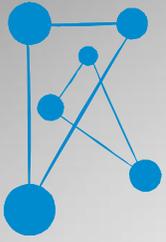




打造数据中央厨房 助力大数据创业

上海长江时代众创空间数字技术有限公司
孙繁荣



引言

□ 大数据为新财富，价值堪比石油

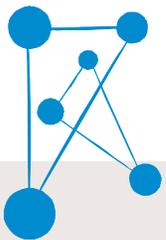
——世界经济论坛报告

□ 数据列入企业资产负债表只是时间问题

——维克托

□ 一个组织如果没有认识到管理数据和信息如同管理有形资产一样
极其重要，那么他在新经济时代将无法生存

——汤姆·彼得斯

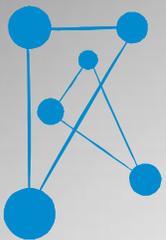


数据创业维艰：从零到一



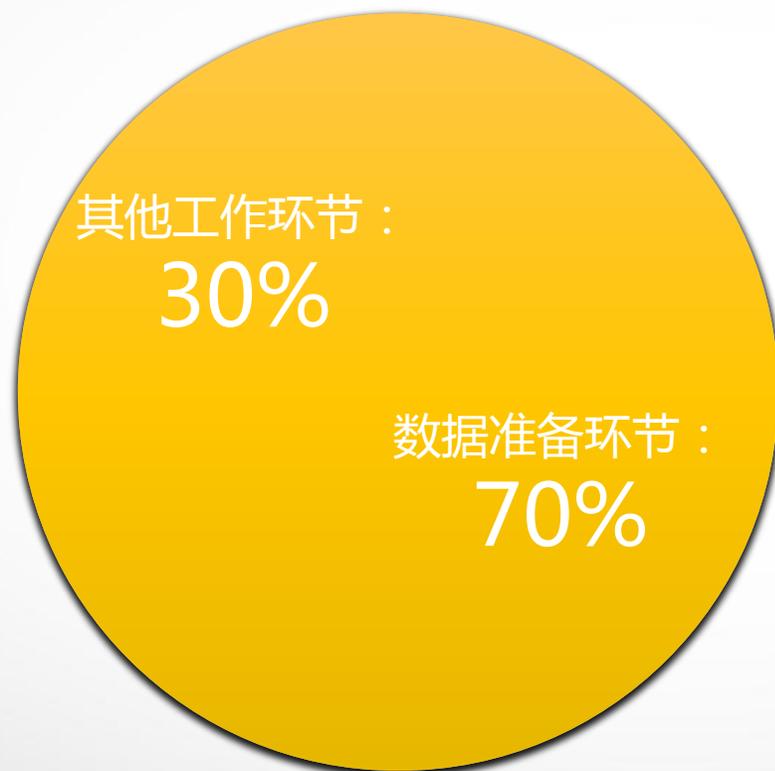
创业公司往往面临着招人难、融资难、推广难等等各种困境。

在瞬息万变的移动互联网领域，创业公司要想在巨头的夹缝中求生存，
高效的产品研发能力和快速更新迭代，才是生存与发展的关键。



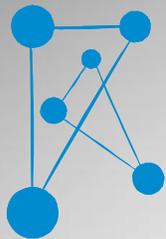
聚焦产品创新

据统计：一个数据分析项目中，数据获取，数据清洗等准备工作占据了将近70%的时间。



- 数据准备包括：数据获取、数据清洗、存储归档等
- 其他工作包括：数据观察、数据建模、数据挖掘等

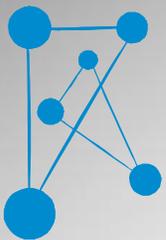
企业可以聚焦在专业领域，把数据获取和清洗环节作为产品的外延服务



数据AI生态圈

长江众创打造数据协同工作平台，提供“数据中央厨房”服务，整合多方资源，孵化各类垂直场景金融数据及人工智能企业建设AI生态圈





数据集成开发流程

数据集成开发遵循完整的软件项目开发流程

高层次需求

高层次设计

定义数据需求

定义数据源

数据源和目标概要分析

定义清洗流程

定义转换和映射

定义数据校对

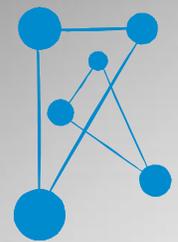
编码和测试

定义数据服务接口

编码和调试接口



数据协同工作平台一览



一鱼数据 企信通 有数啦

37
数据源总量

130,045
采集数据总量

6045
清洗数据总量

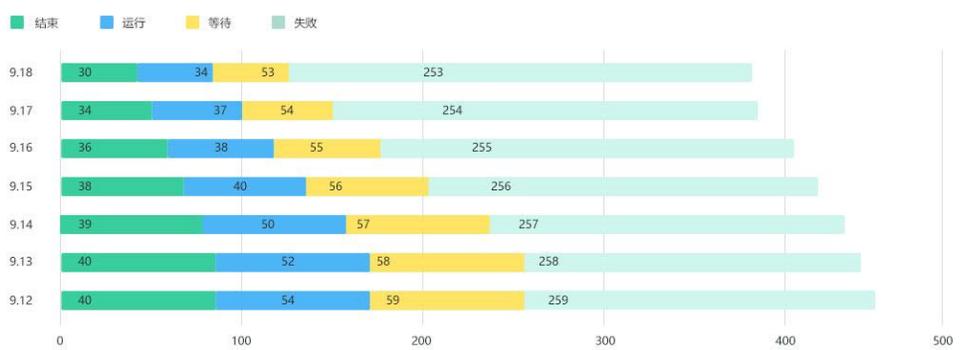
210,241
API调用次数

13%
存储空间使用量

采集任务运行情况

清洗流程运行情况

更多 >



异常任务列表

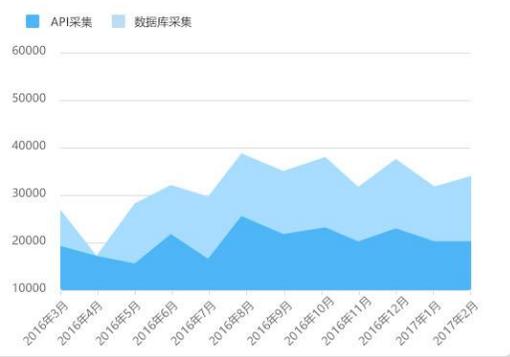
更多 >

采集 (5) 清洗 (4)

序号	任务名称	任务状态	异常检测	发生时间
1	起点女生网	失败	异常	2017-09-05
2	起点女生网	失败	异常	2017-09-05
3	起点女生网	失败	异常	2017-09-05
4	起点女生网	失败	异常	2017-09-05
5	起点女生网	失败	异常	2017-09-05

