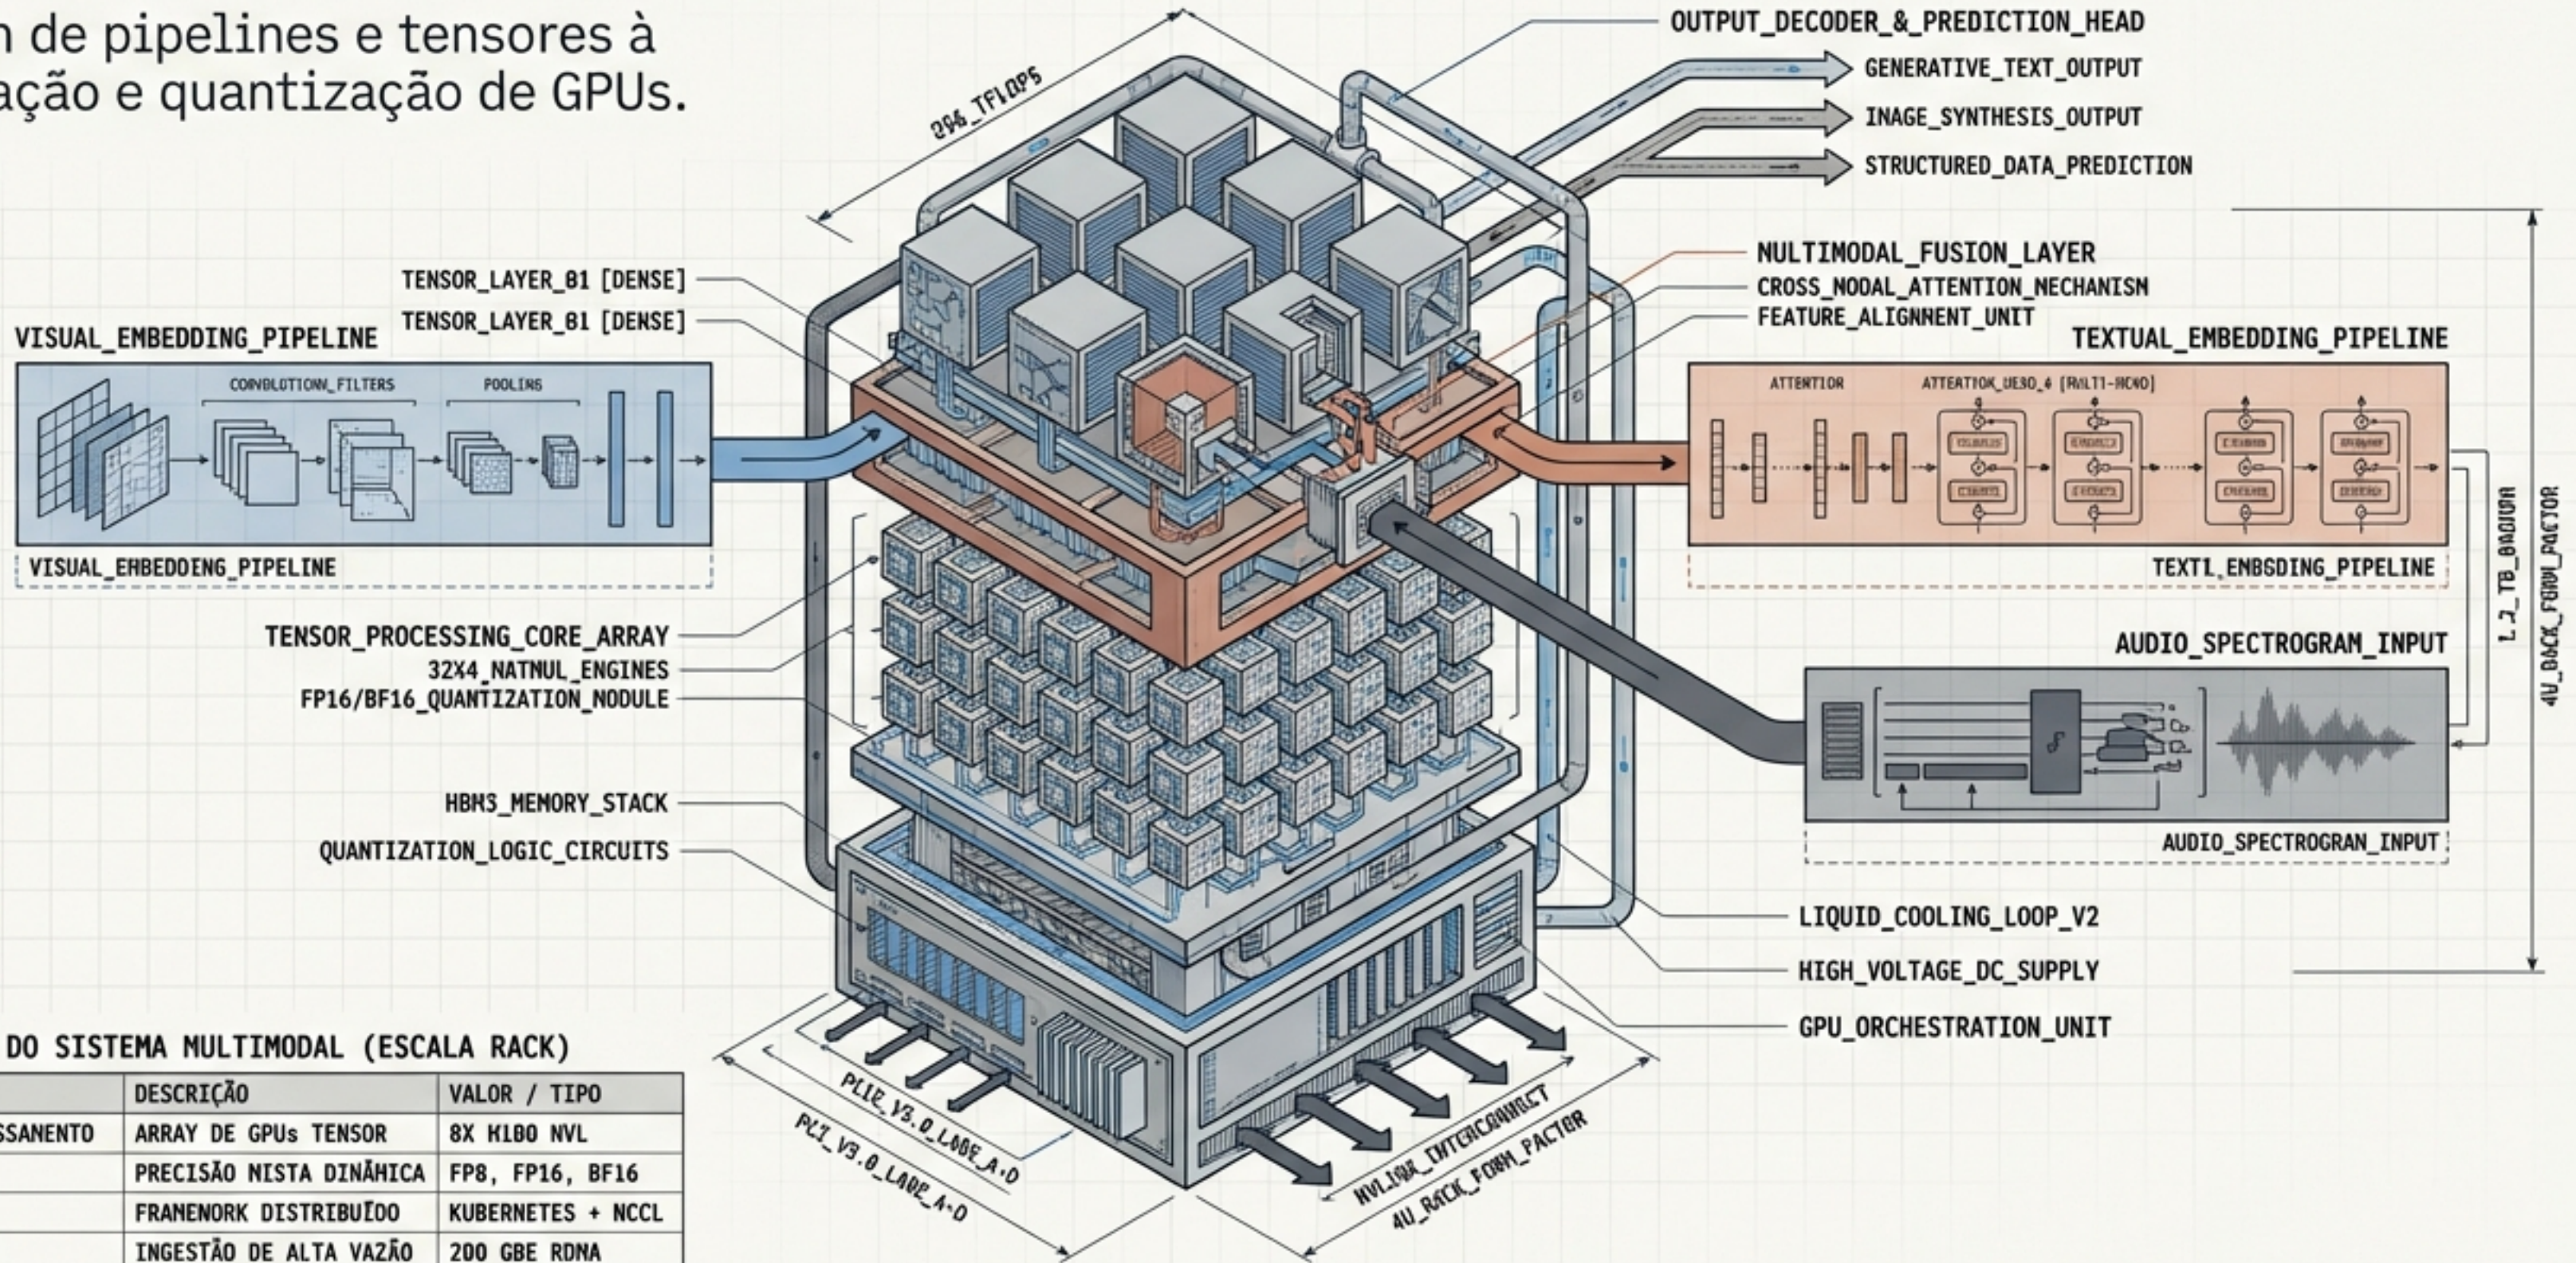


# BLUEPRINT DE SISTEMAS: ARQUITETURA DE IA