



# 伟仕佳杰 打破AzureOpenAI 配额限制解决方案



伟仕佳杰集团



伟仕佳杰微讯

亚太地区领先的专注ICT行业解决方案的科技平台

[www.vstecs.com](http://www.vstecs.com)

# 集团简介

## GROUP PROFILE

**伟仕佳杰控股有限公司（简称“伟仕佳杰”）成立于1991年，2002年在香港主板上市，股票代码00856.HK。**

伟仕佳杰是亚太地区领先的专注ICT行业解决方案的科技平台，是科技产品进入中国及东南亚市场的主要路径，为合作伙伴提供全品类、一站式、全链路的信息化服务，以提升运营效率，降低交易成本，推动行业数智化转型，加快信息化产业数智化进程。

# 企业实力

ENTERPRISE STRENGTH

集团简介

业务概览

业务亮点

合作生态

企业文化

- 1991年成立，专注深耕ICT行业
- 员工5,500名，认证工程师1,000+名
- 业务覆盖亚太9个国家
- 全亚太87个分支机构，50,000+渠道伙伴
- 香港主板上市 (00856.HK)，“深港通+沪港通”双标的

聚焦ICT行业，携手生态伙伴向千行百业提供产品和解决方案

通过**行业解决方案**深度服务千行百业

政府 金融 交通 制造 能源 教育 医疗 媒体 ...

通过**产业链解决方案**多元化链接ICT产业链上下游

工程师资源  
产品 服务 技术解决方案

## 企业系统

基础建设 软件  
人工智能 网络及安全  
计算 物联应用  
存储

## 消费电子

智能终端 游戏娱乐  
虚拟现实 整机外设及配件

## 云 计 算

分销转售  
咨询迁移  
运维管理  
开发与增值

## 自研产品

AI算力调度和运营平台  
RightCloud多云管理平台  
Vplus云平台

## 全周期服务

产品渠道赋能 系统集成赋能  
服务合作赋能 培训认证赋能  
解决方案赋能 市场营销赋能  
技术支持赋能

AI产业链全覆盖

云全生命周期管理

信创产业深度布局

深度覆盖中国及东南亚9个国家

## 中国区500+认证工程师

基于在ICT领域的资源积累和长期实践，伟仕佳杰围绕人工智能、云计算、大数据、信息安全等领域，打造了一支技术领先、能力全面、行业经验丰富并拥有国际视野的专家团队，为上下游合作伙伴充分赋能。

### AI算力与多云管理自研实力

佳杰云星有近百名聚焦软件研发和服务的技术工程师，拥有华为云HCIA/HCIP/HCIE认证、阿里云认证等云计算领域头部认证，及AI领域权威认证——人工智能工作级开发者认证HCCDP - AI。

### AI基础设施领域技术能力

伟仕佳杰拥有华为、超聚变、昆仑、宝德、华鲲振宇和五舟等头部厂商售前、售后、投标工程师认证的工程师团队，为合作伙伴提供全周期的运维优化。聚焦高性能计算解决方案，团队具备超聚变、昆仑等FCS-Bidding、FCIE、FusionOne HCI FCS-Solution、KCIA、KCS-Pre-sales售前、服务器系统设计、解决方案实施等能力认证，能够根据用户需求提供定制化的技术支持和服务。

### 云计算领域技术能力

与VMware by Broadcom、华为云、AWS、阿里云、移动云、天翼云、百度智能云等国际顶尖厂商合作，为企业提供全面的云计算和大数据服务，在架构设计、专业咨询、服务集成、数据备份与灾难恢复等方面经验丰富。

#### C-]阿里云

AliCloud MVP  
阿里云工程师最高认证

#### C-]阿里云

AliCloud ACPACE  
阿里云工程师认证



Huawei Cloud HCIA  
华为云服务工程师认证




Huawei Cloud  
HCIP  
HCIE

#### vmware<sup>®</sup> by Broadcom

VMware VCP VMware  
工程师认证

#### Microsoft

Microsoft SQL DBA  
微软数据库工程师认证



Azure Solutions  
Architect  
微软解决方案架构专家认证



REDHAT RHCA  
红帽系统架构师认证



ITIL  
IT基础架构管理认证



PMP  
项目管理资格认证



Cisco CCIE  
思科互联网专家认证



- Distribution
- AWS China Promotion
- Small and Medium Business Services Competency
- Migration and Modernization Services Competency

# 伟仕佳杰人工智能合作图谱



# 打破OpenAI 配额限制


- Azure OpenAI 的配额限制策略主要基于订阅级别，按区域和模型类型分配 Tokens per Minute (TPM) 和 Requests per Minute (RPM) 限额
- 用户可将 TPM 灵活分配到多个部署中，总和不超过该区域的配额上限
- 不同的订阅类型和模型对应不同的配额

Model	Enterprise and MCA-E	Default	Monthly credit card-based subscriptions	MSDN subscriptions
gpt-4.1	5B	200M	50M	90K
gpt-4.1 mini	15B	1B	50M	90K
gpt-4.1-nano	15B	1B	50M	90K
gpt-4o	5B	200M	50M	90K
gpt-4o-mini	15B	1B	50M	90K
gpt-4-turbo	300M	80M	40M	90K
gpt-4	150M	30M	5M	100K
gpt-35-turbo	10B	1B	100M	2M
o3-mini	15B	1B	50M	90K
o4-mini	15B	1B	50M	90K
gpt-5	5B	200M	50M	90K

