



拿破仑

内容安全解决方案

MIAOCHU CONTENT SECURITY



革新

提供全方位的

科技

内容安全服务

CONTENT SECURITY



CONTENT SECURITY



目录

CONTENTS




01
团队介绍




02
业务矩阵



03
客户体验



04
接入流程



01

SECTION 01

团队介绍

- 拿破仑安全团队，专注于为泛娱乐内容提供合规的安全解决方案



团队介绍

INTRODUCE

拿破仑安全团队，专注于为泛娱乐内容提供合规的安全解决方案。

为业务安全和内容安全提供双重保障，助力合作伙伴实现安全与可持续发展，与合作伙伴一起共同构建一个安全可信的泛娱乐生态环境。

2013年

推出了第一代人工审核系统，实现了对视频流的“实时截图-识别-审核-控制”的完整审核流程

2018年

自主研发了音频识别系统，成为行业内多个安全技术方向上的效果评测标准

2020年

推出信用标签体系，助力合作企业落实降本增效管理与精细化运营

2015年

自主研发了图像识别系统，为直播和短视频领域的内容审核工作提供了强有力的支持

2019年

引入了多模态数据模型，将图像、音频和文本综合运用，进一步提升内容安全的准确性和全面性

2022年

行业首创即时屏蔽技术，推动内容审核领域“人机结合”的模式改革





02

SECTION 02

业务矩阵

- 核心API检测能力
- 事前屏蔽智能解决方案
- 内容安全专家服务



产品矩阵

PRODUCTS



核心API检测能力

图像检测

涉政 | 涉黄 | 涉恐暴 | 低俗 | 人脸检测
| OCR

音频检测

ASR | 娇喘 | 版权歌曲 | 红政

文本检测

自定义敏感词库 | 自然语言处理 (NLP) |
文本分类



事前屏蔽智能解决方案

即时消音

涉政 | 涉黄 | 谩骂

即时文本过滤

异常检测 | 语义分析 | 情感分析 | 句法分析 | 文本
分类与聚集

即时打码

研发中...敬请期待☺



内容安全专家服务

安全专家服务

安全舆情 | 安全培训

合规咨询服务

双新测评 | 合规咨询

共建探索

私有化部署 | 算法共建咨询

效果介绍

千万亿+

年过滤数据

100+






精细化标签

99%+

召回率

核心API检测能力

PRODUCT POWER PART1





文本检测

核心API检测能力



千万级
策略集



20+
多语种策略支持



定制化
关键词/策略



十毫秒级别
接口响应

基础类别能力

涉政

支持敏感专项、时事报道、领导人相关、英雄烈士相关、邪教迷信、落马官员相关、热点舆情、宗教、恶搞领导人等相关能力

色情

支持色情传播、色情性器官、低俗段子、挑逗、性行为等相关等精细化子分类返回


暴恐

针对危害公共安全、国家安全的内容进行识别

违禁

支持刀枪弹药、赌博、违禁工具、违禁代办、违禁药品等相关等精细化子分类返回

- 生僻词支持
- 文本聚类
- 行为识别
- 词向量模型
- NLP技术
- 文字变种





图片检测

核心API检测能力



定制化

人脸库、关键词/策略



百毫秒级别

接口响应

基础类别能力

涉政

支持核心领导人、领导人相关、英雄烈士相关、落马官员相关、热点舆情、宗教相关等精细化子分类返回

色情

支持性器官、低俗、挑逗、性行为等相关等精细化子分类返回

暴恐

针对危害公共安全、国家安全的内容进行识别

违禁

支持刀枪弹药、赌博、违禁工具、违禁药品等相关等精细化子分类返回

专项识别能力

人脸识别


自定义人脸识别

LOGO识别

长短视频版权LOGO、赛事版权LOGO等

图片OCR

识别图片中的文字信息，检测有害内容






视频检测

核心API检测能力

检测流程



覆盖场景

- 直播间
- 短视频
- 点播视频
- 多人互动聊天

辅助检测

- 智能截帧
- 智能电视墙
- 视频MD5库
- 主播黑名单
- 直播间热度监控





音频检测

核心API检测能力

声音输入

突出人声、噪音过滤



ASR识别

特征提取

声学模型

语言模型

输出文字结果

音节

字/词

句子

声纹检测

ASMR、娇喘、领导人声纹

特征提取

声学模型

输出结果

歌曲识别 (覆盖9500+、支持自定义)

当你

加油

明天过后...

