

不懂算法，如何投资医疗 AI! ?

——影像篇

报告日期：2020年4月6日

全球知名创投研究机构 CB Insights 发布的 2019 全球 AI 百强创业公司榜单“AI 100”中，有 6 家来自中国的 AI 公司，它们分别为：商汤、依图、第四范式、旷视、Momenta、地平线。同时，这 6 家公司的估值全部已经超过 10 亿美元，成为独角兽级别。



虽然 AI 人工智能概念由来已久，但近年来人工智能发展浪潮又一次席卷而来。

在众多应用领域中，AI 进入医疗领域备受关注，特别是医学影像、辅助诊断、药物研发、健康管理、疾病预测在内的五大应用领域。在这其中，国内借助医疗影像大数据及图像识别技术的发展优势，使得 AI 医学影像成为中国人工智能与医疗行业应用结合最成熟的领域。

在众多的医疗 AI 项目中，我们有时候会发现，头部的企业挤不进去，初创的企业又不敢投。既然这样，那我们只能从医疗 AI 最核心的东西——“AI 算法”研究起。当然，这并非决定企业未来发展的唯一因素，但是，也起了举足轻重的作用。

说起算法，近几年来，深度学习技术的大爆炸式发展，除了理论层面的突破，还有基础架构的突破，这些都奠定了深度学习繁荣发展的基础。但“大道至简”，再复杂的 AI 算法，也离不开最基本的算法原理。

1. 深度学习框架

这里我们首先介绍一些常见的深度学习框架。

1.1.Theano



Theano 是在 BSD 许可证下发布的一个开源项目，是由 LISA 集团（现 MILA）在加拿大魁北克的蒙特利尔大学开发的，其是以一位希腊数学家的名字命名的。

Theano 是一个 Python 库，可用于定义、优化和计算数学表达式，特别是多维数组。它的诞生是为了执行深度学习中的大规模神经网络算法，从本质上而言，Theano 可以被理解为一个数学表达式的编译器：用符号式语言定义程序员所需的结果，并且 Theano 可以高效地运行与 GPU 或 CPU 中。

在过去很长一段时间内，Theano 是深度学习开发与研究的行业标准。但 Theano 诞生于研究机构，服务于研究人员，其设计具有较浓厚的学术气息，在工程设计上有较大的缺陷。一直以来，Theano 因调试难、构图慢等缺点为人所诟病。随着 TensorFlow 在谷歌的支持下强势崛起，Theano 日渐式微，使用 Theano 的人也越来越少。这个转变的标志性事件是：Theano 的创始者之一 Ian Goodfellow 放弃 Theano 转而去谷歌开发 TensorFlow。

尽管 Theano 已逐渐退出历史舞台，但作为 Python 的第一个深度学习框架，它很好的完成了自己的使命，为深度学习研究人员的早期开荒提供了极大的帮助，同时也为之后的深度学习框架的开发奠定了基本的设计方向：以计算图为框架的核心，采用 GPU 加速计算。

1.2.TensorFlow



2015 年 11 月 10 日，谷歌宣布推出全新的机器学习开源工具 TensorFlow。TensorFlow 最初是由谷歌机器智能研究部门的 Google Brain 团队开发，基于 Google 2011 年开发的深度学习基础框架 DistBelief 构建起来的。TensorFlow 是广泛使用的实现机器学习以及其它涉及大量数学运算的算法库之一。谷歌几乎在所有应用程序中都使用 TensorFlow 来实现机器学习。

TensorFlow 在很大程度上可以看做是 Theano 的后继者，不仅因为它们有很大一批共同的开发者，而且还拥有相近的设计理念：它们都是基于计算图实现自动微分系统。TensorFlow 使用数据流图进行数值计算，图中的节点代表数学运算，而图中的边则代表这些节点之间传递的多维数组（tensor）。

TensorFlow 编程接口支持 Python 和 C++。随着 1.0 版本的公布，Java、Go、R 和 Haskell API 的 alpha 版本也被支持。此外，TensorFlow 还可在 Google Cloud 和 AWS 中运行。TensorFlow 还支持 Windows7、Windows10 和 Windows Server 2016。由于 TensorFlow 使用 C++ Eigen 库，所以库可在 ARM 架构上编译和优化。这也就意味着用户可以在各种服务器和移动设备上部署自己的训练模型，无需执行单独的模型解码器或者加载 Python 解释器。

由于谷歌在深度学习领域的巨大影响力和强大的推广能力，TensorFlow 一经推出就获得了极大的关注，虽不完美但是最流行，并迅速成为如今用户最多的深度学习框架。

1.3.MXNet



MXNet 是亚马逊的李沐带队开发的深度学习框架。它拥有类似于 Theano 和 TensorFlow 的数据流图，为多 GPU 架构提供了良好的配置，有着类似于 Lasagne 和 Blocks 的更高级别的模型构建块，可以运行在 CPU、GPU、集群、服务器、台式机或者移动设备上。对 Python 的支持只是其功能的冰山一角，MXNet 同样支持 C++、R、Scala、Julia、Golang、Matlab 及 JavaScript 等语言。