MULTIMODAL

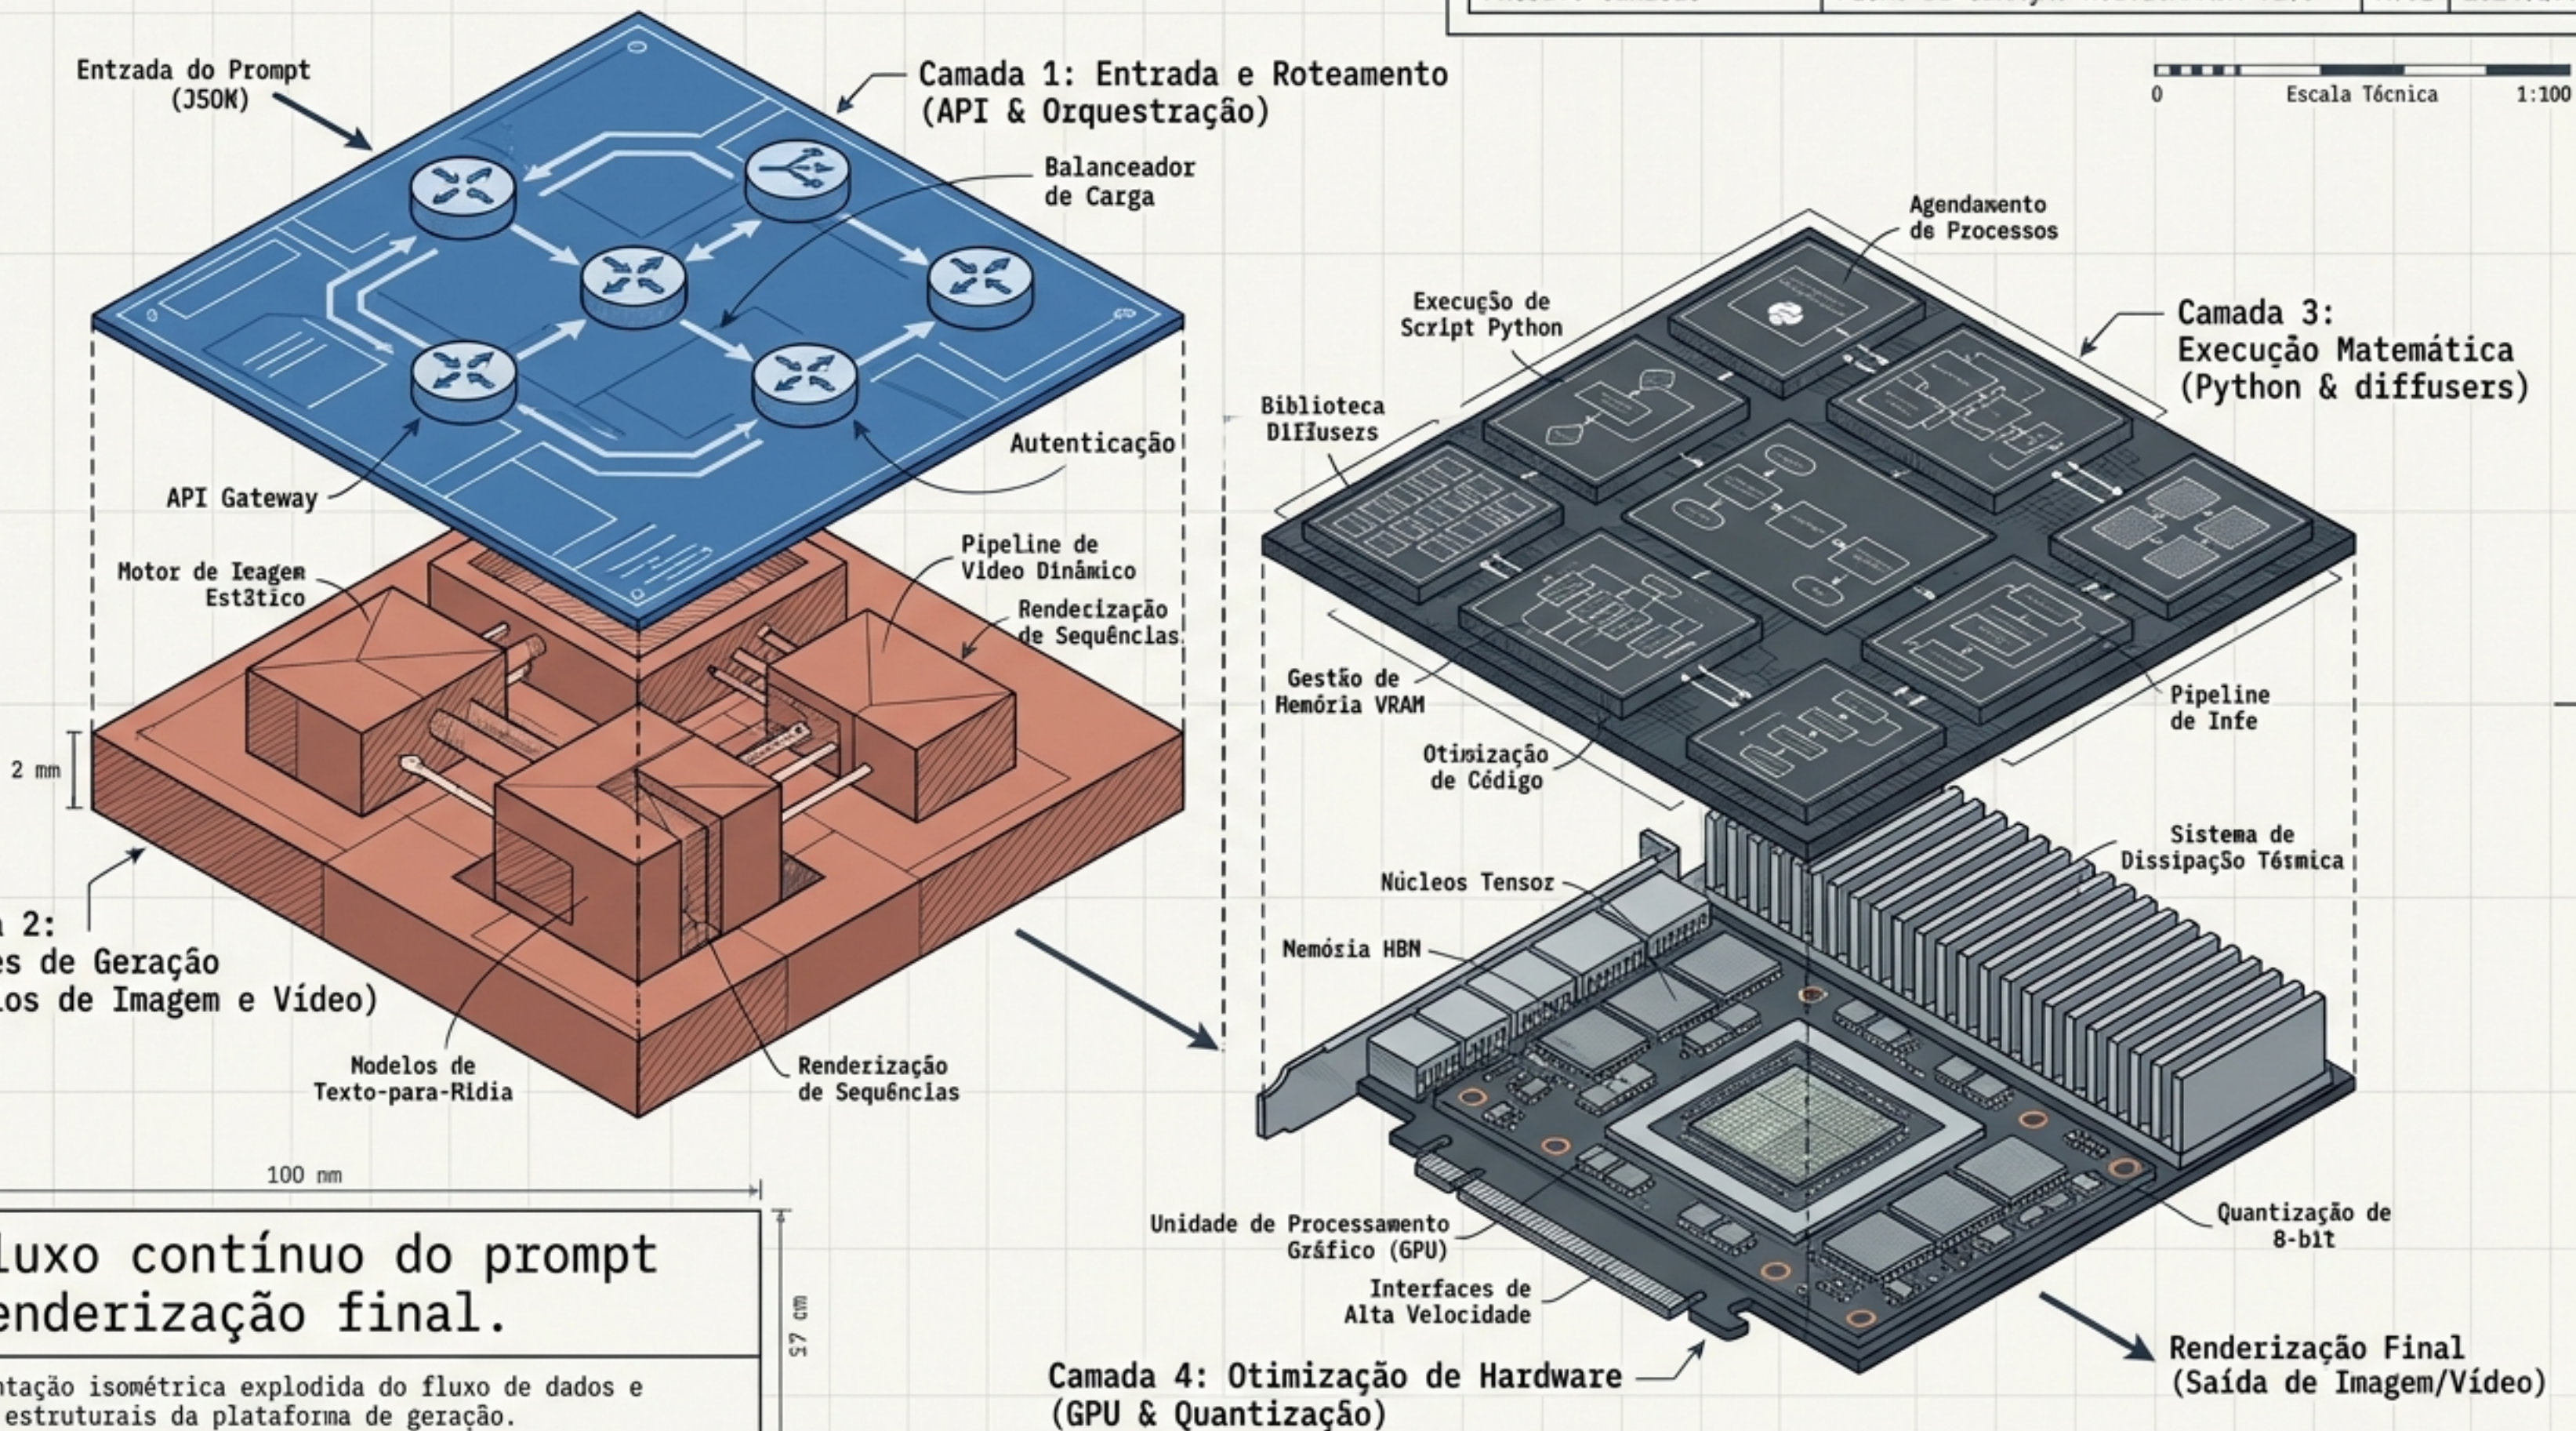
[CONFIDENTIAL / ENGINEERING\_DRAFT\_V1]

Do design de pipelines e tensores à orquestração e quantização de GPUs.



