Ranking

目 录

摘 要.....	I
Abstract.....	III
1 绪论.....	1
1.1 研究背景.....	1
1.2 研究现状.....	2
1.3 迁移学习与其它机器学习方法的区别.....	5
1.4 迁移学习不同方法.....	6
1.4.1 迁移学习的定义.....	6
1.4.2 迁移学习的分类.....	7
1.5 迁移学习的应用.....	9
1.6 本文所做的工作及创新.....	10
1.7 论文组织结构.....	12
2 文本分类综述.....	13
2.1 自动文本分类系统.....	13
2.1.1 文本表示.....	13
2.1.2 特征选择.....	14
2.1.3 文本分类方法.....	15
2.1.4 评价标准.....	18
2.1.5 文本分类的总体步骤.....	19
2.2 文本分类的研究现状及存在的问题.....	19
2.3 迁移学习在文本分类中的应用.....	20
2.3.1 主要的应用领域和方法.....	20
2.3.2 实验语料.....	22
2.3.3 对比结果.....	23
2.3.4 存在的问题.....	28
3 两阶段特征选择方法.....	29
3.1 背景知识.....	29
3.2 两阶段特征选择方法.....	29
3.2.1 FCD 特征选择方法.....	30
3.2.2 基于 LSI 的特征选择.....	31
3.3 实验和结果.....	32

3.3.1	语料	32
3.3.2	结果	32
3.4	本章小结	35
4	基于特征映射的迁移学习	37
4.1	背景介绍及问题描述	37
4.1.1	背景介绍	37
4.1.2	问题描述	38
4.2	基于特征映射的迁移学习方法	38
4.2.1	新的特征表示子空间	38
4.2.2	特征相互关系	39
4.2.3	特征映射函数	40
4.2.4	算法描述	41
4.3	实验和结果	41
4.3.1	语料	41
4.3.2	工具包	43
4.3.3	结果	43
4.4	本章小结	47
5	自适应迁移学习	48
5.1	背景介绍及问题描述	48
5.1.1	背景介绍	48
5.1.2	问题描述	49
5.2	自适应的迁移学习方法	49
5.2.1	基于 SVD 的迁移学习算法 TLSVD	49
5.2.2	自适应的迁移学习算法 ATL	51
5.3	实验和结果	53
5.3.1	语料	53
5.3.2	TLSVD 方法的结果	54
5.3.3	ATL1 方法的结果	54
5.3.4	ATL2 方法的结果	55
5.3.5	实验的比较结果	56
5.4	本章小结	58

6	基于图的迁移学习	59
6.1	背景介绍及问题描述	59
6.1.1	背景介绍	59
6.1.2	问题描述	60
6.2	基于图排序算法的迁移学习方法	60
6.2.1	PageRank 模型及其算法	60
6.2.2	基本假设	61
6.2.3	特征选择	61
6.2.4	初始化	62
6.2.5	文本相似度矩阵	62
6.2.6	以文本相似度矩阵为基础的文本分值	63
6.2.7	收敛性证明	64
6.3	实验和结果	65
6.3.1	语料	65
6.3.2	实现细节	67
6.3.3	结果	67
6.3.4	参数敏感性	68
6.3.5	与 SCL-MI 方法的实验结果对比	71
6.4	本章小结	71
7	工作总结与展望	73
7.1	总结	73
7.2	进一步的工作	75
	参 考 文 献	76
	攻读博士学位期间发表学术论文情况	87
	攻读博士学位期间参加项目情况	88
	致 谢	89
	作者简介	90
	大连理工大学学位论文版权使用授权书	91

1 绪论

机器学习(Machine Learning)是研究计算机如何实现或模拟人类的学习行为,以获取新的知识或技能,重新组织已有的知识结构使之不断改善自身的性能。目前在机器学习研究领域影响较大的是H.Simon的观点:学习是系统中的任何改进,这种改进使得系统在重复同样的工作或进行类似的工作时能完成得更好。它是人工智能的核心,是使计算机具有智能的根本途径,其应用遍及人工智能的各个领域,如专家系统、自动推理、自然语言理解、模式识别、计算机视觉、智能机器人等领域。利用机器学习的技术,计算机可以根据已经拥有的数据进行自动的学习,提炼出有价值的知识,并应用在新的问题上。机器学习的研究目的是用计算机模拟人类的学习活动,而从数据中学习是机器学习研究的关键问题之一^[1,2]。从数据中学习就是研究如何从一些观测数据(样本)出发得到目前尚不能通过原理分析得到的规律,然后利用这些规律对未知数据进行分析和预测。基于数据的机器学习主要包括三种方式:监督学习^[3-6]、无监督学习^[7-11]和半监督学习^[12-18]。