MXNet 以其超强的分布式支持，明显的内存、显存优化为人所称道。同样的模型，MXNet 往往占用更小的内存和显存，并且在分布式环境下，MXNet 展现出了明显优于其他框架的扩展性能。

MXNet 的缺点是推广不给力以及接口文档不够完善。MXNet 长期处于快速迭代的过程中，其文档却长时间未更新，导致新手用户难以掌握 MXNet，老用户常常需要查阅源码才能真正理解 MXNet 接口的用法。

1.4.Keras



Keras 是一个高层神经网络 API，由纯 Python 语言编写而成，并使用 TensorFlow、Theano 以及 CNTK 作为后端。Keras 为支持快速实验而生，能够把想法迅速转换为结果。Keras 应该是深度学习框架中最容易上手的一个，它提供了一致而简洁的 API，能够极大地减少一般应用下用户的工作量，避免用户重复造轮子，而且 Keras 支持无缝 CPU 和 GPU 的相互转换。

为了屏蔽后端的差异性，提供一致的用户接口，Keras 做了层层封装，导致用户在新增操作或是获取底层的数据信息时过于困难。同时，过度封装也使得 Keras 的程序过于缓慢，许多 Bug 都隐藏在封装之中。另外就是学习 Keras 十分容易，但是很快就会遇到瓶颈，因为它缺少灵活性。此外，在使用 Keras 的大多数时间里，用户主要是在调用接口，很难真正学到深度学习的内容。

1.5.Caffe/Caffe2



Caffe 的全称是 Convolutional Architecture for Fast Feature Embedding，它是一个清晰、高效的深度学习框架，核心语言是 C++，它支持命令行、Python 和 Matlab 接口，既可以在 CPU 上

运行，也可以在 GPU 上运行。

Caffe 的优点是简洁快速，缺点是缺少灵活性。不同于 Keras 因为太多的封装导致灵活性丧失，Caffe 灵活性的缺失主要是因为它的设计。在 Caffe 中最主要的抽象对象是层，每实现一个新的层，必须要利用 C++ 实现它的前向传播和反向传播代码，而如果想要新层运行在 GPU 上，还需要同时利用 CUDA 实现这一层的前向传播和反向传播。这种限制使得不熟悉 C++ 和 CUDA 的用户扩展 Caffe 十分困难。

Caffe 凭借其易用性、简洁明了的源码、出众的性能和快速的原型设计获取了众多用户，曾经占据深度学习领域的半壁江山。但是在深度学习新时代到来之时，Caffe 已经表现出明显的力不从心，诸多问题逐渐显现（包括灵活性缺少、扩展难、依赖众多环境难以配置、应用局限等）。尽管现在在 GitHub 上还能找到许多基于 Caffe 的项目，但是新的项目已经越来越少。

Caffe2 是一个兼具表现力、速度和模块性的开源深度学习框架。它沿袭了大量的 Caffe 设计，解决了多年在 Caffe 的使用和部署中发现的瓶颈问题。Caffe2 的设计追求轻量级，在保有扩展性和高性能的同时，Caffe2 也强调了便携性。Caffe2 从一开始就以性能、扩展、移动端部署作为主要设计目标。Caffe2 的核心 C++ 库能提供速度和便携性，而其 Python 和 C++ API 使用户可以轻松地在 Linux、Windows、iOS、Android，甚至 Raspberry Pi 和 NVIDIA Tegra 上进行原型设计、训练和部署。

Caffe2 继承了 Caffe 的优点，在速度上令人印象深刻。但 Caffe2 仍然是一个不太成熟的框架，安装比较麻烦，编译过程时经常出现异常。虽然 Caffe2 已经做了许多改进，但是还远未达到能完全替代 Caffe 的地步。

1.6.CNTK



2015 年 8 月，微软公司在 CodePlex 上宣布由微软研究院开发的计算网络工具集 CNTK 将开源。5 个月后，2016 年 1 月 25 日，微软公司在 GitHub 上正式开源了 CNTK。早在 2014 年，在微软公司内部，黄学东博士和他的团队正在对计算机能够理解语音的能力进行改进，但当时使用的工具显然拖慢了他们的进度。于是，一组志愿者组成的开发团队构想设计了他们自己的解决方案，最终诞生了 CNTK。