## ESPECIFICAÇÕES DO SISTEMA MULTIMODAL (ESCALA RACK)

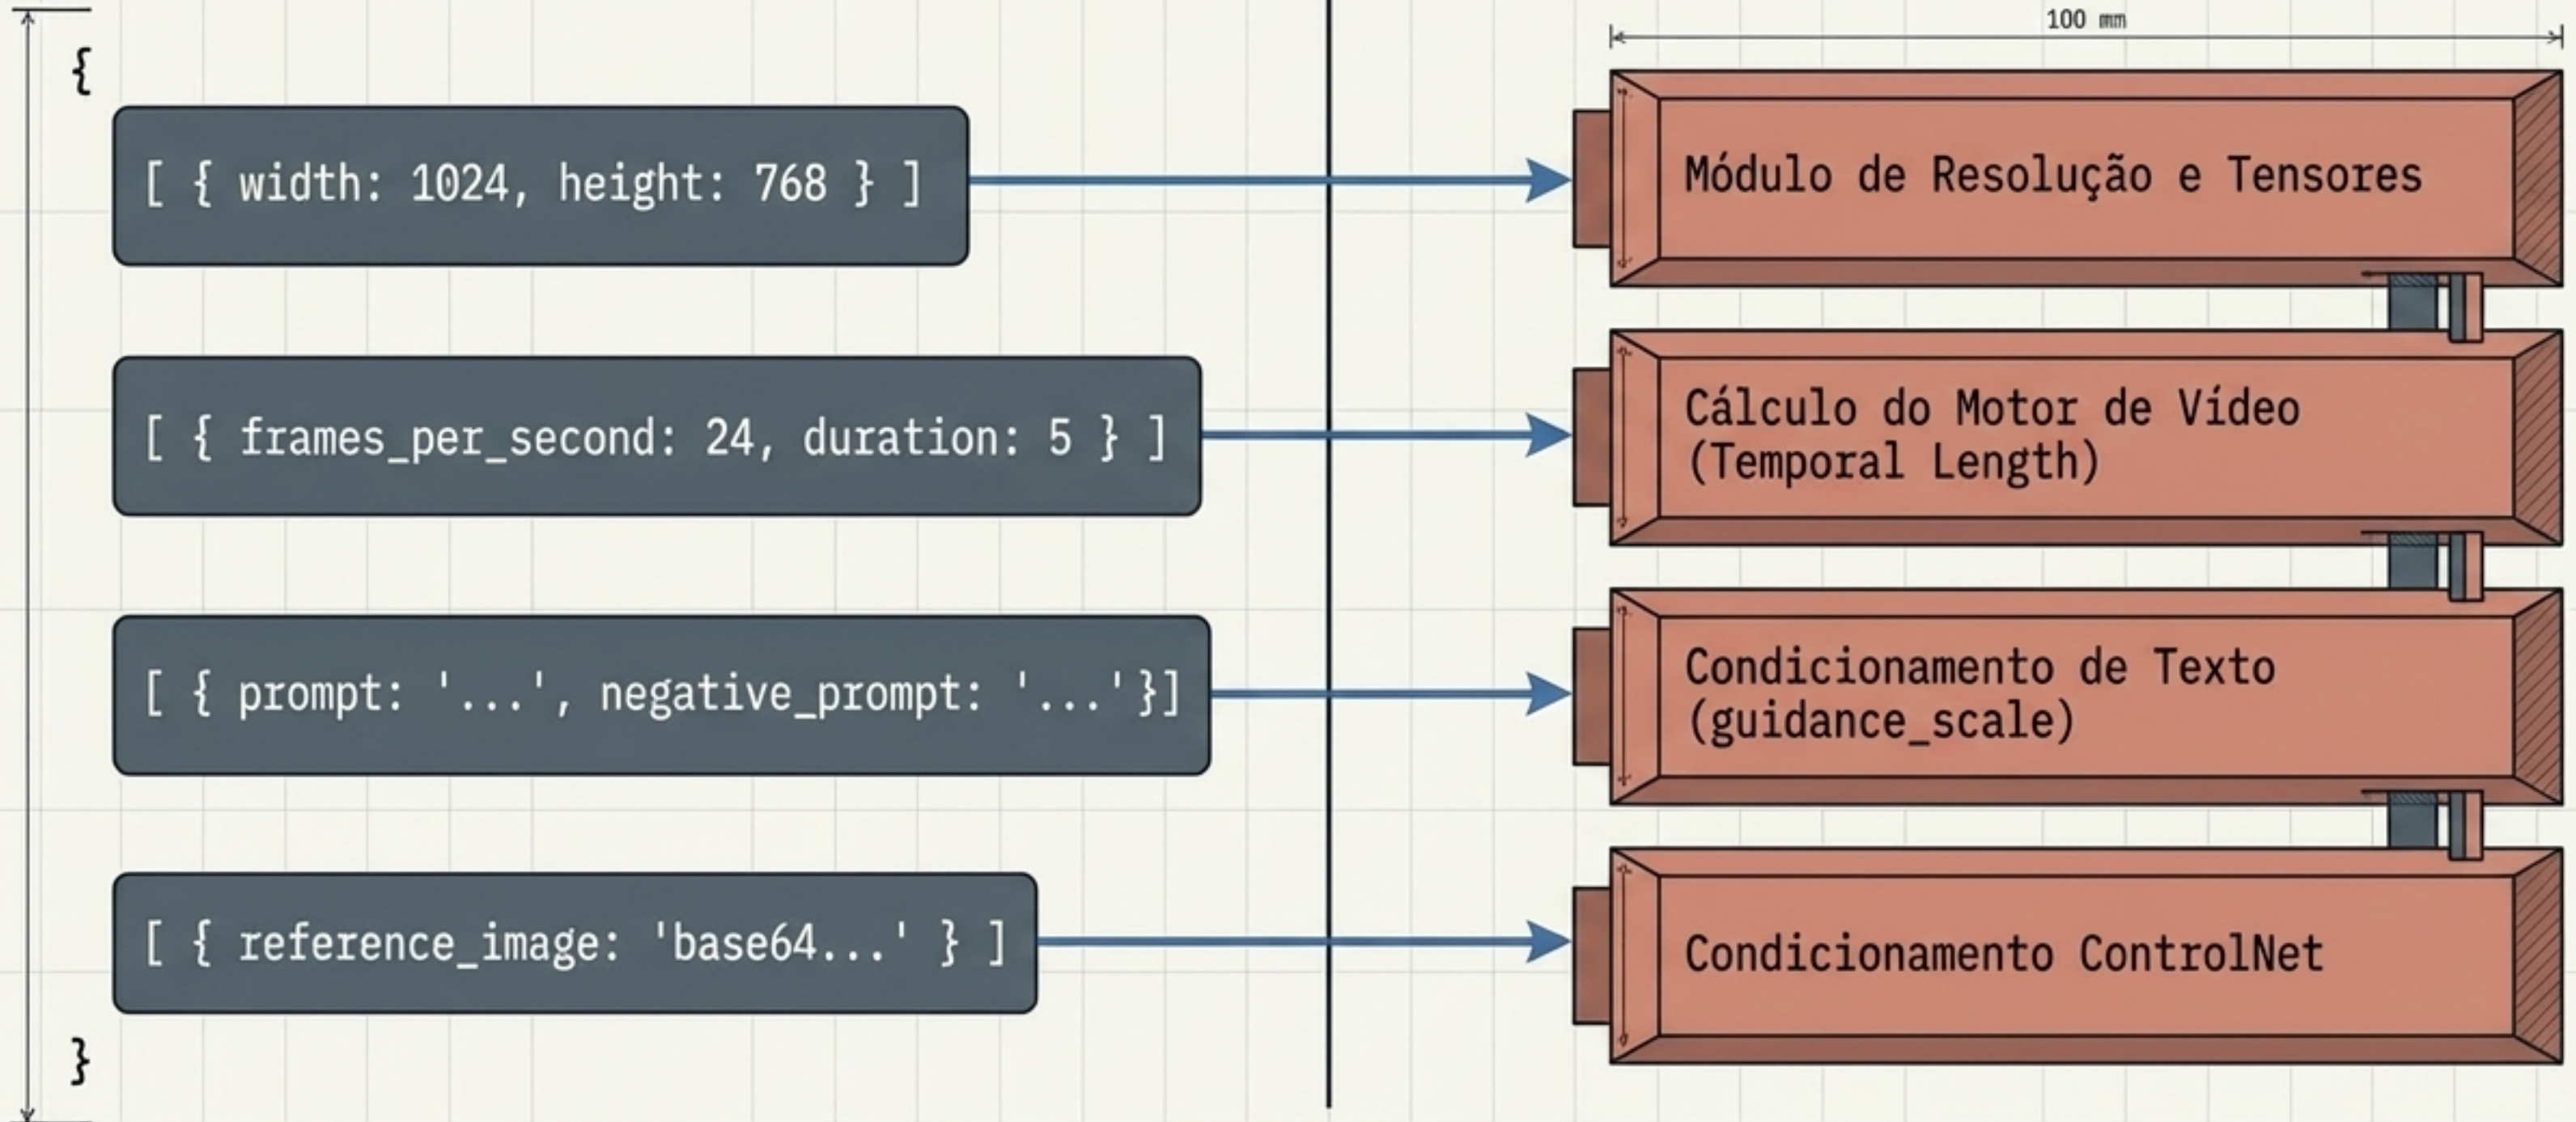
PARÂMETRO	DESCRIÇÃO	VALOR / TIPO
UNIDADES DE PROCESSAMENTO	ARRAY DE GPUS TENSOR	8X H100 NVL
QUANTIZAÇÃO	PRECISÃO NISTA DINÂMICA	FP8, FP16, BF16
ORQUESTRAÇÃO	FRANENORK DISTRIBUÍDO	KUBERNETES + NCCL
PIPELINE DE DADOS	INGESTÃO DE ALTA VAZÃO	200 GBE RDMA
ARMAZENAMENTO	BUFFER DE MODELO	512 GB HBM3 / GPU