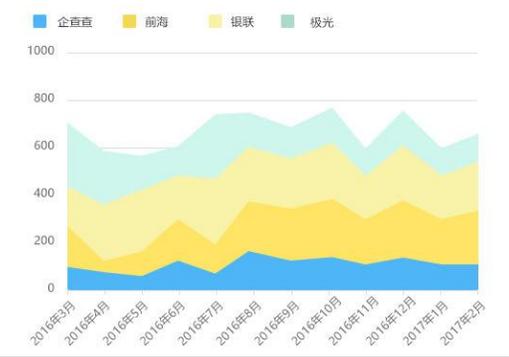
数据采集分类统计

更多 >




API调用次数统计

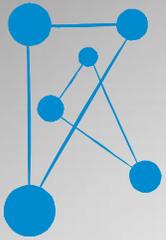
更多 >



采集/清理数量统计

更多 >

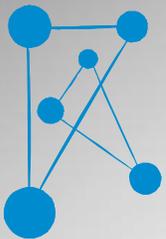




数据集成面临的挑战

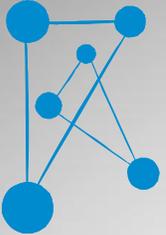
1. 多源异构数据源的接口复杂性
 1. 多样的应用数据库
 2. 不同外部数据供应商的接入协议（通信、数据格式、认证、加密、字典）
 3. 多种类型的数据类型：结构化、半结构化、非结构化
2. 语义歧义
 1. 同一概念在不同数据源的涵义不同
 2. 不同概念在不同数据源的涵义相似
3. 实例歧义
 1. 数据记录唯一标示
 2. 关联数据识别
4. 数据标准和质量不规范
 1. 格式、编码、度量单位、缺值、多值等
 2. 指标、统计口径不一致
5. 多源数据的更新频率/方式不一致