根据微软开发者描述，CNTK 的性能比 Caffe、Theano、TensorFlow 等主流工具都要强。CNTK 支持 CPU 和 GPU 模式，和 TensorFlow/Theano 一样，它把神经网络描述成一个计算图的结构，叶子节点代表输入或者网络参数，其他节点代表计算步骤。在 Microsoft 内部使用的目的而开发的，一开始甚至没有 Python 接口，而是使用了一种几乎没什么人用的语言开发的，而且文档有些晦涩难懂，推广明显不足，导致现在用户比较少。但就框架

本身的质量而言，CNTK 表现得比较均衡，没有明显的短板，并且在语音领域效果比较突出。

1.7.PyTorch



PyTorch 是一个 Python 优先的深度学习框架，能够在强大的 GPU 加速的基础上实现张量和动态神经网络。


2017 年 1 月，Facebook 人工智能研究院（FAIR）团队在 GitHub 上开源了 PyTorch。考虑到 Python 在计算科学领域的领先地位，以及其生态完整性和接口易用性，几乎任何框架都不可避免地要提供 Python 接口。而 PyTorch 不是简单地封装 Lua Torch 提供 Python 接口，而是对 Tensor 之上的所有模块进行了重构，并新增了最先进的自动求导系统，成为当下非常流行的动态图框架。

几乎所有的框架都是基于计算图的，而计算图又可以分为静态计算图和动态计算图，静态计算图先定义再运行（define and run），一次定义多次运行，而动态计算图是在运行过程中被定义的，在运行的时候构建（define by run），可以多次构建多次运行。PyTorch 和 TensorFlow 都是基于计算图的深度学习框架，PyTorch 使用的是动态图，而 TensorFlow 使用的是静态图。在 PyTorch 中每一次前向传播（每一次运行代码）都会创建一幅新的计算图，如下图所示。

A graph is created on the fly

```
x = torch.randn(1, 10)
prev_h = torch.randn(1, 20)
W_h = torch.randn(20, 20)
W_x = torch.randn(20, 10)

i2h = torch.mm(W_x, x.t())
h2h = torch.mm(W_h, prev_h.t())
next_h = i2h + h2h
```



静态图一旦创建就不能修改，而且静态图定义的时候，使用了特殊的语法，就像新学一门语言。这还意味着你无法使用 if、while、for-loop 等常用的 Python 语句。因此静态图框架不得不为这些操作专门设计语法，同时在构建图的时候必须把所有可能出现的情况都包含进去，这也导致了静态图过于庞大，可能占用过高的显存。动态图框架就没有这个问题，它可以使用 Python 的 if、while、for-loop 的等条件语句，最终创建的计算图取决于你执行的条件分支。

1.8.其他框架


除了上述的几个框架，还有不少框架，都有一定的影响力和用户。比如百度开源的 PaddlePaddle，CMU 开发的 DyNet，简洁无依赖符合 C++11 标准的 tiny-dnn，使用 Java 开发并且文档及其优秀的 DeepLearning4J，还有英特尔的 Habana(英特尔于 2020 年 3 月决定终止其先前的 Nervana 神经网络处理器的开发工作，转而将精力集中于 2019 年 12 月收购的 Habana 上)，Amazon 开

源的 DSSTNE。这些框架各有优缺点，但是大多流行度和关注度不够，或者局限于一定的领域。此外，还有许多专门针对移动设备开发的框架，如 CoreML、MDL，这些框架纯粹为部署而诞生，不具有通用性，也不适合作为研究工具。

2. 深度学习模型


2.1. 什么是神经网络?

神经网络包含了三个层次，分别是：输入层，隐藏层以及输出层。在神经网络中，神经元模型是一个包含输入、输出与计算功能的模型。输入可以类比神经元的树突，输出可以类比为神经元的轴突，而计算则可以类比为细胞核。



如下图所示，每个神经元有 n 个输入值，每个输入值有一个权重 (Weight) 值，把所有输入值乘权重值加总起来，有时会另外加上一个偏置值 (Bias) 来调整，将得到的值再经过一个激活函数 (Activation function) 即可产生新的输出值。从另一个角度

来看,相当于每个权重值决定对应的输入值对这个神经元的影响程度。



由左至右为推论 (Inference), 可得到算输出结果, 过程中需要 n 个权重值加上 1 个偏置值, 而这些值是需要经由训练 (Training) 而得。训练前须取得许多 (越多越好) 已知答案或称为标签 (Label) 的训练数据, 假设输出值只有二种答案, 是 (1.0) 或者不是 (0.0)。


如果第一组输入数据已知答案为是 (1.0), 但经过推论后只得到 0.6, 则表示权重及偏置值不理想需要调整, 此时利用根据差值 ($1.0 - 0.6 = 0.4$) 由右至左调整每个权重及偏置值, 而至于调多少则随不同方式也有不同。

同样的步骤再输入第二组数据进行调整, 直到所有训练数据都做过一轮 (Epoch)。此时, 大家可能会问这样就训练好了吗? 我们还得拿出另一组未曾出现在训练资料中, 但却已知答案的数据来进行验证, 就如同学校老师教了许多内容, 但要透过考试成