1.1 研究背景

虽然机器学习已经取得了引人注目的成果,但是,和人的学习相比,机器学习还存在着明显的不足。人可以通过不断学习,继承和发展过去学到的知识,持续增强自己的能力。而绝大多数机器学习都是从零开始的,并不借鉴以前学到的知识,也不对学到的知识进行改进和发展,这很大程度上限制了机器学习的能力。人在学习时,具有在不同领域、不同问题之间进行迁移转化的能力,例如,一个人如果已经掌握了法语,那么在以后学习德语或其它语言时将会起到帮助,而这正是目前机器学习所缺乏的。知识在不同任务或领域之间迁移转化的能力被称作迁移学习(Transfer Learning)^[19-23]。

迁移学习是人的基本学习技能,具体来说,迁移学习是指一种学习对另一种学习的影响或学习的经验对完成其他任务的影响。平时我们说的触类旁通、举一反三等都属于迁移。心理学家发现,当两种学习在内容和方法上有共同因素时,就会产生迁移,反之,就不会有迁移作用的发生。两种学习共同因素越多,迁移作用就越大。例如,人在学习数学知识后,在学习力学时会起到很大帮助,这是因为数学和力学有很多共通之处,因此就会起促进作用。而数学知识对学习语言学则没有什么帮助。

综上所述,提高机器学习能力的一个关键问题就在于,要让机器像人一样能够继承和发展过去学到的知识,而这其中一个关键的问题就在于,要让机器学会迁移学习。学会了迁移学习,机器就会提高充分利用以前学到的知识的能力,从而更好地奠定了机器实现增量学习的基础。

1.2 研究现状

知识在不同场景之间迁移转化的能力被称作迁移学习。迁移学习方法是一种新的机器学习框架，它不同于传统的监督学习、无监督学习和半监督学习。在传统的监督学习中，学习器通过对大量有标记的训练样本进行学习，进而建立相应的模型用以处理测试样本。这里的“标记”(Label)是指样本所对应的目标向量。随着数据收集和存储技术的飞速发展，收集大量未标记(Unlabeled)样本已相当容易，而获取大量有标记的样本则要困难得多，因为获得这些标记往往需要耗费大量的人力物力，因此半监督学习方法应运而生，半监督学习是模式识别和机器学习研究领域的热点之一，在文本分类、图像分类、邮件过滤、信息抽取、词性消歧等方面得到了广泛的应用^[24-29]。根据半监督分类算法的实现方式，现有的典型方法大致分为：自训练方法(Self-training)、协同训练方法(Co-training)、基于图的半监督分类方法、基于生成模型(Generative Model)的半监督分类方法、直推式支持向量机方法(Transductive Support Vector Machine, TSVM)等。在没有任何标注数据的情况下，可以选择无监督的学习方法，无监督学习也可以称之为聚类分析。一般的聚类方法可以分为五类：基于模型的方法^[30]，基于密度的方法^[31]，基于划分的方法^[32-33]，基于网格的方法^[34]和基于层次的方法^[35-36]，而有的方法是综合了上述多个方法^[37]。

