

张胜东

- 性别: 男
- 出生年月: 1991.11
- 学历: 硕士研究生
- QQ: 435878393
- 手机: 13912998528
- Email: 435878393@qq.com
- 个人主页: <https://www.zhangshengdong.com>
- Github: <https://github.com/zhangsheng377>

教育经历

江苏省南京市金陵中学 2007.9-2010.7

长春理工大学光电信息学院本科 2010.9-2014.7

- 物理系,光学专业
- 获奖情况:

2010-2011 学年 一等奖学金
2011-2012 学年 一等奖学金
2012-2013 学年 一等奖学金
2013-2014 学年 国家奖学金
校级 和 院级 优秀毕业论文

- 获证书情况:

全国蓝桥杯软件大赛全国总决赛 二等奖
全国大学生数学建模竞赛吉林赛区 二等奖
吉林省程序设计大赛(acm) 一等奖
吉林省电子设计大赛 二等奖
全国信息技术考试数据库工程师认证
全国计算机四级数据库工程师

南京邮电大学研究生 2015.9-2018.7

- 计算机技术专业

- 获奖情况:

凯易讯软件大赛全国总决赛 第 25 名

中兴软件编程大赛 决赛

黑马大赛全国总决赛 第 2 名

全国物联网设计竞赛 二等奖

- 主要项目:

- i. **卫星鉴权高并发服务器和客户端:**

使用了 **epoll, fork, socket, pipe, 命名管道 FIFO** 等的服务器和客户端程序, 功能是串口连接北邮的网关设备进行控制, 同时接收用户的信息, 若是登录信息就进行鉴权, 鉴权通过就将此端口转发规则写入网关设备, 同时还涉及到信道分配, 流量管理, 加解密通讯等。

- ii. **大气质量监测及预测系统:**

树莓派开 **gpio** 读取传感器并上传云端, 同时有触屏显示界面; 跨平台客户端从云端读取数据, 并作 3d 显示; 用 **php** 写的微信公众号服务器程序, 支持查询、订阅和报警; **用 Python 写了机器学习的线性回归和在线学习, 来预测第二天的空气质量。**

- iii. **水产品监控及直播系统:**

与中科院南京软件研究所合作, 使用单片机连接摄像头采集视频信号, 使用 **EasyDarwin** 推送视频流, 使用拉流技术建立起流媒体管理云平台, 从而实现一对多的直播效果, 类似于现在的直播软件。

- iv. **黑马大赛: 商品类目预测:**

题目: 只给商品标题和已有分类, 测试集中可能需要分到新的类。

方案: 使用 **多线程jieba分词** 得到商品标题的分词向量, 然后手撸的朴素贝叶斯算法, 同时做了一些修改: **当一个词在某个类中出现的频率低于所设阈值时, 则将该词在这类的权重置为 0, 以此来避免大众词汇对于分类的干扰, 提升小样本类别的识别率;** 并且当分类得分低于阈值时, 则新建分类, 并更新矩阵。

- v. **利用视频关键帧预测中间帧:**

教研室项目: 视频传输时只传关键帧, 中间的补帧利用机器学习预测出。具体是将画面分割成许多 8*8 的小块, 将每一块丢进神经网络计算运动向量, 再将结果平滑, 得到运动轨迹, 从而生成中间帧。最后, 提供训练好的模型和供 **c++** 调用的 **python** 的接口给下游。

- vi. **盲人导盲项目:**

单板机放置于盲人帽子上, 实时语音识别出口令后, 调用摄像头拍照, 开启控制信令 **socket** 与服务器建立会话, 然后建立数据 **socket**, 将压缩后的图片发送给服务器(**图片压缩后可以降低图片中杂项的干扰, 提高对于主体的识别率**)。服务器使用 **yolo** 进行物体识别, 对于主要物体的方位和距离进行估算, 将结果以 **json** 格式返回给单板机。单板机接收到识别结果后, 语音合成内容, 播报出来。

工作经历

华为 数据通信网络协议开发部 2018.7-2020.5

- **主要项目：**

- i. **独立设计 Trunk 软件选口算法**，使用分层的 avl 管理端口资源，使板级异常的主备切换耗时从原来的几百毫秒，降低至几毫秒。
- ii. **使用 bitmap 设计并完成网络协议的动态唯一标签申请及分配模块。**
- iii. 对开源代码 sprintf 进行整改，成功对 va_list 底层异构所导致的异常进行定位，并做出应对方案。
- iv. **成为代码 committer，负责部门代码微重构**，及代码review，并指导新员工编程；
- v. **被选拔进入软件学院进修，并成为部门第一个通过软件认证考试的人；**
- vi. 日常分享技术总结，并在内网发博客 10 余篇，累计 UV 阅读量 3000 多人。