绩才能知道学生是否学会了，如果分数不及格，就要重新训练加强磨练。

相同地，我们必须反复执行这些步骤直到验证数据都得到满意的答案，因此，可想而知所需来回的次数相当大，所以通常训练会需要设计什么时候停止，可选择成绩（正确率）到达某个门坎，或者不管成绩只考虑训练次数。这就好比学校的模拟考，虽然学生每次都考高分，但真正考试时成绩仍不理想，此时就得增加学习样本重新训练。

为了能处理更复杂的问题，一个神经元可扩展成一组简单（单层）神经网络，如下图所示，有输入层、隐藏层（Hidden Layer）及输出层，推论及训练的概念和一个神经元大致相同。




若待解决问题更困难，如下图所示，则可增加每一层的神经元或隐藏层数来解决。



了解了什么是神经网络之后，我们介绍两个较著名的模型，包括非时序性的卷积神经网络（CNN）LeNet-5 以及时序性的递归神经网络（RNN），方便说明模型中常用到的元素与流程，如何用深度学习框架来表示。

2.2.卷积神经网络（CNN）

下图为最知名的卷积神经网络 LeNet-5，主要是用来辨识手写数字（MNIST 数据库），输入为一张 8bit 灰阶 32×32 像素的影像，而输出为十个节点，分别表示影像为十个数字的机率，这个模型几乎是所有研究深度学习的入门起手式。目前先不解释这个模型为何能学会辨识图像，而是单纯就模型组成以及表示方法来进行说明。



首先，说明卷积特征图 C1 层，C1 层上的红点，是由输入层（INPUT）红色框（ 5×5 个像素）乘上 5×5 的卷积核加总而后得，依序由输入影像的左至右、上至下共享一个卷积核进行卷积，一次移动一个像素（Stride = 1），如此即可产生一张特征图，而 C1 层共享了六组卷积核，因此产生六张 28×28 像素的特征图。再来将影像进行池化，较常见的方式就是把相邻四点（如图一绿色框所示）中最大的点当成新点，称为 Max Pooling，同时把影像长宽都减为一半，成为 S2 层。

接下来，对 S2 层以 16 组 3×3 卷积核进行卷积，产生 C3 层，共有 16 组 10×10 像素的特征图。同样地再对 C3 层进行池化产生 S4 层，变成 16 组 5×5 像素的特征图，最后再以 16 组 5×5 卷积核把 S4 层的 16 个特征图卷积变成 16 个输入点，再以传统全链接神经网络进行链接。C5 层就是以 16 个输入点和隐藏层 120 点进行全连结，并依指定的激活函数将输出传到下一层，

接下来再和下一组隐藏层 F6 的 84 点进行全连结，最后再和输出层 (OUTPUT) 的十个输出点进行全连结，并正规化输出得到各输出的机率，即完成整个 LeNet-5 模型 (网络) 结构。


综合上述内容可得知一个基本的卷积神经网络会有输入层、卷积层、池化层、全连结层及输出层。卷积层要定义卷积核大小、移动距离、输出特征图数量。而池化层同样需要定义核的大小 (一般是 2×2)、移动距离 (一般是 2) 及池化方式 (可以是取最大值或平均值)。全连结层部份则需要定义节点数量及激活函数类型 (如: reLu、sigmoid 等)，最后输出层除了要定义正规化机率值 (如: Softmax) 外，还要定义损失函数以作为训练模型用。

前面提到的卷积神经网络 CNN 是一种前馈 (Forward) 的单向网络，其输出结果不会影响输入，但如果遇到如语音、翻译、视频这类时序问题时，CNN 就搞不定了，此时就该轮到递归神经网络 (RNN) 登场了。

2.3.递归神经网络 (RNN)

下图所示就是 RNN 最基本入门的模型，把此次输出的结果经过加权后，再和下一次的输入一起计算出下一次的输出，以串起输入数据的时序关连。从展开图可更清楚看出其关连，当前输出 (ot) 是由目前状态 (st) 乘上权重 (U) 加上前一状态 (st-1) 输出乘上权重 (W) 后，经过双曲正切 (tanh) 函数并乘上输出权重 (V)，最后取 Softmax 算式得出，依此类推可展开成任意

级数的网络。




RNN 可以有很多种输出型态，一对一就等于单纯的前馈网络没有时序关系，另外也可以一对多、多对一、多对多等不同的输出方式，应用于时序性内容分类，例如语句情绪意图、音乐曲风、视频动作分析、影像加注标题等，或是型态移转（Style Transfer），例如语言翻译、文章音乐创作等。