目前，机器学习基本建立在一个很强的假设之上：训练数据与测试数据分布相同，然而这一假设在许多实际应用中并不成立。当分布发生改变时，需重新训练模型，代价往往很高。例如，在一个网页检索系统中，因为互联网上的信息变化非常快，用来训练网页分类模型的Web数据经常会随着时间的变化而发生过的情况，不能正确地表达目前网页的信息特征，用这些过时数据得到的分类模型来对未知的Web网页进行分类时就不能准确的标注，而重新对新获得的数据进行标注在许多实际问题中也不现实。事实上，这些机器学习方法均没有利用之前的学习任务中获得的知识，如果这些任务之间具有一定的相关性，先前任务中得到的知识也许经过些许变换甚至无需任何改动就可直接应用于新的任务中。而采用传统的机器学习方法，一切从零开始，无疑将浪费大量的时间和精力。此外，倘若这些知识是普遍有效的规则，并且在新任务中使用的少量数据很难获得，那么通过知识迁移无疑将大大提高精度。这种将其他任务(源任务)或其他领域(源领域)中学习到的知识，迁移应用到目标任务或领域中，使之有利于目标任务或领域的完成，减少对目标任务或领域训练数据的依赖的学习方式就是迁移学习。其中，源任务与目标任务或源领域与目标领域之间的特征空间、分布都可以有所不同。

在机器学习领域，迁移学习是一个比较新的名词。最初是在上世纪 90 年代人们可是进行迁移学习的研究。开始的研究方向主要包括，“learning how to learn^[38]”、“multi-task learning^[39-40]”。2005 年，美国高级研究计划局（DARPA）的信息处理技术办公室(IPTO) 对迁移学习的定义是：一个系统将先前任务中学习的知识和技能应用和识别到新任务中的能力。迁移学习近期受到机器学习领域的广泛关注，DARPA 联合美国加州大学伯克利分校、麻省理工学院、俄勒冈州立大学和斯坦福大学四所高校成立了一个项目组，专门研究高性能贝叶斯迁移学习，目前，在该项目组的推动下，已举办了几个 workshop。在过去几年的美国人工智能会议(AAAI)、国际机器学习会议(ICML)和国际人工智能联合会议(IJCAI)上，和迁移学习相关的文章呈递增趋势。预计在今后的研究中，迁移学习将会成为机器学习和人工智能研究领域的一个热点。

迁移学习自提出后，受到越来越多的关注，并已被成功应用到很多实际问题中，如文本数据挖掘^[41-43]、文本分类^[44-46]、命名实体识别^[47-49]等。图1.1给出了传统的机器学习方法与迁移学习方法学习过程的不同^[20]。

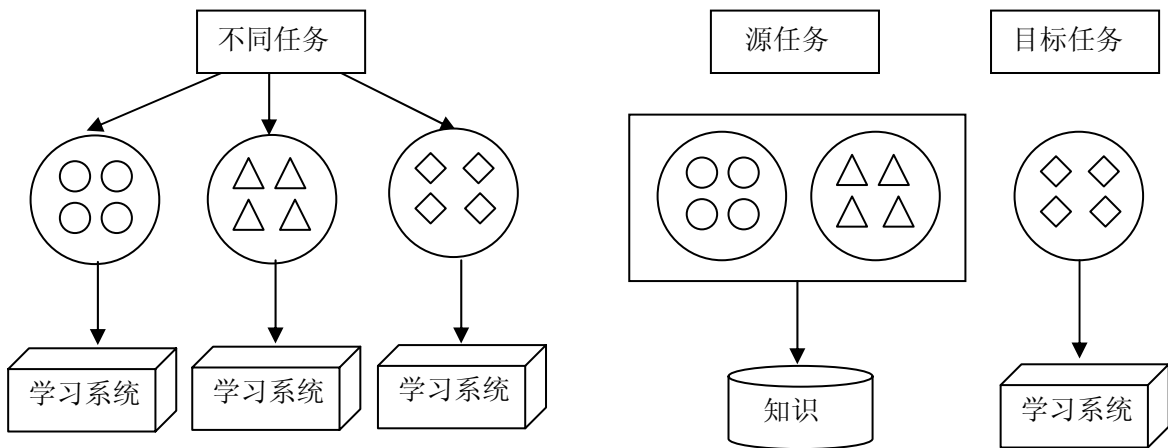


图 1.1 传统的机器学习方法与迁移学习方法的不同

Fig. 1.1 Different learning processes between traditional machine learning and transfer learning

在迁移学习问题中，有如下三个主要研究方面：迁移什么、如何迁移和何时迁移^[20]。

“迁移什么”主要是讨论哪部分知识能够在领域和任务之间迁移。一些知识对于特殊的领域和任务是重要的，一些知识可能在不同的领域之间是公共的，也许能够提高目标领域和任务的分类效果。这里所说的“知识”可以是源领域与目标领域的公共“特征”、“特征”之间的相关性、“样本”之间的相关性、共享的先验分布、共享的语义空间等等。在发现哪些知识能够被迁移之后，需要改进学习算法来解决“如何迁移”问题。“如