声音分类

静音

人声

歌声

噪音

声音属性:
性别、未成年、年龄

反垃圾检测

多意义上下文短文本垃圾检测

Deep Learning垃圾检测

规则引擎、分类器等

输出反垃圾综合结果

- 风险级别: 删除 通过 嫌疑
- 命中信息: 娇喘 谩骂
- 命中断句时间戳: [2:33:12-2:33:32]
(自然断句, 支持最短返回断句时长)
- 音频标签: 中文 人声 女声



音频检测

核心API检测能力



自定义

歌曲检测、关键词

• 语音识别

• 语种识别

• 人声属性



语音识别能力范围

🔊 涉政类语音

新中国联邦成立后郭文贵就可以在国外开创新中国了

🔊 色情类语音

打个飞机全身是汗，撸完就是爽

🔊 推广类

我们平台流量大，平台日结提现

🔊 其他违规类

危害国家安全/谩骂类/空语音无意义

声纹检测能力范围

🔊 娇喘

展示或模拟星星为过程中发出的具有明显挑逗性的声音

🔊 ASMR

展示或模拟克诱导听觉自发性知觉经络反应的声音，如口腔音/舔耳等

🔊 违禁歌曲

涉及领导/历史事件/热点舆情相关的恶意抨击调侃等不实歌曲识别
[精细化子分类返回](#)

🔊 涉政人物声纹


涉及11重要涉政人物及家属的声音识别
(毛泽东/江泽民/习近平/彭丽媛/郭文贵/王立铭/郝海东/何岸泉/李洪志/青海无上师/热比娅卡德尔/十四达赖喇嘛/王丹/吾尔开希/周锋锁/黄之锋)

事前屏蔽智能解决方案


PRODUCT POWER PART2

LIVE


拳头服务




性感-呻吟



性感-勾线



性感-勾线



性感-呻吟



✓ 合规内容



版权违规



赛事版权



规游戏



即时消音

事前屏蔽智能解决方案




低延时
实时率 5%



无感知
单次消音时长 0.7s




少量人审
较推审模式成本低 85%



不同厂商ASR指标对比（数据为最新一次评测，支持客户自主评测）

		黑词识别准确率	黑词识别召回率
整体	A厂商	83.26%	76.21%
	B厂商	76.69%	80.24%
	C厂商	79.76%	81.85%
	消音	71.02%	97.43%
		黑词识别准确率	黑词识别召回率
涉政	A厂商	78.99%	93.97%
	B厂商	73.57%	88.79%
	C厂商	81.75%	88.79%
	消音	68.82%	95.27%
		黑词识别准确率	黑词识别召回率
涉黄	A厂商	73.91%	79.53%
	B厂商	78.26%	70.59%
	C厂商	79.35%	73.37%
	消音	72.40%	97.49%
		黑词识别准确率	黑词识别召回率
谩骂	A厂商	67.86%	91.72%
	B厂商	77.04%	86.29%
	C厂商	80.10%	85.33%
	消音	88.51%	99.40%





高风险违规内容（如涉政类）建议采用重召回模型，其他违规内容可随业务发展的节奏和时间段做相应调整。

快手@508039932

提供给客户自定义的黑词库管理


模型	违规标签	当前黑词量
涉政	涉一号	1000+
	党政相关	200+
	敏感事件	300+
	政民争议	500+
	反华分裂	1000+
	英烈相关	100+
	国&红歌	100+
	其他国家领导人	300+
	邪教迷信	400+
	六四相关	1000+
	历史事件	100+
	合计	5000+
涉黄	描述性行为或性器官	2000+
	低俗，引起不适	600+
	淫秽制品相关	200+
	传播色情行为	200+
	低俗歌词	300+
	合计	1500+
谩骂	谩骂-人身攻击	2000+
	谩骂-口头禅粗口	500+
	合计	2500+