对 RNN 而言，需要定义展开的级数、隐含层（或称为状态 S）到隐含层权重矩阵（W）、输入层到隐含层权重（U）、隐含层到输出层权重（V）、激活函数（例如：tanh 等）类型，以及输出层机率正规化方式（例如：Softmax 等）。

2.4. 其它

为了解决各种不同问题，于是各种不同的网络（Net）结构或模型（Model）被提出。从下图中可看出，横轴是计算量，每个乘法或加法就算一次运算（Operations, Ops），不同算法从数千万次到数百亿次的计算才能推论一笔数据，通常计算量和参数量

(圆圈直径) 有直接关系，参数量可能从数百万到数亿个。不过正确率和参数量及计算量则不一定有直接关连,对实际使用上来说当然希望找到计算量越低、正确率越高的模型，而正是 AI 科学家及工程师努力的方向。



3. 图像分类之 KNN 算法原理


3.1. 什么是 KNN 算法?

KNN 算法也称 K-最近邻算法 (k-NearestNeighbor, KNN), 是一种最简单的图像分类算法。KNN 算法的思想非常简单，其涉及的数学原理知识也很简单。


KNN 算法的核心思想是如果一个样本在特征空间中的 k 个最相邻的样本中的大多数属于某一个类别,则该样本也属于这个类别，并具有这个类别上样本的特性。该方法在确定分类决策上

只依据最邻近的一个或者几个样本的类别来决定待分样本所属的类别。KNN 方法在类别决策时, 只与极少量的相邻样本有关。由于 KNN 方法主要靠周围有限的邻近的样本, 而不是靠判别类域的方法来确定所属类别的, 因此对于类域的交叉或重叠较多的待分样本集来说, KNN 方法较其他方法更为适合。

换句话说, KNN 的原理就是当预测一个新的值 x 的时候, 根据它距离最近的 K 个点是什么类别来判断 x 属于哪个类别。如下图所示:



图中绿色的点就是我们要预测的那个点, 假设 $K=3$ 。那么 KNN 算法就会找到与它距离最近的三个点 (这里用圆圈把它圈起来了), 看看哪种类别多一些, 比如这个例子中是蓝色三角形多一些, 新来的绿色点就归类到蓝三角了。



但是，当 $K=5$ 的时候，判定就变成不一样了。这次变成红圆多一些，所以新来的绿点被归类成红圆。从这个例子中，我们就能看得出 K 的取值是很重要的。

3.2. 距离选择

要度量空间中点距离的话，有好几种度量方式，比如常见的曼哈顿距离计算，欧式距离计算等等。不过通常 KNN 算法中使用的是欧式距离，这里只是简单说一下，拿二维平面为例，二维空间两个点的欧式距离计算公式如下：

$$\rho = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

这个公示其实早就有接触到了，就是计算 (x_1, y_1) 和 (x_2, y_2) 的距离。拓展到多维空间，则公式变成这样：

$$d(x, y) := \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}.$$


这样我们就明白了如何计算距离，KNN 算法最简单的就是将预测点与所有点距离进行计算，然后保存并排序，选出前面 K

个值看看哪些类别比较多。但其实也可以通过一些数据结构来辅助，比如最大堆，这里就不再延伸。

3.3.K 值选择

通过上面那张图我们知道 K 的取值比较重要，那么该如何确定 K 取多少值好呢？最好的办法是通过交叉验证（将样本数据按照一定比例，拆分成训练用的数据和验证用的数据，比如 6:4 拆分成部分训练数据和验证数据），从选取一个较小的 K 值开始，不断增加 K 的值，然后计算验证集合的方差，最终找到一个比较合适的 K 值。

通过交叉验证计算方差后我们大致会得到下面这样的图：



这个图其实很好理解，当你增大 k 的时候，一般错误率会先降低，因为有周围更多的样本可以借鉴了，分类效果会变好。但当 K 值更大的时候，错误率会更高。这也很好理解，比如说你一共就 35 个样本，当你 K 增大到 30 的时候，KNN 基本上就没

意义了。

所以选择 K 点的时候可以选择一个较大的临界 K 点，当它继续增大或减小的时候，错误率都会上升，比如图中的 K=10。

3.4.KNN 算法特点

KNN 是一种非参的，惰性的算法模型。那什么是非参，什么是惰性呢？

非参的意思并不是说这个算法不需要参数，而是意味着这个模型不会对数据做出任何的假设，与之相对的是线性回归（我们总会假设线性回归是一条直线）。也就是说 KNN 建立的模型结构是根据数据来决定的，这也比较符合现实的情况，毕竟在现实中的情况往往与理论上的假设是不相符的。

惰性又是什么意思呢？想想看，同样是分类算法，逻辑回归需要先对数据进行大量训练（training），最后才会得到一个算法模型。而 KNN 算法却不需要，它没有明确的训练数据的过程，或者说这个过程很快。