# A Ponte API-Backend

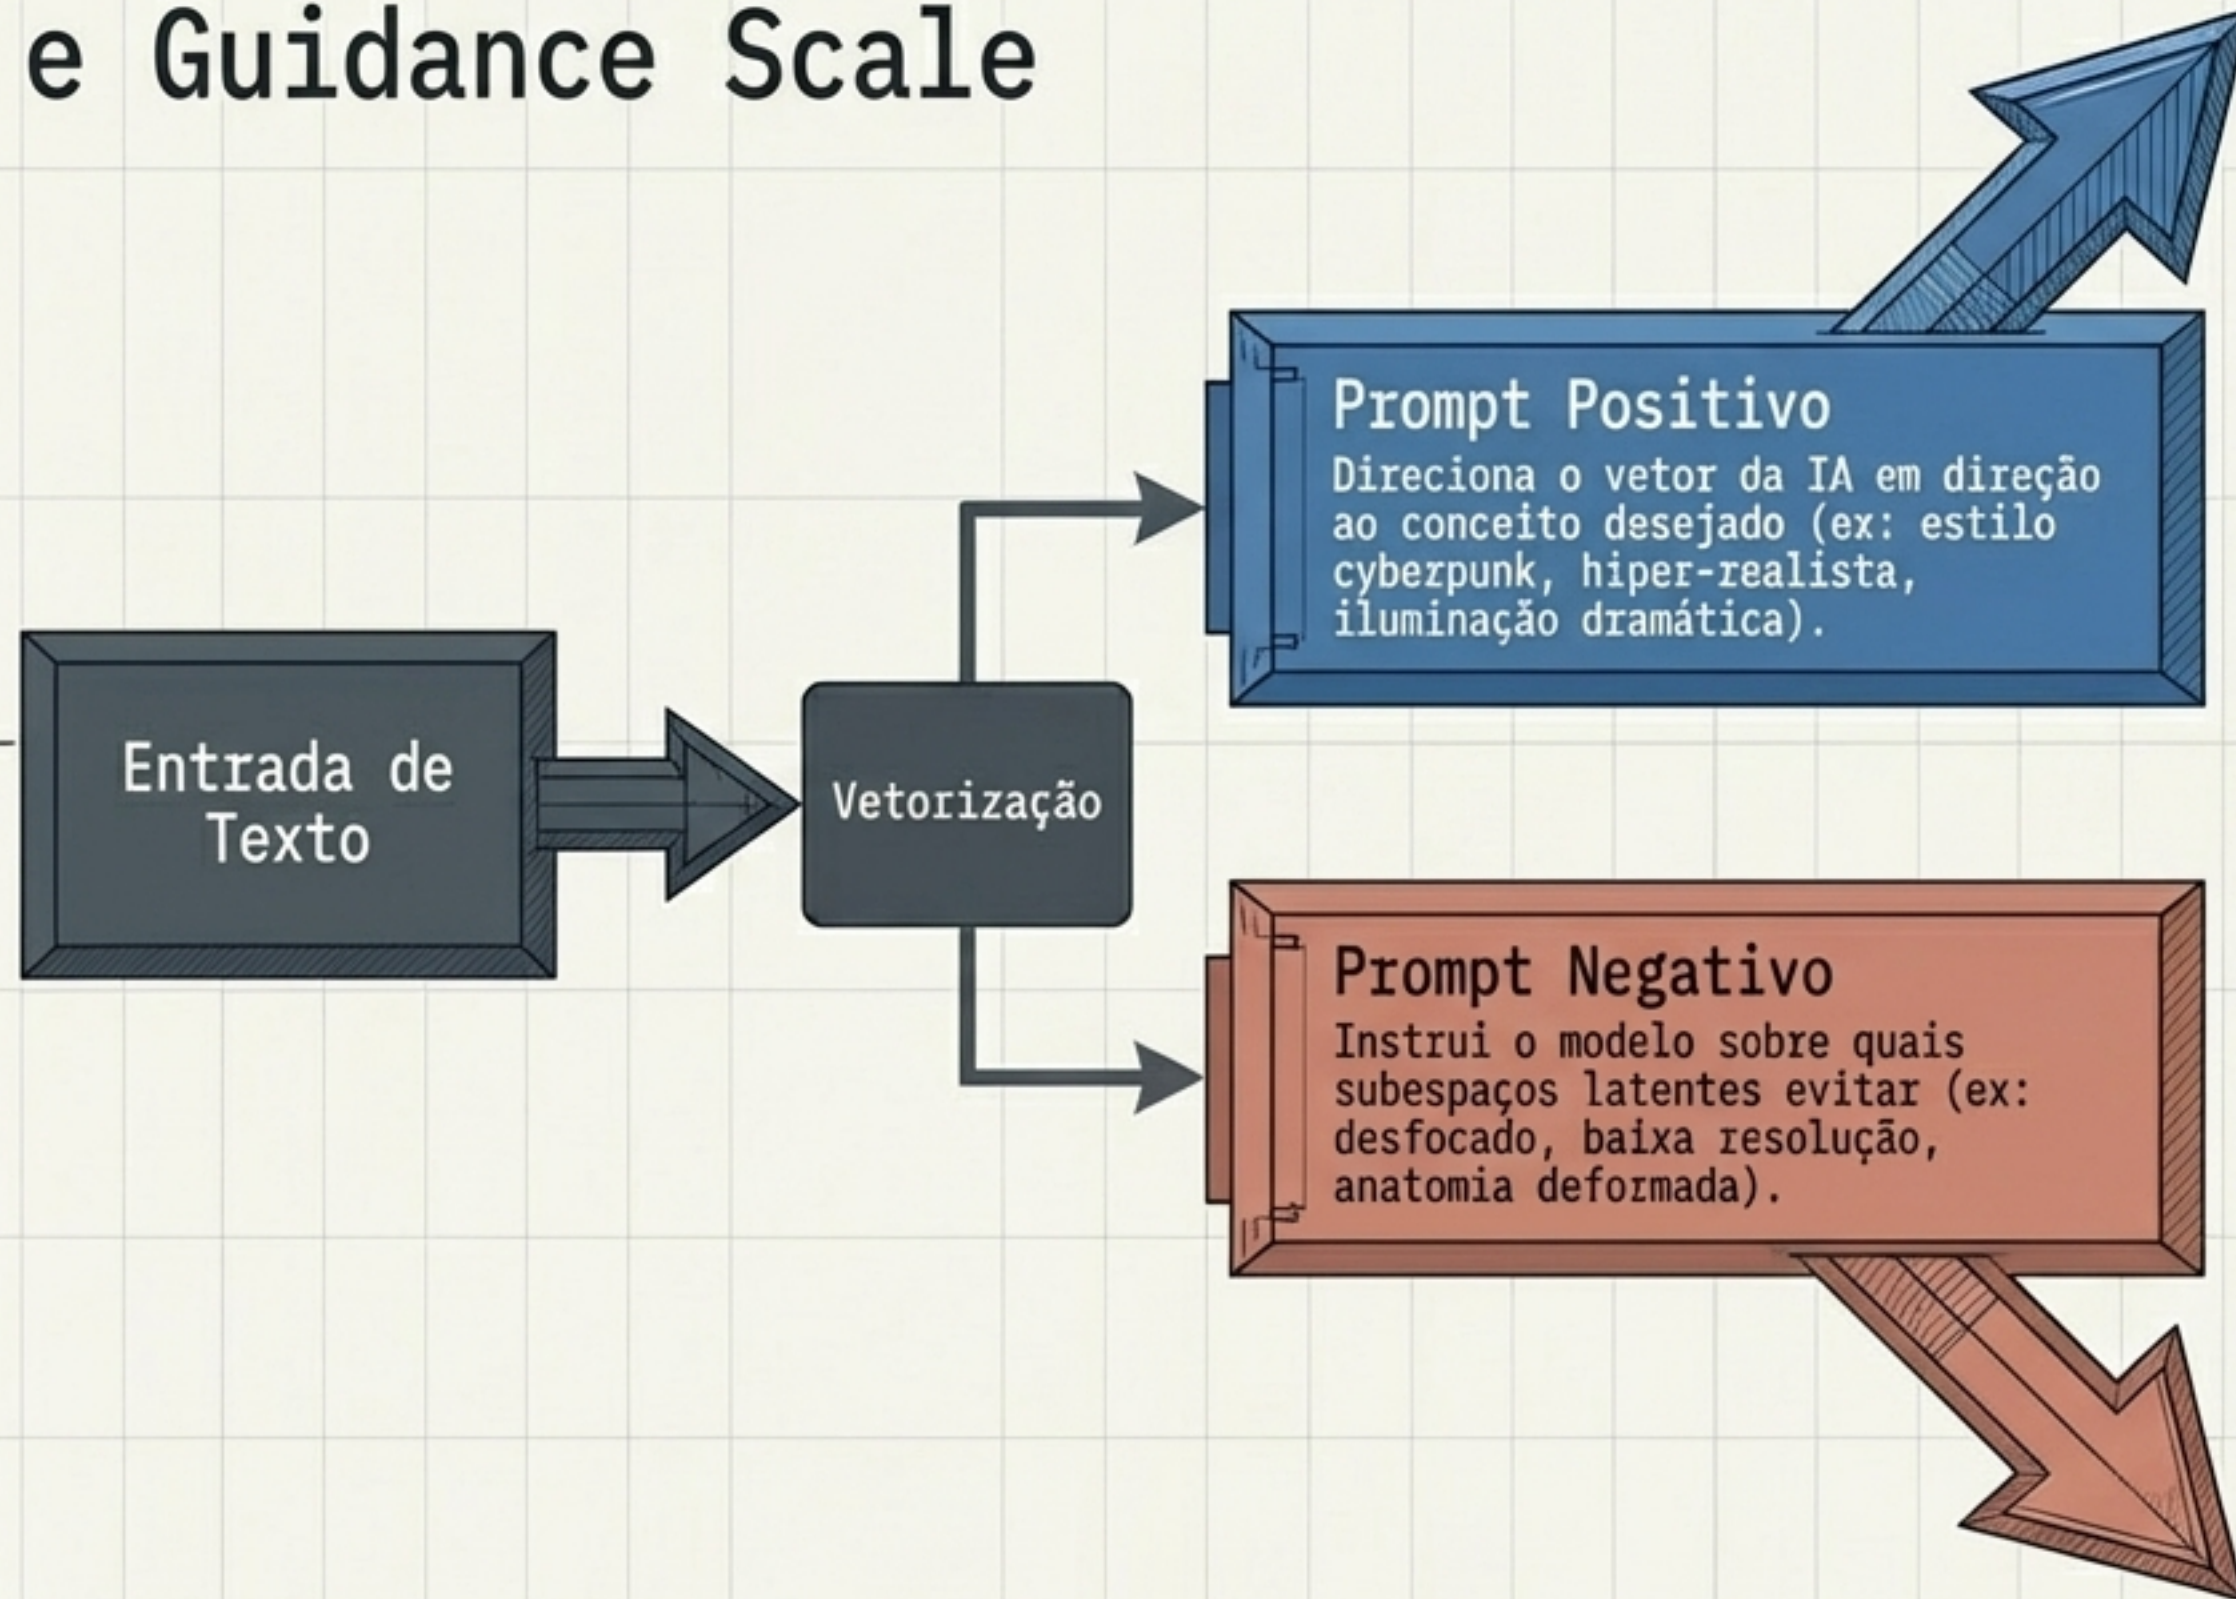
Dados estruturados roteando a intenção criativa diretamente para os pesos da rede neural.