## Microsoft Foundry 中的 Azure OpenAI 模型配额限制

## 由此引发的问题

- 面对大量并发时，调用端需要自己实现多订阅间的负载平衡
- 在单个订阅的TPM接近配额上限时，调用端会收到429错误
- 响应延迟增加和性能不稳定



- **扩展性和配额优化**: 通过活跃-活跃负载均衡, 将请求分布到多个订阅或部署 (如预配吞吐量与标准部署), 实现流量溢出和突发处理, 突破单一订阅的 TPM/RPM 限额, 支持多租户场景下的集中配额分配。
- **高可用性和可靠性**: 支持故障转移、自动重试和断路器逻辑, 当一个订阅因配额耗尽 (429 错误) 或故障时, 智能路由到可用后端, 确保服务连续性, 并减少客户端代码负担。
- **性能提升**: 采用优先级分组路由 (如优先使用高优先级后端), 避免传统轮询延迟, 实现随机负载分布和无延迟切换, 提高整体响应速度和吞吐量。
- **成本控制**: 允许低配预配实例并用标准实例处理溢出, 优化资源利用, 避免过度配置导致的浪费, 同时支持基于客户端的计费和展示模型。
- **安全与合规**: 在网关层集中管理凭证终止、客户端识别路由和模型隔离, 提供比 Azure OpenAI 实例级 IAM 更细粒度的访问控制, 增强多订阅环境的安全性。
- **监控与可观测性**: 统一收集跨订阅的遥测数据、日志和配额使用指标, 便于仪表板可视化、警报设置和使用追踪, 支持多区域冗余部署的单一控制平面管理。

- **Round-Robin (轮询)** : 静态算法, 按顺序均匀分配请求到多个后端实例 (如不同订阅的 OpenAI 部署), 适用于基本负载均衡场景。
- **Random (随机)** : 随机选择后端, 避免单一实例过载, 常用于简单流量分散。
- **Priority-Based (基于优先级)** : 优先路由到高优先级后端 (如高配额订阅), 当其不可用 (如 429 限流) 时降级到次级, 支持分组和权重内部分配, 提升资源利用率。
- **Weight-Based (基于权重)** : 自定义权重 (如根据 TPM 配额比例分配流量), 通过策略表达式实现动态路由, 优化多订阅配额使用。



	Basic v2	Standard v2	Premium v2
适用场景	团队和项目的 API 管理	启动组织内部的 API 项目，并随着项目的发展逐步扩展。	适用于庞大请求量的企业级场景
基础价格	\$150.01 per month <sup>8</sup>	\$700/月	\$2,801/月
扩展价格 (每增加一个单位)	\$150.01/月	\$500/月	\$1,401/月
月请求量上限	基础价格内含10M次请求 每增加1百万次请求\$3	基础价格内含50M次请求 每增加1百万次请求\$2.50	无上限



# 利用生产环境数据确定 API SKU

## 类别: Azure OpenAI - HTTP 请求

 展开表

指标	REST API 中的名称	单 位	集 合 体	尺 寸	时间 粒度	DS 导 出
Azure OpenAI AvailabilityRate  使用以下公式计算可用性百分比: (调用总数 - 服务器错误数)/调用总数。服务器错误包括任何 >=500 的 HTTP 响应。	AzureOpenAIAvailabilityRate	百 分 比	最 小 值、 大 值、 平 均 值	ApiName、 OperationName、Region、 StreamType、 ModelDeploymentName、 ModelName、ModelVersion	PT1M	否
Azure OpenAI 请求  一段时间内对 Azure OpenAI API 的调用次数。适用于 PTU、PTU 管理的部署以及即用即付部署。若要细分 API 请求, 可以按以下维度添加筛选器或应用拆分: ModelDeploymentName、 ModelName、ModelVersion、 StatusCode (成功、客户端程序、服务器错误)、IsSpillover 以获取溢出信息、StreamType (流式处理请求和非流式处理请求) 和作。	AzureOpenAIRequests	计 数	总 计 (总 和)	ApiName、 OperationName、Region、 StreamType、 ModelDeploymentName、 ModelName、 ModelVersion、 StatusCode、IsSpillover	PT1M	是 的

[Azure OpenAI 监视数据参考](#)



## 我们能做什么？

- **架构设计与配额规划**: 评估客户流量, 设计最优的多订阅/多区域/PTU + PayGo 混合架构APIM
- **统一网关一键部署**: 通过 ARM/Bicep/Terraform 快速交付支持优先级+权重+自动故障转移的完整策略模板
- **智能负载均衡策略实施**: Round-Robin、权重路由、429 自动降级、断路器、突发流量溢出处理
- **企业级安全与治理**: APIM 层集中密钥管理、客户端证书/JWT 验证、IP 白名单、订阅级模型隔离、Azure Policy 合规
- **统一监控与告警**: 构建跨所有订阅的配额使用、延迟、429 错误率仪表板 + 自动告警与配额预警
- **自动扩缩容与成本优化**: 按月/季分析使用率, 动态调整订阅数量
- **企业支持与 SLA**: 7×24 监控与应急响应, 保证 99.95%+ 可用性,
- **迁移与落地陪跑**: 从单订阅迁移到多订阅高可用架构, 全程陪跑与知识转移



THANKS



伟仕佳杰集团号



伟仕佳杰微讯号

伟仕佳杰

亚太地区领先的专注ICT行业解决方案的科技平台

[www.vstecs.com](http://www.vstecs.com)  
m