3.5.KNN 算法的优势和劣势

KNN 算法优点


- 1、简单易用，相比其他算法，KNN 算是比较简洁明了的算法。即使没有很高的数学基础也能搞清楚它的原理。
- 2、模型训练时间快，上面说到 KNN 算法是惰性的。
- 3、预测效果好。

4、对异常值不敏感

KNN 算法缺点

- 1、对内存要求较高，因为该算法存储了所有训练数据。
- 2、预测阶段可能很慢。
- 3、对不相关的功能和数据规模敏感。

至于什么时候应该选择使用 KNN 算法，可以参考下图。简单来说，当需要使用图像分类算法，且数据比较大的时候就可以尝试使用 KNN 算法进行分类了。



4. AI 企业发展现状

我们随机选取了几家具有代表性的 AI 企业，简单介绍一下其发展情况。

4.1. 第四范式



第四范式成立于 2014 年底，是国际领先的人工智能平台与技术服务提供商。依托于领先的机器学习技术与丰富的行业实践经验，第四范式打造了企业智能化转型战略产品“天枢”，通过构建以消费者为中心的全链路客户流量运营，帮助企业实现以创造业务价值为目标的智能化转型。

第四范式从金融、互联网等领域进入到更多垂直化产业中，实现了包括医疗、媒体、零售、政府、能源等在内的多领域落地突破，完成超过 2000 个 AI 应用案例。除了继续在金融领域深耕外，以医疗领域为例，第四范式与上海瑞金医院合作的“瑞金知糖”系列项目已经在 30 多个省市的 400 多家医院投入使用。

2020 年 4 月 2 日，第四范式宣布完成 C+轮融资，C 轮总计融资金额达 2.3 亿美元，投后估值约 20 亿美元。本轮融资中，引入新战略股东包括思科、中信银行、联想，松禾资本、基石资本以财务投资方加入。本轮融资的完成，为第四范式快速拓展产业链上下游资源奠定良好基础，有助于构建基于 AI 的企业级服务生态体系。

第四范式融资历程：

序号	披露日期	交易金额	融资轮次	估值	投资方
1	2020年4月2日	2.3亿美元	C+轮	约20亿美元	思科
					中信银行
					联想创投
					松禾资本
2	2019年4月28日	未披露	股权融资	未披露	基石资本
					中互金投
					金石投资
3	2018年12月19日	超10亿人民币	C轮	12亿美元	越秀产业基金
					国新基金
					荷塘创投
					保利资本
					三峡鑫泰
					中信证券
					中国农业银行
					交通银行
4	2018年1月27日	未披露	B+轮	未披露	红杉资本中国
					工商银行
					中国银行
					建设银行
5	2017年12月19日	未披露	B轮	未披露	融泽通远
					光控众盈资本
					昊翔资本
					领飒资本
					元生资本
6	2017年12月19日	未披露	股权融资	未披露	众为资本
7	2016年11月28日	未披露	A轮	未披露	国新启迪基金
					峰尚资本
					红杉资本中国
8	2015年10月16日	未披露	天使轮	未披露	创新工场
					红杉资本中国
					金石投资

4.2. 依图科技



2020 年 3 月 19 日，“依图科技”公布完成 3000 万美元的新一轮融资，投资方为华润资本与诚通香港共同发起设立的“润诚产业领航基金”。

依图科技是一家完全基于自主研发技术成长起来的世界级人工智能企业，系国家新一代人工智能开发创新平台和上海市医疗图像与医学知识图谱人工智能重点实验室建设单位；利用计算机视觉、自然语言学习、语音识别和芯片设计开发等软硬件技术，提供各应用场景下的综合人工智能解决方案。作为人工智能领域创新的先驱之一，依图将先进的人工智能技术与公共安全、医疗保健、金融、零售和芯片开发行业的工业应用相结合。

其“新冠肺炎智能评价系统”是业内首款智能评估新型冠状病毒性肺炎的 AI 影像产品。采用创新的人工智能全肺定量分析技术，为临床专家提供基于 CT 影像的智能化新型冠状病毒性病灶定量分析及疗效评价等服务。系统可在 2-3 秒之内完成分析，极大提升了医生诊断效率，已在武汉协和医院、武汉大学中南医院、武汉大学人民医院、荆州市第一人民医院等几十家公共医疗机构完成部署。

依图科技融资历程：

序号	披露日期	交易金额	融资轮次	估值	投资方
1	2020年3月20日	3000万美元	战略融资	未披露	润诚产业领航基金
2	2019年5月6日	未披露	战略融资	未披露	上海科创基金
					联新资本
					高榕资本
3	2018年7月16日	1亿美元	战略融资	150亿人民币	兴业资管
4	2018年6月12日	2亿美元	C+轮	未披露	高成资本
					工银国际
					浦银国际
5	2017年5月15日	3.8亿人民币	C轮	未披露	高瓴资本
					云锋基金
					红杉资本中国
					高榕资本
					真格基金
6	2016年6月3日	数千万美元	B轮	未披露	云锋基金
7	2014年11月1日	数百万美元	A轮	未披露	红杉资本中国
					高榕资本
8	2012年9月1日	100万美元	天使轮	未披露	真格基金