何迁移”主要是研究如何通过迁移知识来发展学习算法，发现不同领域潜在的共性和联系，而这些共性和联系往往需要发现原有“特征”之间的相关性，或者将特征空间变换到可以共享的空间上，或者通过挖掘其某些共享的参数等，对于不同的应用领域，这种知识的迁移可以体现在不同的方面。“何时迁移”主要是研究在何种形式下能够使用迁移技术。除此之外，人们也对哪种形式下不能迁移知识感兴趣。在某些形式下，当源领域和目标领域互相没有关系时，强行迁移将不可能成功。在最坏的情况下，它可能会破坏在目标领域学习的效果，这种情况下的迁移被称之为负迁移。目前，通过假设源领域和目标领域相关，大多数迁移学习的工作都集中在“迁移什么”和“如何迁移”上，然而，如何避免负迁移也是一个重要的开发课题，未来会吸引更多的关注。

迁移学习逐渐成为信息检索、文本挖掘和自然语言处理的热点话题，引起学术界和企业界的高度重视，近些年来迁移学习在文本挖掘方面的一些主要的研究成果有：

(1)目前的研究成果主要应用在 Web 网页分类问题、垃圾邮件过滤和文本倾向性分析几个方面。在 Web 网页分类方面，过去的研究主要有样本选择偏置(Sample Selection Bias)^[50]和协方差偏移^[51](Covariate Shift)两个方向。样本选择偏置近年来在机器学习领域得到了关注，Zadrozny 在 2004 年的国际机器学习会议上首次将样本选择偏置引入到机器学习中来。此后，每年的 NIPS 会议都会有研究样本选择偏置和协方差偏移这两个问题的论文，Bickel 和 Scheffer^[52]利用纠正样本选择偏置的方法提出了一个新的反垃圾邮件算法。其他相关的文章可参见[53-55]。其它的研究方向还包括领域适应性问题(Domain Adaptation)，Blitzer 等人^[56]提出一种结构对应学习(SCL)算法，该算法扩展了文献[57]，可以使用目标领域的未标注数据来抽取能够减少领域之间区别的特征。其它的领域适应性问题的相关文献参见文献[58-60]。

(2)国内目前在迁移学习方面研究的个人和机构很少，主要有香港科技大学杨强教授和上海交通大学的机器学习小组薛贵荣等人在从事这方面的研究，近几年他们已经取得了一定的研究成果，发表了十几篇AI领域顶级的会议论文。在2007年的国际机器学习会议上，上海交通大学机器学习小组的相关研究人员发表了名为“Boosting for Transfer Learning”的论文^[61]，用boosting方法在PAC模型的框架下讨论不同数据分布下的学习问题，并设计出一个不同以往的自动调整样本权重的学习算法框架。此后，该小组又提出了一系列的迁移学习方法，例如，Xue等^[62]提出一种跨领域算法，将传统的概率潜在语义分析(PLSA)扩展到来自于不同但相关领域的标注和未标注数据上；Dai等^[63]提出一种统一的处理各种迁移学习问题，诸如跨领域学习、自指导学习等问题的迁移学习框架。除此之外，国内中科院计算所谭松波博士等将迁移学习用于情感分类等方面，

提出了适合领域自适应性的朴素贝叶斯方法^[64]和自适应的信息瓶颈方法^[65],取得了一定的研究成果。

1.3 迁移学习与其它机器学习方法的区别

监督学习、半监督学习和无监督学习是几种典型的机器学习方法,迁移学习与它们既有相同点也有区别。

监督学习要求训练和测试数据来源于相同的分布,训练时要求已经拥有大量的标注数据,这样训练的模型才能在测试时使用。而迁移学习的特点是训练集和测试集数据的分布是不同的,因此,如果简单的使用监督学习的方法,分类的效果就会很差。