- **个人项目：**

- i. 参加 科赛Kesci 的「二分类算法」提供银行精准营销解决方案 比赛，**取得全球100+名次**，获得一张100美元AWS代金券。

华为 消费者云服务HiCloud开发部 2020.5-2021.9

在浏览器算法团队，负责NLP模型和搜索直达的排序模型。

- **主要项目：**

- i. 优质文章模型（浏览器每日精选栏目）：经bert得文章embedding(即文章的语义信息)，再拼接上文章的结构信息（段落、字数、图片数、来源、作者等，经过embedding和标准化），接上双塔网络，判断文章优质与否，以及属于哪个优质类别。
- ii. 层次文章分类模型：根据各层次分类之间天然的关联性，同时学习多个label，设计多任务的 Bert模型（将一级分类网络的最后一级输出，拼上之前bert输出的embedding，再进二级分类网络，以此类推），在学习阶段就即可自动进行层次分类校准。并且，在推断时，可以获取各层分类类别的概率，采用beam search，进行有限度的扩展搜索。
- iii. 搜索直达功能的排序模型：打通FTRL模型上线，在产品诞生之初快速赋能；后切换到DCN模型，自动进行特征交叉；现转向ESMM模型，多任务，同时训练 CTR 和 CVR 指标，以期真正提升 CTCVR 业务指标。
- iv. 同时做过 文章地域模型、时效模型、负面文章模型、友商吹捧文章模型等，主管NLP领域的分类模型。

- **个人项目：**

- i. 编写股票监控平台。采用docker部署爬虫模块、量化指标算法模块、订阅分发模块等，各模块之间使用rabbitmq和redis，以及mongodb连接。爬虫模块爬取股票数据存入通用数据库接口 (mongodb)，并缓存至redis；算法模块监控rabbitmq，从而处理数据并将报警信息存入redis；订阅分发模块监控到有报警信息后主动向微信订阅用户推送；同时部署有微信服务器，完成与微信用户的交互。https://www.zhangshengdong.com/post/monitor_stock_system/

华为 NAIE AI模型与训练服务部 2021.9-至今

在用户体验团队，承担算法SE（架构师）角色，负责设计与实现电信领域用户体验相关模型。

• 主要项目：


- i. 基站信号仿真大模型：输入地形各图层数据及基站位置等参数，输出地图各处基站信号强度。模型结构借鉴cv领域双流网络思想，采用白盒（可微电磁传播公式）和黑盒（大规模卷积网络）双流的思路。
- ii. 大规模表格类数据无监督训练框架：针对电信领域数据基本为表格类无标签数据的特点，结合巧妙地特征工程，设计了以锚点和先验概率分布为约束的无监督训练框架。可直接利用无标签数据进行训练，给出用户的体验打分，同时支持小批量有标签样本（数据不出局点）的在线调优。
- iii. 神经网络关于特征的模型自解释方法：利用模型对于特征的梯度，结合巧妙地特征工程构造出的背景样本和MSE Loss，即可计算出各用户特征输入关于模型打分结果的影响度。

晟腾特战队：

• 主要项目：

- i. 负责开源项目大模型加速库 <https://gitee.com/ascend/AscendSpeed> 的调优部分，并成为该项目的committer。主要是带领团队进行大模型训练和调优方面的特性开发，并支撑客户训练大模型。多次向Megatron-LM、Megatron-DeepSpeed和PEFT库贡献代码。
- ii. 向PEFT开源社区贡献了一个关键独立特性：分布式LoRA

<https://github.com/huggingface/peft/pull/1092> 已经在peft0.7.0版本发布：



huggingface / peft

Releases / v0.7.0

v0.7.0: Orthogonal Fine-Tuning, Megatron support, better initialization, safetensors, and more

BenjaminBossan released this last week · 17 commits to main since this release · v0.7.0 · 2665f88

Highlights

- Orthogonal Fine-Tuning (OFT): A new adapter that is similar to LoRA and shows a lot of promise for Stable Diffusion, especially with regard to controllability and compositionality. Give it a try! By [@okotaku](#) in [#1160](#)
- Support for parallel linear LoRA layers using Megatron. This should lead to a speed up when using LoRA with Megatron. By [@zhangsheng377](#) in [#1092](#)
- LoftQ provides a new method to [initialize LoRA layers](#) of quantized models. The big advantage is that the LoRA layer weights are chosen in a way to minimize the quantization error, as described here: <https://arxiv.org/abs/2310.08659>. By [@yxli2123](#) in [#1150](#).

Significant community contributions

The following contributors have made significant changes to the library over the last release:

[@zhangsheng377](#)

- Parallel linear Lora by [@zhangsheng377](#) in [#1092](#)
- Fix parallel linear lora by [@zhangsheng377](#) in [#1202](#)

<https://github.com/huggingface/peft/releases/tag/v0.7.0>

iii. 向Accelerate开源社区贡献了一个关键独立特性：支持nvidia官方megatron的MegatronLMPlugin <https://github.com/huggingface/accelerate/pull/2501> 已经在accelerate0.31.0版本发布：



<https://github.com/huggingface/accelerate/releases/tag/v0.31.0>

[pdf版简历](#)

本科时期的旧博客: <http://zhangshengdong29.lofter.com/view>