0 Escala Técnica 1:100



# A Mecânica dos Prompts e Guidance Scale

0 Escala Técnica 1:100



Ajusta a força matemática com que a IA segue as diretrizes do prompt contra sua própria distribuição latente.



Escala de Intensidade  
0 1:100

# O Ecossistema da API: Roteamento Inteligente


Balaceando custo computacional e controle criativo.



Usuário  
(Mobile/Web)




Roteador Multimodal  
(Avaliação de Carga e Tipo)



Escala Técnica 0 1-100

Rota A: Geração de Imagem  
Stable Diffusion + ControlNet  
Controle Granular & Open-Source



Rota B: Geração de Vídeo  
APIs Proprietárias  
RunwayML, Pika Labs, Google Veo

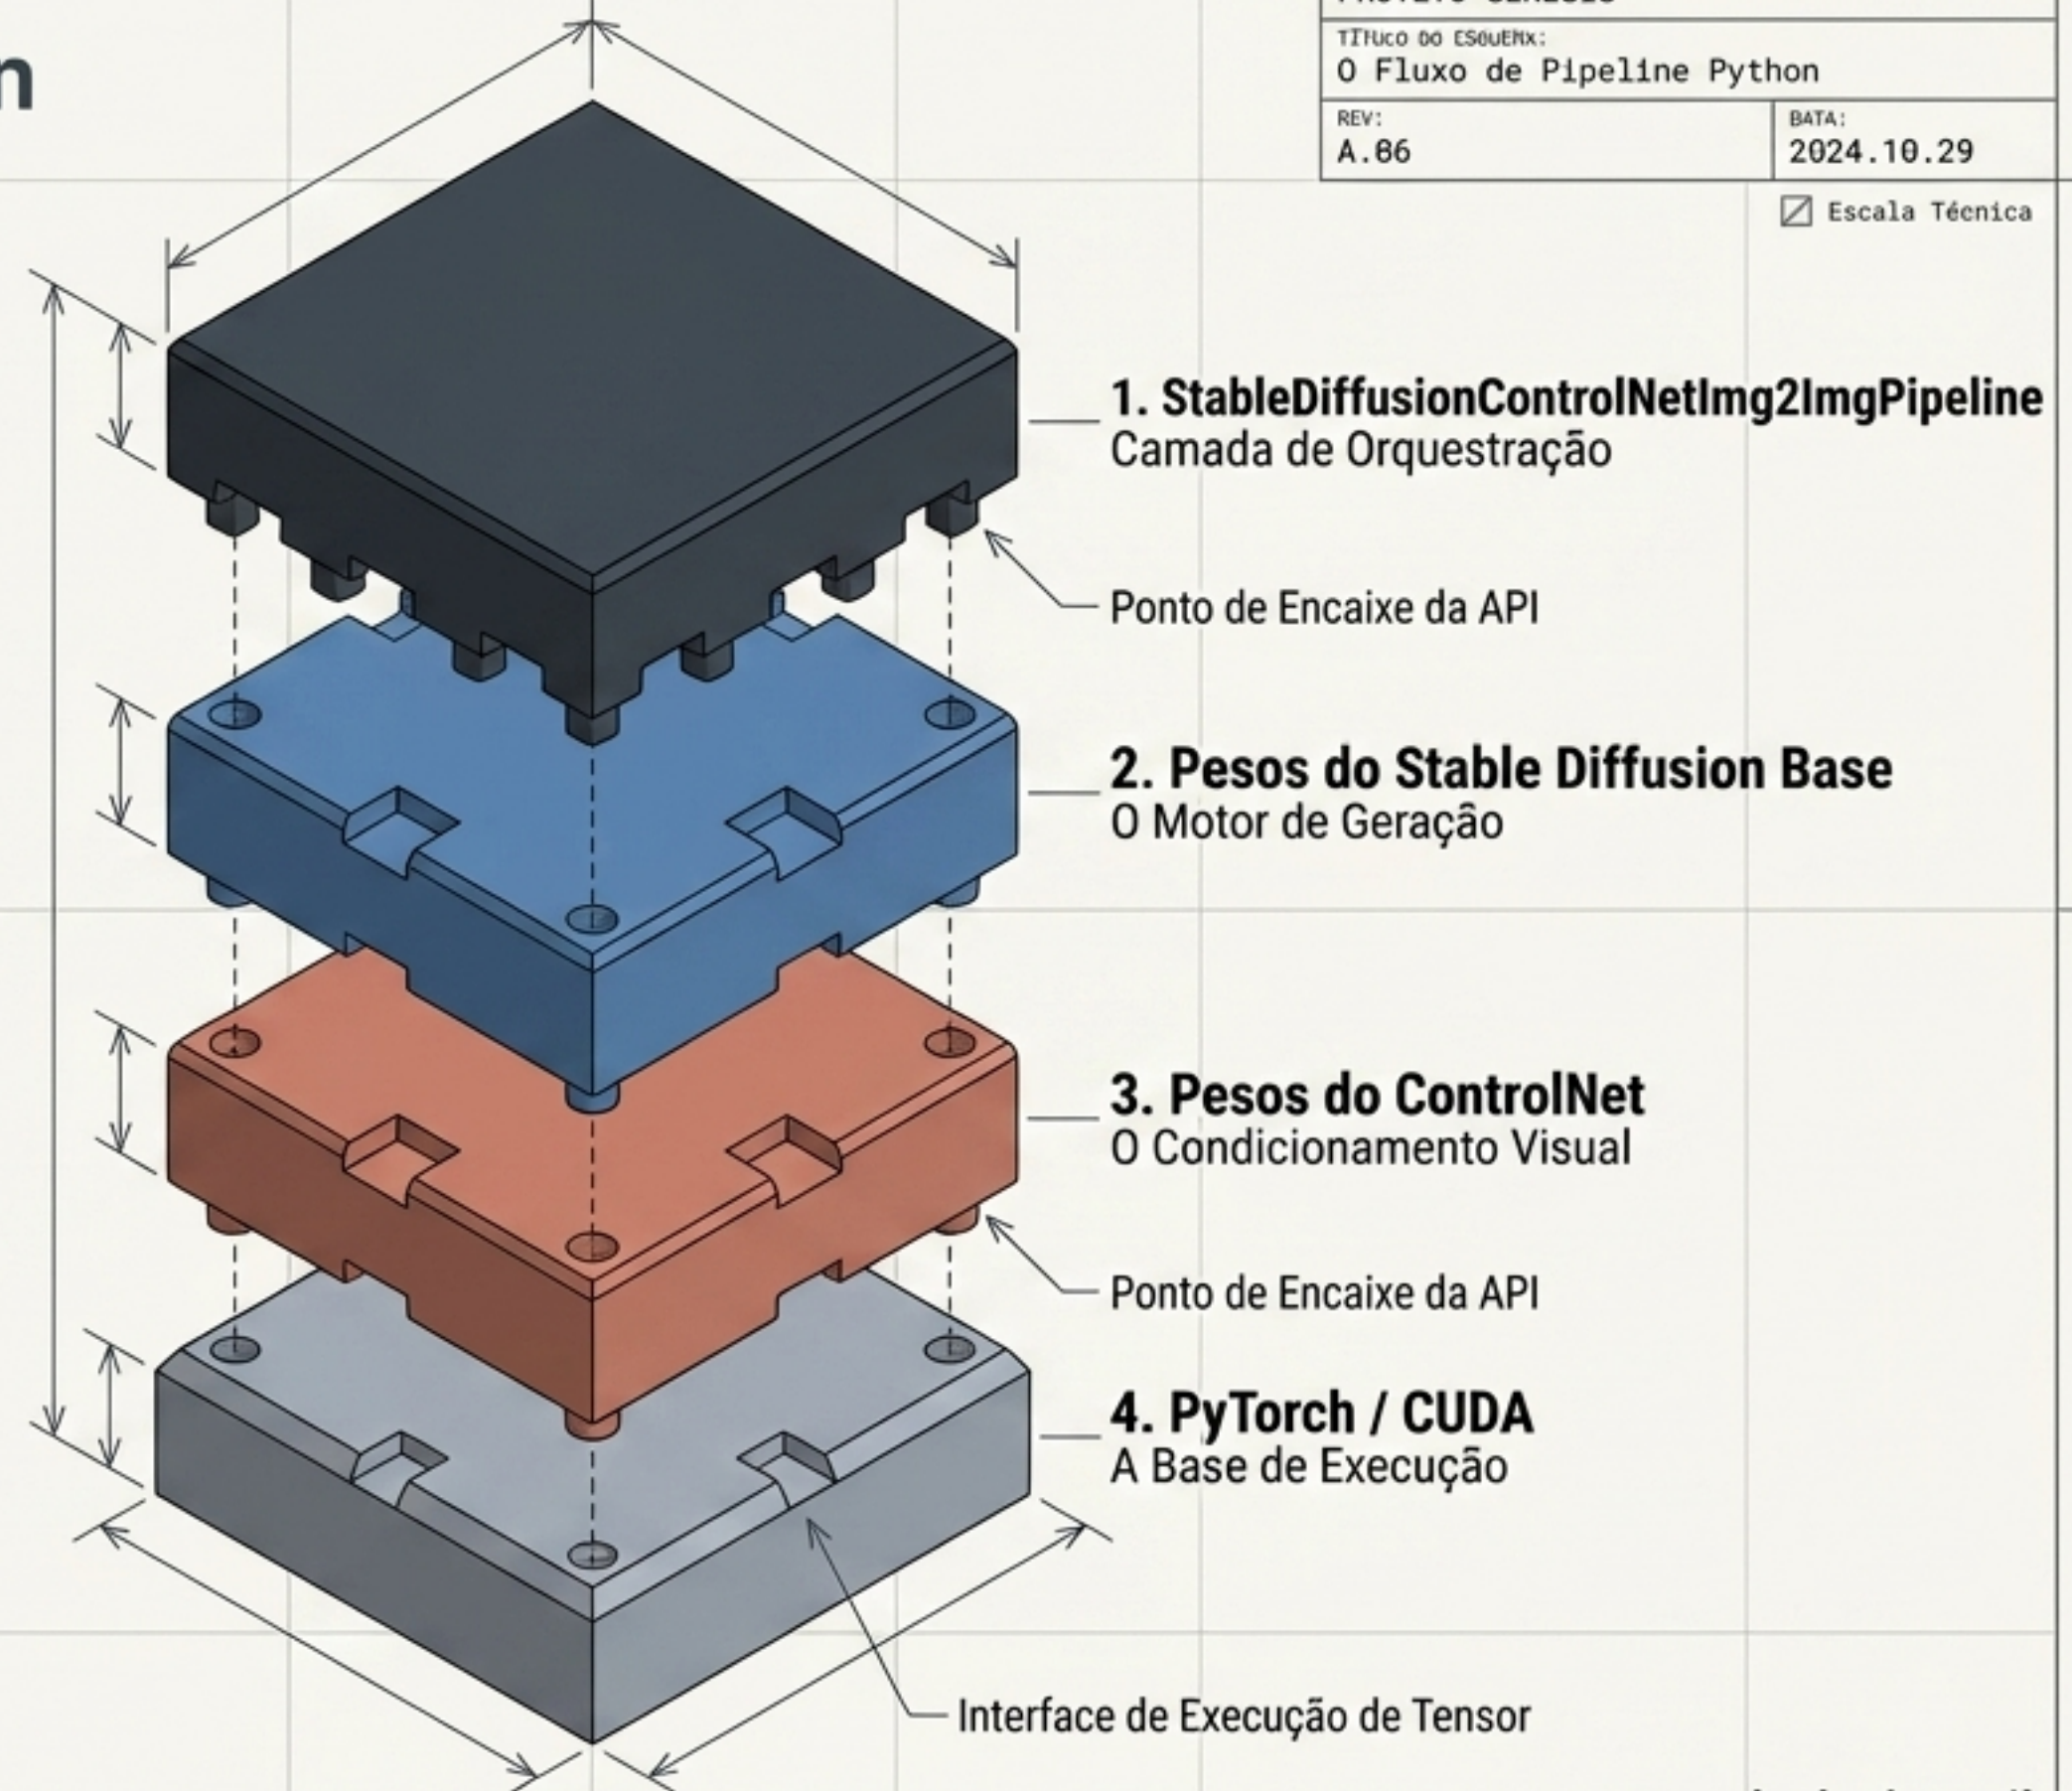
Escala de Intensidade 0 1:100

# 0 Fluxo de Pipeline Python

A biblioteca `diffusers` da Hugging Face atua como a camada de abstração, empilhando modelos de base e condicionadores de forma modular.