4.3. 推想科技



推想科技是一家全球领先的人工智能医疗创新高科技企业，利用深度学习技术，发展包括 AI 部署管理平台、AI 大数据挖掘科研平台以及 AI 临床应用平台在内的医疗 AI 全流程平台，打造医疗质控、健康管理以及科研创新等医疗 AI 产品，切实为政府、医疗机构、医生、患者提供先进性、智慧化、系统化的服务。

推想科技的执行点已经覆盖全国 33 个省级行政区。拓展中国医疗市场的同时，推想科技完成了北美、亚太以及欧洲的战略布局，推想医疗 AI 服务已覆盖全球 10 个国家。

2018 年 12 月，推想科技宣布完成最新 C1 轮融资，由鼎晖资本领投，海通开元、红杉资本、襄禾资本、鸿为尚城、元生以及泰合资本六家联合跟投。

推想科技融资历程：

序号	披露日期	交易金额	融资轮次	估值	投资方
1	2018年12月7日	未披露	C轮	未披露	鼎晖百孚
					海通开元
					红杉资本中国
					襄禾资本
					尚城资本
					元生资本以及泰合资本
2	2018年6月19日	未披露	股权融资	未披露	百川汇达投资
3	2018年2月28日	3亿人民币	B轮	未披露	启明创投
					元生资本
					红杉资本中国
					尚城资本
					泰合资本
					襄禾资本
4	2017年1月18日	5000万人民币	A轮	未披露	红杉资本中国
					广发信德
					英诺天使基金
					臻云创投
					启明创投
5	2016年6月13日	1250万人民币	天使轮	未披露	英诺天使基金
					臻云创投
					快的打车吕传伟个人

4.4. 汇医慧影



汇医慧影成立于 2015 年，总部位于北京，在美国硅谷、香港、苏州、广州设有分公司，据汇医慧影创始人兼 CEO 柴象飞介绍，公司现已形成了从科研到临床的多条产品线，涉及筛查、

诊断、治疗各个方面，覆盖病种包括胸部 CT 防漏诊断、乳腺钼靶检测、脑梗、骨折、脑出血核磁分析及 10 多项常见癌症等。

另外，汇医慧影现已在单病种上实现了智能筛查、智能决策、预后预测、随访的全流程覆盖，形成了多模态和全影像数据链，对应的落地产品包括主动脉夹层人工智能研究平台和人工智能乳腺全周期健康管理系统（与英特尔共同开发）。据悉，前者是全球首个 B 型主动脉夹层自动分割方法。

2018 年 11 月，汇医慧影宣布获得英特尔投资和芯动能投资的战略投资，成为这两家基金在中国投资的首家医疗 AI 企业。公司表示，这笔资金将主要用于公司业务发展、产品创新和团队扩张。

汇医慧影融资历程：

序号	披露日期	交易金额	融资轮次	估值	投资方
1	2018年11月7日	未披露	战略融资	未披露	Intel Capital
					芯动能投资
2	2018年1月8日	数千万人民币	C轮	未披露	鼎晖投资
					蓝驰创投
3	2017年10月25日	数亿人民币	B轮	未披露	达泰资本
					蓝驰创投
4	2016年10月27日	数千万人民币	A轮	未披露	蓝驰创投
5	2015年12月3日	500万人民币	天使轮	未披露	水木易德投资

4.5.深睿医疗



深睿医疗，前身是北大信科学院人工智能实验室项目，2017

年转化成实体公司，总部位于北京中关村高科技核心地区，通过人工智能“深度学习”技术及自主研发的核心算法，为各类医疗服务机构提供基于人工智能和互联网医疗的解决方案。成立至今，深睿医疗已经将其人工智能的产品落地到 400 多家医院。

成立两年多的深睿，已经推出了肿瘤、乳腺、儿童生长发育、卒中、胸片、影像云和多模态科研平台等 7 条 AI 相关产品线。

对于产品的拓展逻辑，深睿主要将人工智能产品切入了各类中国发病率较高、医生临床所需的病种。其中，深睿的肺结节筛查与乳腺钼靶两款产品，分别对应了肺癌和乳腺癌这两项人类第一大癌，肺癌更是世界以及我国发病率最高、死亡率也最高的癌症，早诊断早治疗能够显著降低死亡率。而儿童生长发育 AI 评估系统、脑卒中 AI 医学辅助诊断系统以及胸部平片 AI 医学辅助诊断系统三款产品可广泛应用于脑卒中辅助诊断、儿童生长发育评估、胸部疾病筛查等各个方面，通过深度学习技术和深睿研究院的核心算法为临床进一步检查提供各种可能，助力医生提高诊断精度和效率。