消音策略灵活化

主播端提示

主播端



分策略消音

全消

o鸡巴k吗, o鸡巴k, o鸡巴k, o鸡巴k, o鸡巴k



2消1

o鸡巴k吗, o鸡巴k, o鸡巴k, o鸡巴k, o鸡巴k



3消1

o鸡巴k吗, o鸡巴k, o鸡巴k, o鸡巴k, o鸡巴k





即时文本过滤

事前屏蔽智能解决方案



90%+

拦截准确率



90%+

违规召回率





即时打码

事前屏蔽智能解决方案




开发中...敬请期待



内容安全专家服务

PRODUCT POWER PART3

专家
认证






专家矩阵服务

内容安全专家服务

内容安全政策解读

帮助企业快速了解国内内容安全现状，引起业务部门重视，为安全工作的开展做铺垫



综合解决方案定制

风控专家将对产品进行全面体检，梳理出重点业务环节的风险现状，提出针对性改善方案。对产品完成安全性评估，输出适合产品全场景的风控解决方案



专家矩阵服务

内容安全专家服务

重大专项舆情预案

每年重大专项前准备舆情预案，突出体现当年重点舆情布控方向，行业相关或产品相关重点舆情布控方向，帮助客户打有准备之仗。




红蓝军对抗

以攻击者姿态，向不同的场景投放蓝军样本，并监控蓝军样本的处置方式、处置时长，逐渐升级攻击难度，输出产品内容风控蓝军报告，帮助客户知晓产品抗攻击能力

产品解决方案

PRODUCT SOLUTION





产品解决方案

PRODUCTS

多场景综合解决方案

图文动态

私聊/群聊

评论

直播

互动音视频

弹幕

用户资料

邮件

新闻资讯

网文小说

游戏聊天区

文本

图片

视频

音频

智能AI检测

- 涉黄
- 暴恐
- 涉政
- 违禁
- 广告
- 二维码
- LOGO 识别
- OCR 识别
- 歌曲、声纹识别
- 语音识别
- 人脸识别

即时屏蔽

- 0曝光
- 低延时
- 免人审



支持服务

- 安全舆情与安全培训
- 合规咨询服务
- 定制标签
- 策略配置
- 算法共建

方案架构 – AI检测+人审

业务场景

私聊

群聊

动态广场

评论

用户资料

弹幕

语聊房

视频聊天

娱乐直播

赛事转播

单次提交过检

拉流监听持续检测

业务内容

文本、图片、点播视频、点播音频

语音流，视频流

机器检测

过检数据

文本

音频

图片

视频

内容检测

色情/性感/涉政
暴力/
违禁/广告/
谩骂/灌水/
恶心/涉价值观...


内容识别

情感分析
观点分析
人脸识别
文本纠错
场景识别
LOGO识别

机器检测管理后台

规则策略设置

规则引擎
关键词名单
图片名单
设备名单
自定义名单



产品/业务管理

策略配置与管理

机检数据查询



数字内容
风控引擎

业务风控

人机识别、黑名单库、IP画像、设备指纹、行为模型、业务模型、全链路分析

安全专家服务

舆情顾问、安全蓝军、风控咨询、合规咨询、安全质检、安全培训

SECTION 03

03

客户体验

- 项目经验1
- 项目经验2
- 客户列表



客户体验

CUSTOMER CASE

项目一：某互联网上市公司

CASE SHARING



- **项目痛点**

客户没有系统性的音频审核机制，仅对用户举报内容进行处理，投诉举报量大，人审处理不及时，被监管点名整改

- **解决方案**

提供了“实时消音+AI音频检测+人审”音频一站式解决方案，同时提供消音策略自定义配置，满足客户平台生态需求

- **效果**

使用我方产品服务期间，客户平台无音频风险舆情发生，来自于各方的举报与投诉量大幅减少



客户体验

CUSTOMER CASE

项目二：某互联网上市公司

CASE SHARING



● 项目痛点

初创公司有一定的安全意识，但不知如何高效布控风险内容的管控手段

● 解决方案

基于喵触多年的风控经验，我司对其提供专家服务，针对其业务特点进行多种高效的管控策略制定、敏感专项防控，依据客户业务节奏逐步迭代内容风控方案

● 效果

- 客户业务上线初期，配备轻量级管控策略，确保“有证”驾驶；
- 客户业务扩张阶段，上线信用标签管理机制，帮助客户实现精细化运营

04

SECTION 04

接入流程

- SaaS API接口 / 在线检测



接入流程

PROCESS



SaaS API接口

- ✓应用场景：推荐调用方式，灵活通过http接口提交数据检测，获取检测结果，实时作用在业务处理
- ✓支持能力：文本/图片/视频/直播流检测



在线检测

- ✓应用场景：无研发介入，需快速获得本地数据的检测结果
- ✓使用方式：申请开通系统，后台上传本地数据，获取检测结果



THANKS!

感谢大家观看!