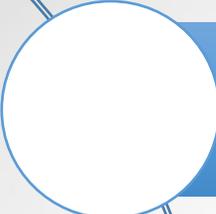


数据管理架构应对复杂的数据集成

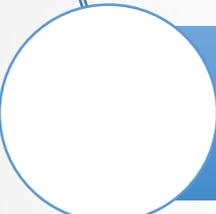




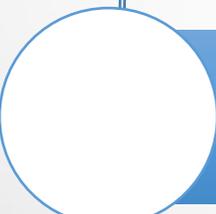
数据协同工作平台四大特点



支持多源异构数据源快速接入



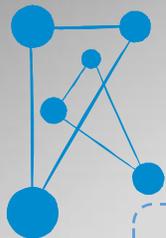
元数据配置驱动的采集和智能清洗流程



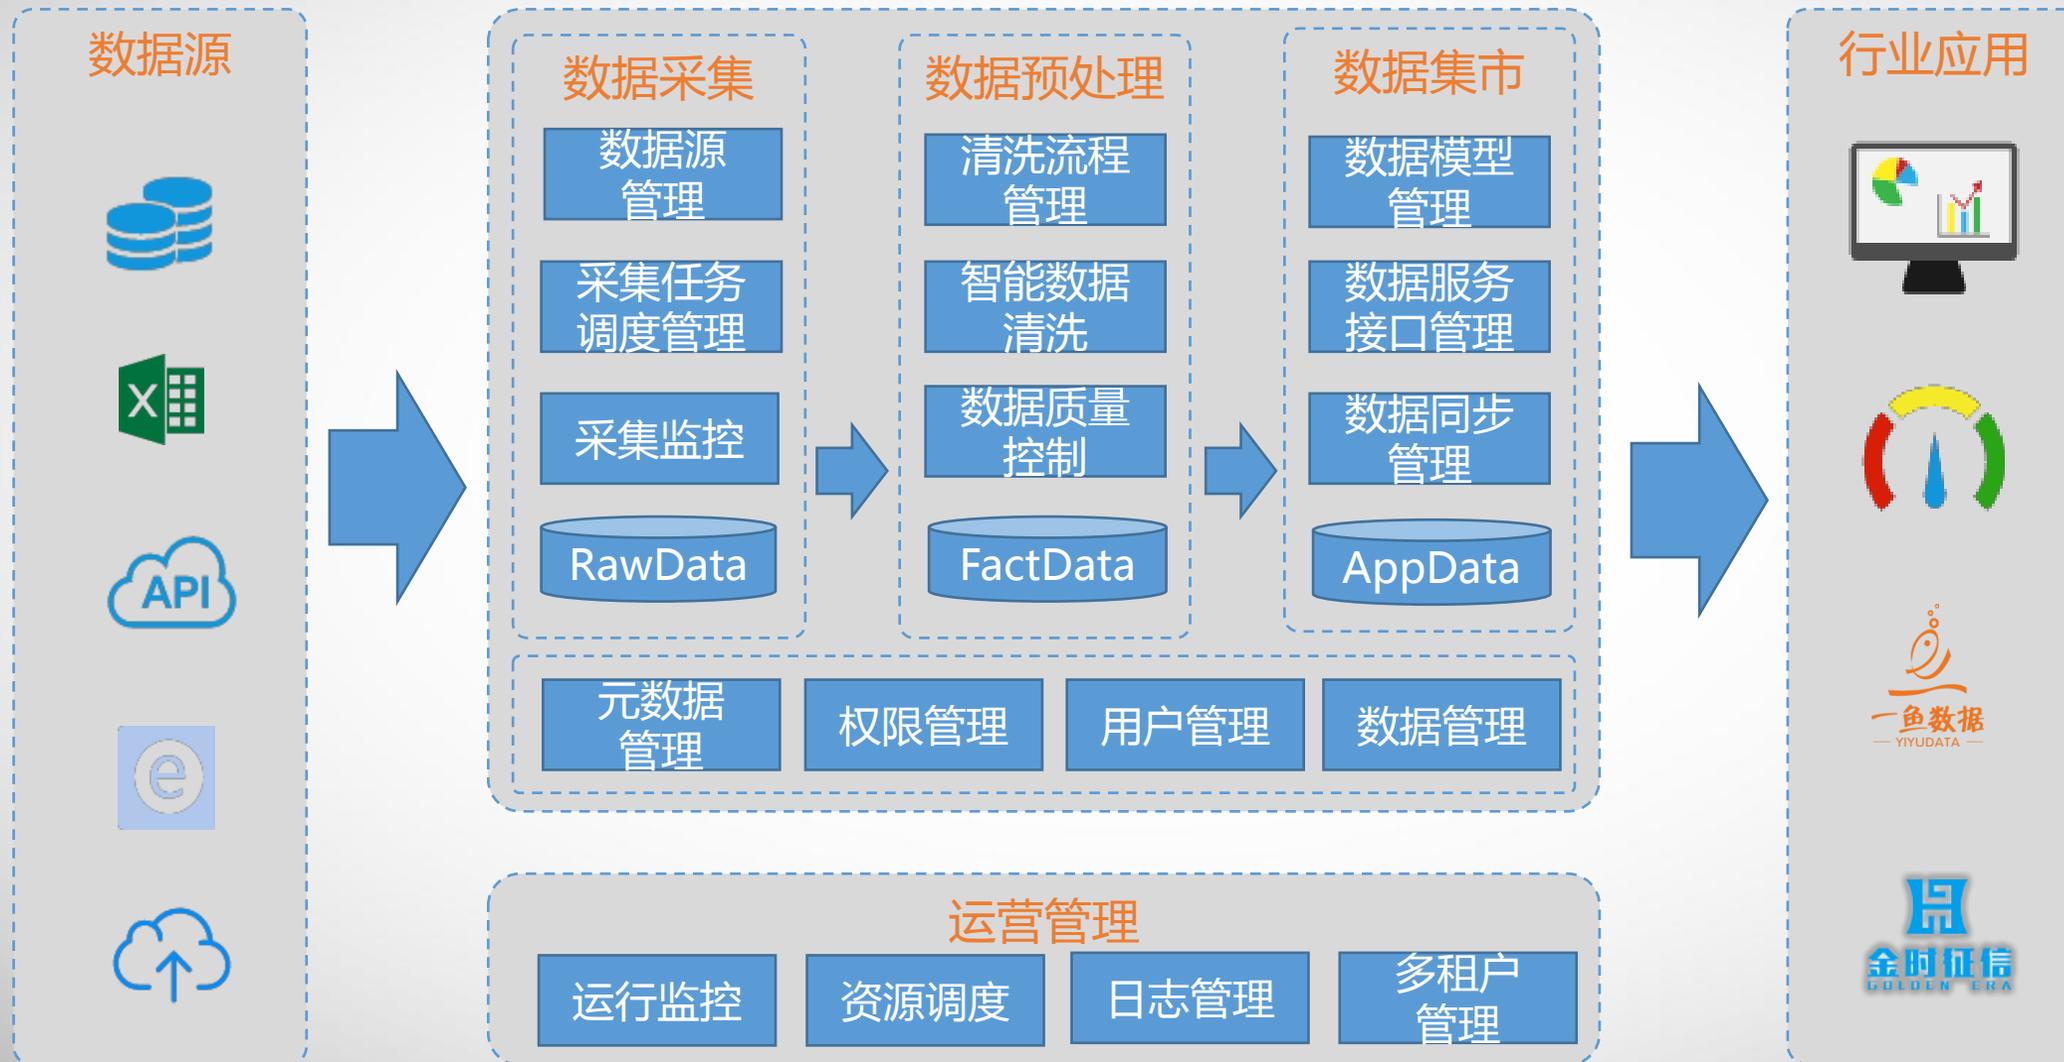
基于容器的微服务架构支持高并发及海量数据存储



数据全生命周期管理与溯源

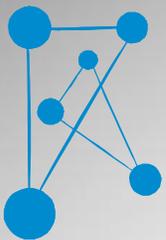


数据集成框架



行业应用





数据协同工作平台关键技术指标

存储量