2019 年 6 月 10 日，深睿医疗宣布完成 C 轮融资，本轮融资由阳光保险集团战略领投，昌发展、丝路华创和山蓝资本跟投。

深睿医疗融资历程：

序号	披露日期	交易金额	融资轮次	估值	投资方
1	2019年6月10日	数亿人民币	C轮	未披露	阳光保险
					昌发展
					丝路华创
					山蓝资本
					君联资本
					昆仲资本
					联想之星
					道彤投资
					同渡资本
2	2018年4月2日	1.5亿人民币	B轮	未披露	君联资本
					联想控股
					丹华资本
					昆仲资本
					同渡资本
					道彤投资
					弘道资本
3	2017年11月13日	1.15亿人民币	A+轮	未披露	丹华资本
					道彤投资
					同渡资本
					弘道资本
					昆仲资本
					风和投资
4	2017年8月18日	3500万人民币	A轮	未披露	昆仲资本
					洪泰基金
					风和投资

5. 小结

很多时候，当我们开始动用资源投资 AI 相关项目的时候，其实我们也明白，就现阶段而言，技术和模式除了一部特定环境下（如医疗领域）的辅助识别类型以外，大部分的 AI 项目从某种程度上来说并无太大用处。但我们之所以要了解技术，不是为了这些，而是为了技术给人性当挡箭牌，为了背后的那一个“确定性”。看项目久了，我们总会遇见形形色色的人，光怪陆离的

故事，和在利益面前的一切。有时，当看到有些资本方或项目方夸夸其谈的时候，我们或许会想问一句：你们是真信了还是演戏就能演成这样？

或许，未来，在 AI 的不断发展下，我们会开始慢慢远离传统的数据+仿真的模型，发展出一种新型的 AI 模型。在这种模型中，数据再也不是仿真和记录的作用，而是代表了一种社会行为。我们所处的时代开始脱离传统的社会，形成独特的体系，即虚拟社会体系。

在这种体系下，人性被无限放大。所谓没有温度的科学是没有意义的。借用 TOMsInsight 的一句话，长远看，我们都在暗沟里，但仍有人仰望星空。

（完）

参考资料：

- 1、中国日报网：CB Insights 发布 AI 100 报告
- 2、上海交大：《人工智能医疗白皮书》
- 3、ChinaIT：《深度学习，从「框架」开始学起》
- 4、CSDN：人工智能 AI 与 Maker 创意接轨
- 5、CSDN：深入浅出 KNN 算法原理
- 7、张修鹏：《深度学习与图像识别》
- 8、TOMsInsight
- 9、天眼查

免责声明

免责声明

本报告仅供智银资本（以下简称“本公司”）的客户使用。本公司不会因接收人收到本报告而视其为客户。

本报告是基于本公司认为可靠的已公开信息，但本公司不保证该等信息的准确性或完整性。本报告所载的资料、工具、意见及推测只提供给客户作参考之用，并非作为或被视为出售或购买证券或其他投资标的的邀请或向人作出邀请。

客户应当认识到有关本报告的相关推荐等只是研究观点的简要沟通，需以本公司 <http://www.sz-zhiyin.com/> 网站刊载的完整报告为准。

本报告所载的资料、意见及推测仅反映本公司于发布本报告当日的判断，本报告所指的证券或投资标的的价格、价值及投资收入可能会波动。在不同时期，本公司可发出与本报告所载资料、意见及推测不一致的报告。

客户应当考虑到本公司可能存在可能影响本报告客观性的利益冲突，不应视本报告为作出投资决策的惟一因素。本报告中所指的投资及服务可能不适合个别客户，不构成客户私人咨询建议。本公司未确保本报告充分考虑到个别客户特殊的投资目标、财务状况或需要。本公司建议客户应考虑本报告的任何意见或建议是否符合其特定状况，以及（若有必要）咨询独立投资顾问。

在任何情况下，本报告中的信息或所表述的意见并不构成对任何人的投资建议。在任何情况下，本公司不对任何人因使用本报告中的任何内容所引致的任何损失负任何责任。

若本报告的接收人非本公司的客户，应在基于本报告作出任何投资决定或就本报告要求任何解释前咨询独立投资顾问。

本报告的版权归本公司所有。本公司对本报告保留一切权利。除非另有书面显示，否则本报告中的所有材料的版权均属本公司。未经本公司事先书面授权，本报告的任何部分均不得以任何方式制作任何形式的拷贝、复印件或复制品，或再次分发给任何其他人，或以任何侵犯本公司版权的其他方式使用。所有本报告中使用的商标、服务标记及标记均为本公司的商标、服务标记及标记。