

上述四类迁移学习方法中，在深度学习算法中结合最多的是第三类基于参数的迁移，通过参数共享的方式大大提升深度模型的泛化能力，降低训练成本。目前业界将迁移学习应用到深度学习中的方式通常有如下三种：Pre-train+Finetuning、Freeze 和 Multi-task Learning。

Pre-train+Finetuning 的原理是先在基础数据集上预训练网络的结构和参数权重，同时将预训练好的网络结构迁移到目标数据集上，重新训练并微调参数的权重。这个方法比较适用于源领域和目标领域之间存在一定差异，并且目标领域具有足够的标签数据可以支持网络的重新训练的情况。当目标领域与源领域非常相近，同时目标领域中并没有太多数据的时候，我们应该更加相信预训练的模型，尽可能少地做调整，这就是 Freeze 的思想。通过冻结预训练网络的中间结构，仅是修改输出层的函数来满足目标领域的标签定义，我们可以快速得到一个新的模型，这里其实是变相地把预训练的模型看作一个特征提取的工具。

无论是 Pre-train+Finetuning 还是 Freeze，都是集中在单一领域中的单任务学习，还有一种多任务学习的方式，也可以实现迁移学习。在 Multi-task Learning 中，我们将源领域和目标领域的数据放在一起，通过共同的浅层网络进行训练，达到参数共享的目的。这种 Multi-task Learning 的方式对于深度学习模型确实行之有效，原因在于共同的浅层网络可以实现领域之间的信息互补，这样训练出来的模型泛化性能更好，解决了深度学习模型容易过拟合的问题。

迁移学习在风控和反欺诈场景中的应用还处在探索阶段，原因在于金融机构之间的信贷数据和模型无法互通，而金融机构内部各条业务线之间的客群又存在较大的分布差异，使得样本和特征层面的迁移难以实现。并且，由于风控行业的安全性要求，并不存在诸如图像识别领域中 ImageNet 这样标准化的公开数据，无法训练可以复用的大型网络结构来做 Fine tuning 或者 Freeze。Multi-task Learning 是目前迁移学习在风控领域可以尝试的方向，因为产品的额度和风险通常是相关的，可以将这两个任务共同训练，提取额度和风险之间的共同信息，同时构建定价模型和风控模型。