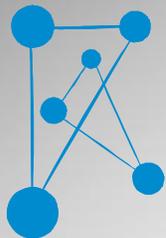
- 千亿量级数据
- PB级空间容量

吞吐量

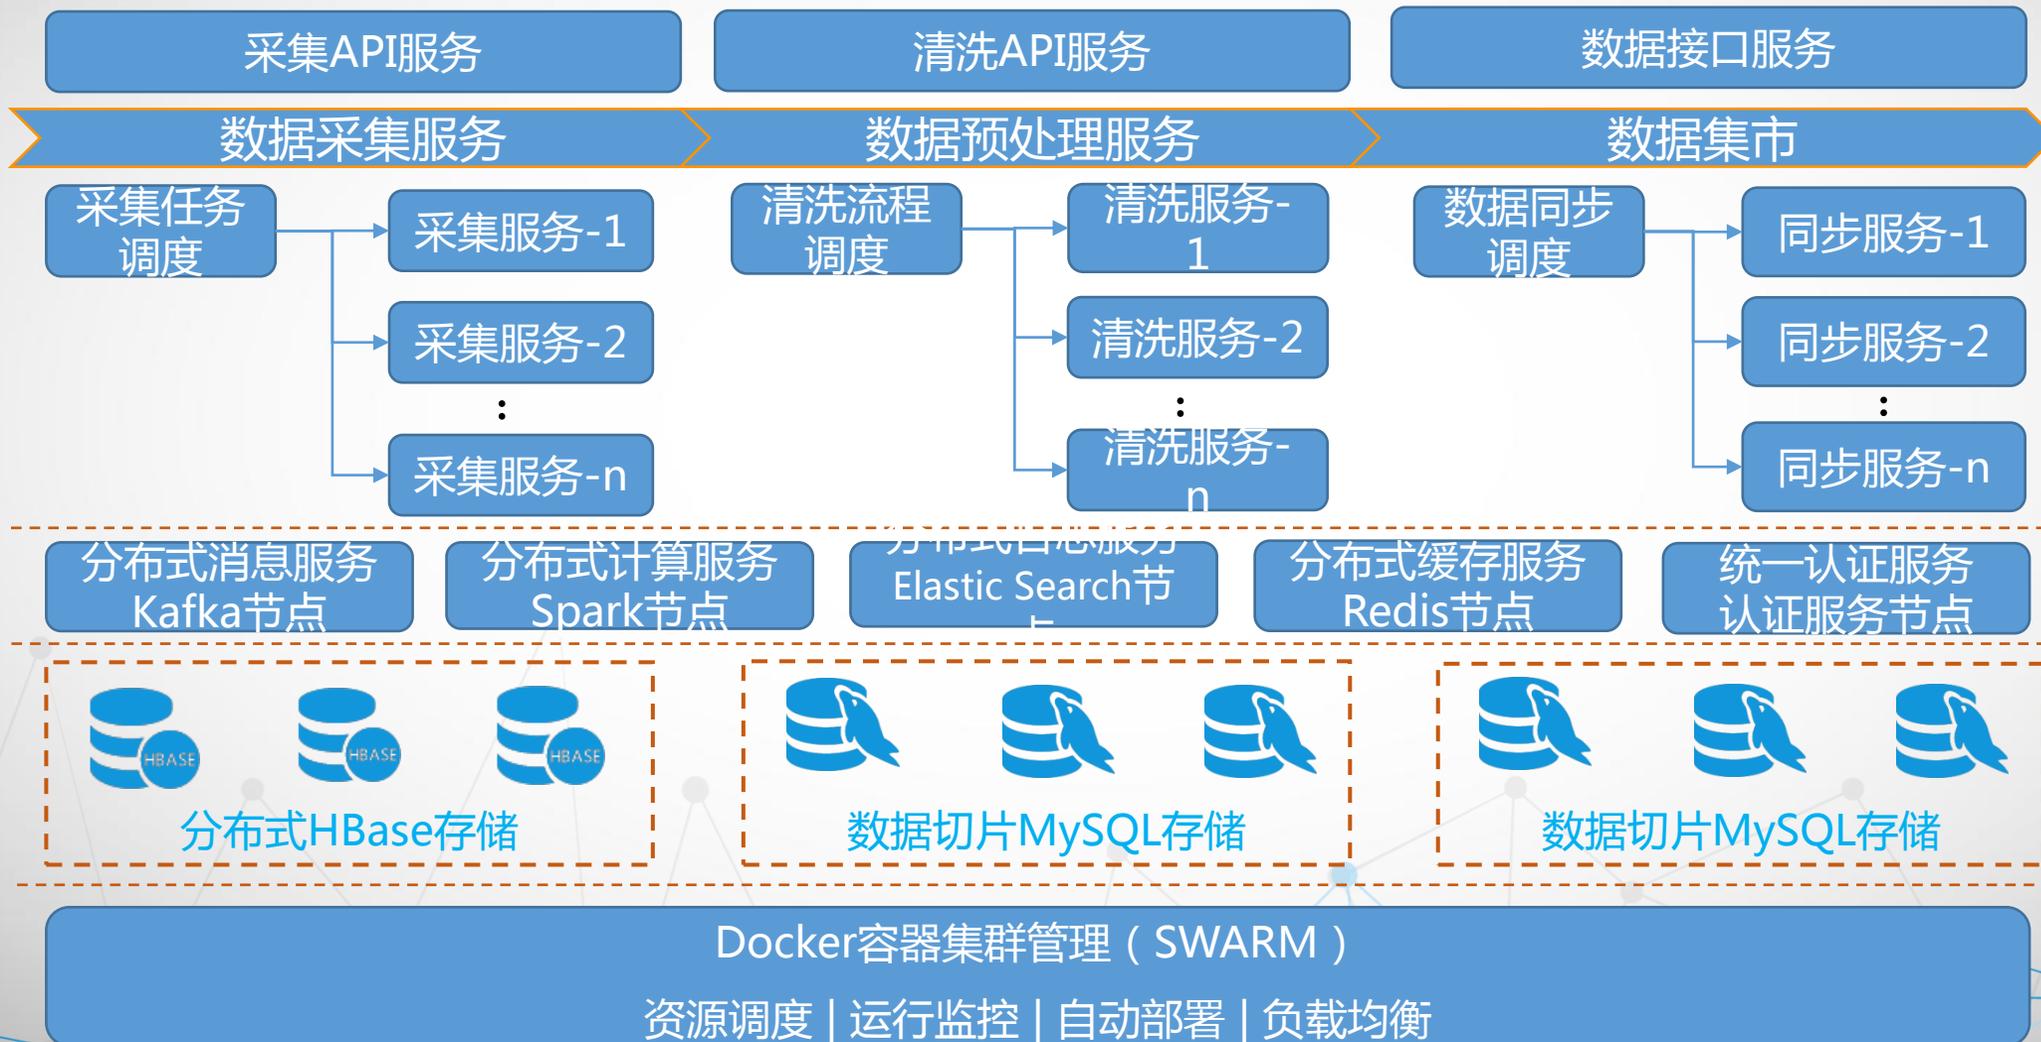
- 日均亿级数据处理
- 秒级单次采集及清洗

可靠性

- 所有数据保留三份全量副本
- 动态资源调度应对高峰压力



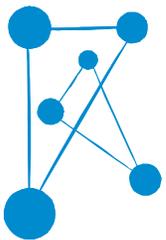
技术架构



关于我们

About us





发展理念

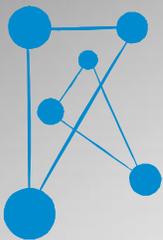
CAPITAL OF STATISTICS
PROFESSION, HUMANITY & INTEGRITY

IT大咖说
知识共享平台



长江众创
WWW.CJZC.NET.CN

打造数据中央厨房，助力数据企业孵化