半监督学习的研究重点在于使用大量的未标注样本,结合少量的标注样本训练生成分类器,训练集与测试集数据的分布也是相同的。与半监督学习相似的是,迁移学习也使用了标注的和未标注的样本,但不同的是,迁移学习可以使用各种来自于其它领域的辅助信息,尽管这些样本可能来自于不同的特征空间,例如,我们要对一些小汽车和摩托车的图像进行分类,而训练时没有关于小汽车和摩托车的大量的标注图像,对于迁移学习,则可以使用其它的,诸如大卡车、自行车等图像辅助小汽车和摩托车图像的分类。

无监督学习也称为无指导学习,是指训练样本没有类别标号,即没有进行标注,而迁移学习训练时一般已有标注的样本,只不过这些与测试集来源于同一领域的样本很少,或只有其它领域的标注样本。

表 1.1 迁移学习与其它机器学习方法的对比

Tab. 1.1 Comparison with other machine learning methods

机器学习方法	训练/测试集	源领域	目标领域
迁移学习	训练	标注/未标注	标注/未标注(没有或很少)
	测试		未标注
监督学习	训练		标注
	测试		未标注
半监督学习	训练		标注/未标注
	测试		未标注
无监督学习	训练		未标注
	测试		未标注

1.4 迁移学习的不同方法

迁移学习方法通过将某一源领域的标注数据和目标领域的少量标注或未标注数据中学习到一个紧凑的、有效的表示，然后将学习到的特征表示方法应用到目标领域的学习任务中。迁移学习方法不仅利用到了已标注数据，也用到了未标注数据，所以它既不是监督学习，也不是无监督学习，也不等同于半监督学习，而是一种新的机器学习方法。

1.4.1 迁移学习的定义

我们介绍本文中用到的一些符号和定义，首先，我们分别给出“领域”和“任务”的定义。

本文中，一个领域 D 包含了两个组成部分：特征空间 \mathcal{X} 和边缘概率分布 $P(X)$ ，这里 $X = \{x_1, \dots, x_n\} \in \mathcal{X}$ 。例如，如果我们的学习任务是文本分类，而且每一个词特征作为一个二进制特征， \mathcal{X} 是所有特征向量组成的空间， x_i 是对应于文本的第 i 个词向量， X 是某个学习样本，一般的，如果两个领域是不同的，它们将具有不同的特征空间或不同的边缘概率分布。

给出某个领域，一个任务 T 由两部分组成：标签空间 \mathcal{Y} 和目标预测函数 $f(\cdot)$ (由 $T = \{\mathcal{Y}, f(\cdot)\}$ 定义)，该函数是未知的但可以由训练数据学习，训练数据由 $\{x_i, y_i\}$ 数据对组成，这里 $x_i \in X$ 并且 $y_i \in \mathcal{Y}$ 。函数 $f(\cdot)$ 用来预测一个新样本 x 对应的标签 $f(x)$ 。从概率的观点来看， $f(x)$ 可以写为 $P(y|x)$ ，在文本分类中， \mathcal{Y} 是标签的集合，即对于一个二分类的文本分类问题，其值为真或假，即 y_i 的值为“真”或“假”。

本文中，我们仅仅考虑只有一个源领域 D_S 和一个目标领域 D_T 的例子，这也是最广泛的研究工作之一。特别的，我们定义源领域数据为 $D_S = \{(x_{S_1}, y_{S_1}), \dots, (x_{S_n}, y_{S_n})\}$ ，其中 $x_{S_i} \in X_S$ ， $y_{S_i} \in \mathcal{Y}$ 是对应的类标签。在文本分类例子中， D_S 是词向量的集合，其值为真或假。相似的，定义目标领域数据为 $D_T = \{(x_{T_1}, y_{T_1}), \dots, (x_{T_n}, y_{T_n})\}$ ，输入值 $x_{T_i} \in X_T$ ， $y_i \in \mathcal{Y}$ 是其对应的输出。在大多数例子中， $0 \leq n_T \ll n_S$ 。

我们给出一个非统一的迁移学习的定义：

已知源领域 D_S 和学习任务 T_S ，目标领域 D_T 和学习任务 T_T ，迁移学习目标是使用 D_S 和 T_S 中的知识提高 D_T 中的目标预测函数 $f_T(\cdot)$ 的学习，这里 $D_S \neq D_T$ 或 $T_S \neq T_T$ 。