秉承 MOM 理念，共建AI产业生态圈



产品与服务

公司形成以数据服务为核心

以咨询顾问、社群服务、投资孵化服务为支撑

相互协同的业务格局

咨询顾问

- 为传统行业中的企业提供大数据+相关咨询顾问

数据服务

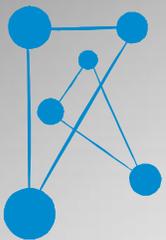
- 场景金融数据服务
- 数据“中央厨房”

创投孵化

- 关联数据公司及AI职能的孵化和投资

社群服务

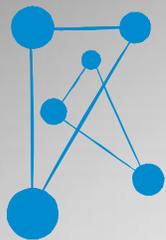
- 数据爱好者社群服务
- 数据咨询师社群服务
- 企业家社群服务



数创空间站



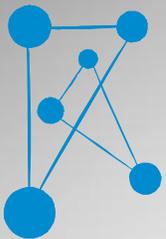
长江众创积极响应国家“大众创业，万众创新”的号召
在上海、北京、宁波等地建立数创客空间（Dataker Station），助力大数据&人工智能产业创新升级
其中上海的空间站为浦东新区创新型孵化器



数创空间站

为大数据及人工智能创新企业提供办公空间与人才聚集平台,大数据技术支持的多样化全流程服务体系
同时为各阶段创业者提供投融资对接服务,释放入孵企业发展潜能,加速入孵企业成长,帮助创业者走好每一步





数创空间站

目前，数创空间站已经孵化了公司内外数个大数据创新项目，助力大数据产业创新升级。

致力于成为中国一流的独立基金信息服务和配置赋能商

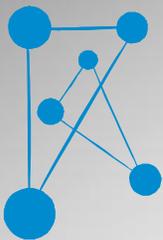


致力于成为公信力卓越的数据驱动型征信服务平台

致力于成为最IN的数据客在线社群



致力于成为中国领先的泛娱乐大数据服务商



长江光启创新学院

学院以数据“三师”培训体系为核心，整合大数据、AI各界专家，通过线上大数据Live及线下沙龙等形式为入孵企业及大数据爱好者提供人才培养与实训，同时为有志创业人才提供创业进阶指导。

职业技能培训
大数据

大数据 分析师课程

- 数据可视化
- 大数据统计分析基础
- 贝叶斯分析与应用
- 数据库与数据处理
- 网络爬虫与文本挖掘
- 数据治理
- 深度学习
- R语言编程与开发
- 大数据平台技术与应用
- Python机器学习

大数据 工程师课程

- Java核心开发
- Hadoop应用
- 大数据行业应用导论
- 大数据架构
- 微服务与实现
- Hopping精讲
- 大数据仓库Hive精讲
- Spark与机器学习
- 分布式存储:HDFS、Hbase

大数据 咨询师课程

- 大数据导论
- 产业研究方法
- 大数据实践与应用
- 数据治理
- 项目管理与有效沟通

大数据统计分析实战训练营(R/Python)

Web全栈工程师数据可视化训练营

量化金融分析师实战训练营

大数据
Live



数创客

THANK YOU