PROJETO: PROTETO GENESIS	
TÍTULO DO ESQUEMA: O Fluxo de Pipeline Python	
REV: A.86	BATA: 2024.10.29



Escala Técnica



# A Equação ControlNet

Forçando o modelo principal a respeitar estritamente a estrutura, composição ou pose de uma entrada base.

PROJETO: PROTETO GENESIS	
TÍTULO DO CSOU/DIA: A Equação ControlNet	
REV: A.87	DATA: 2024.10.30

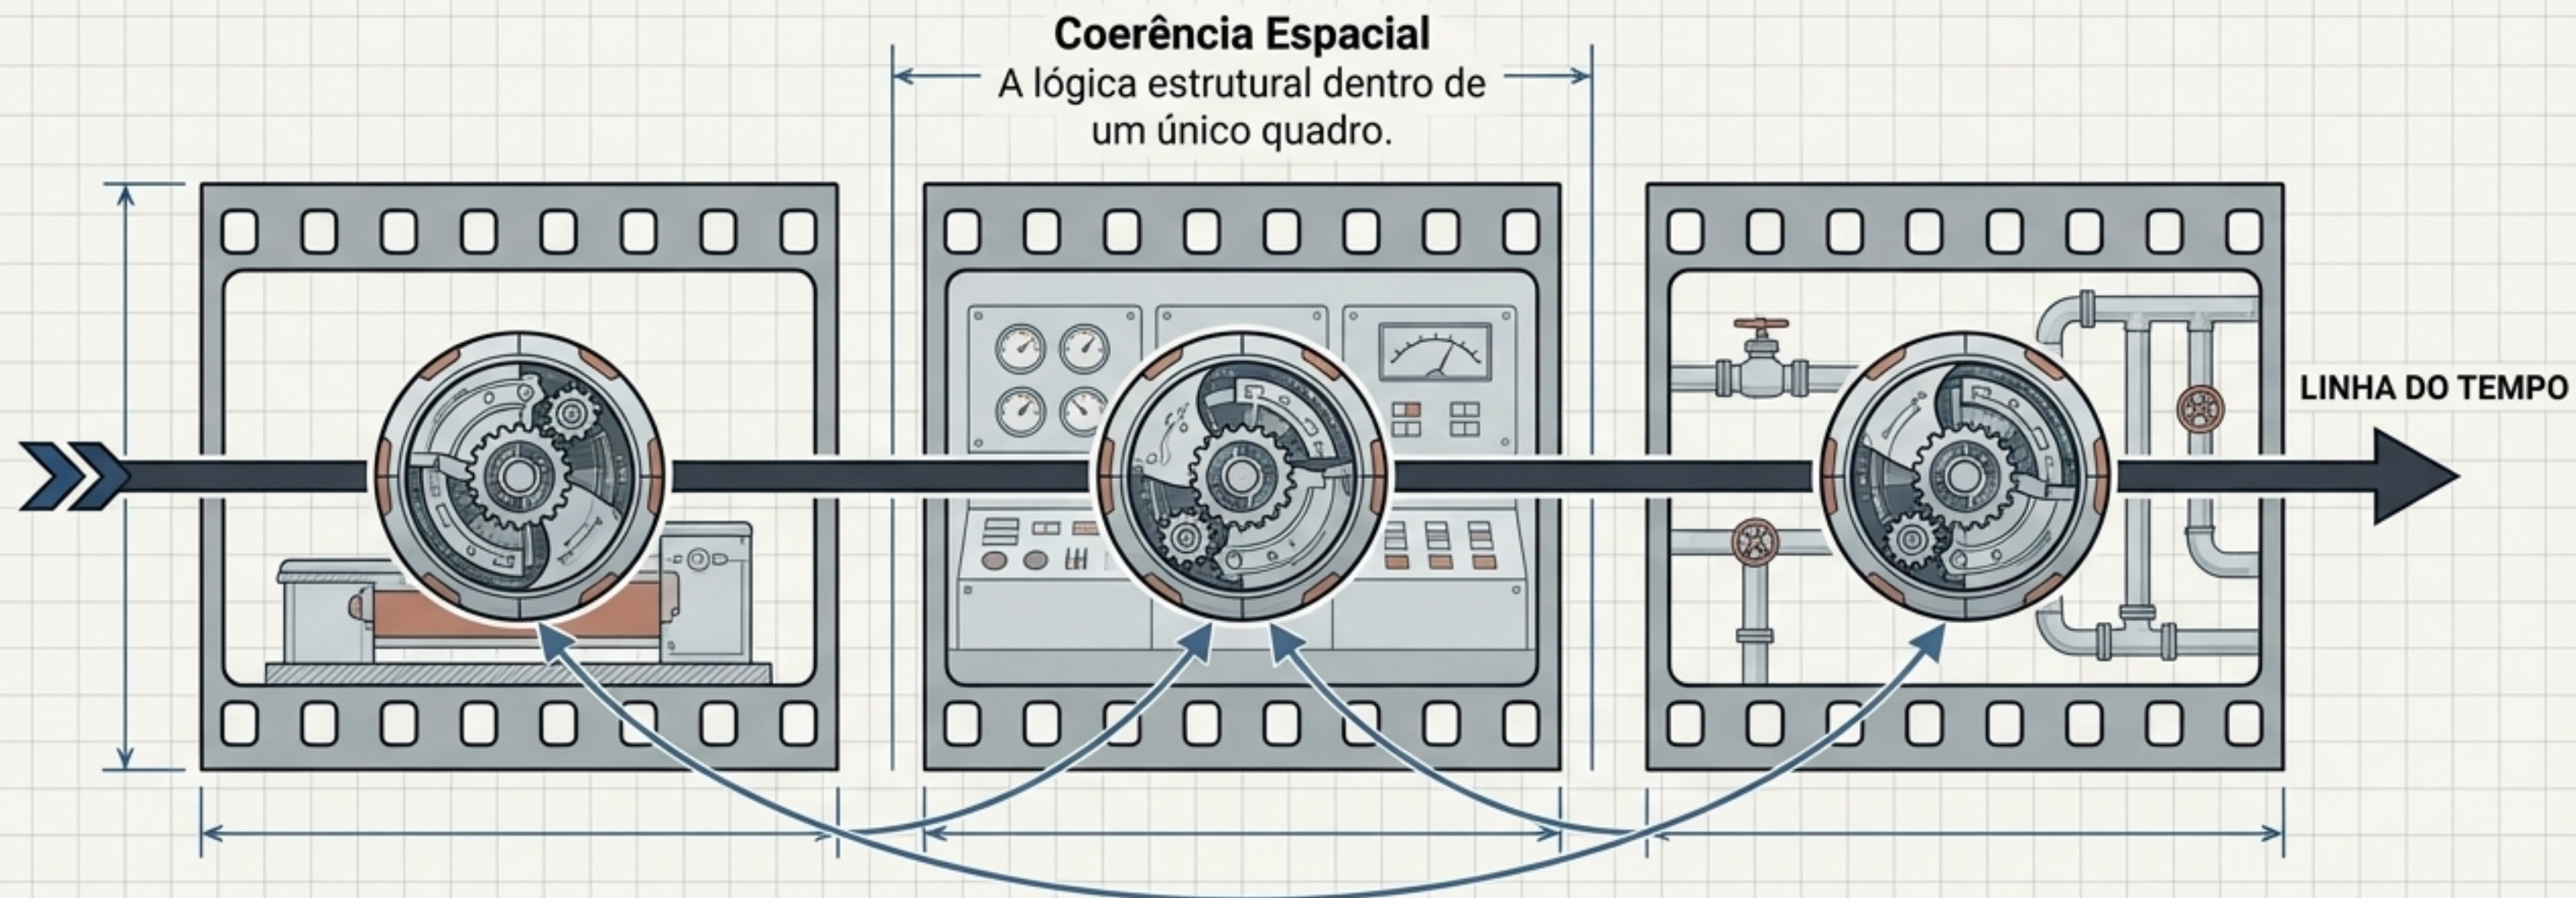


[Imagem de Referência]

[Saída Altamente Fiel]

# A Anatomia da Coerência Temporal

O verdadeiro desafio do vídeo: distinguir 10 quadros contínuos de 10 imagens isoladas.



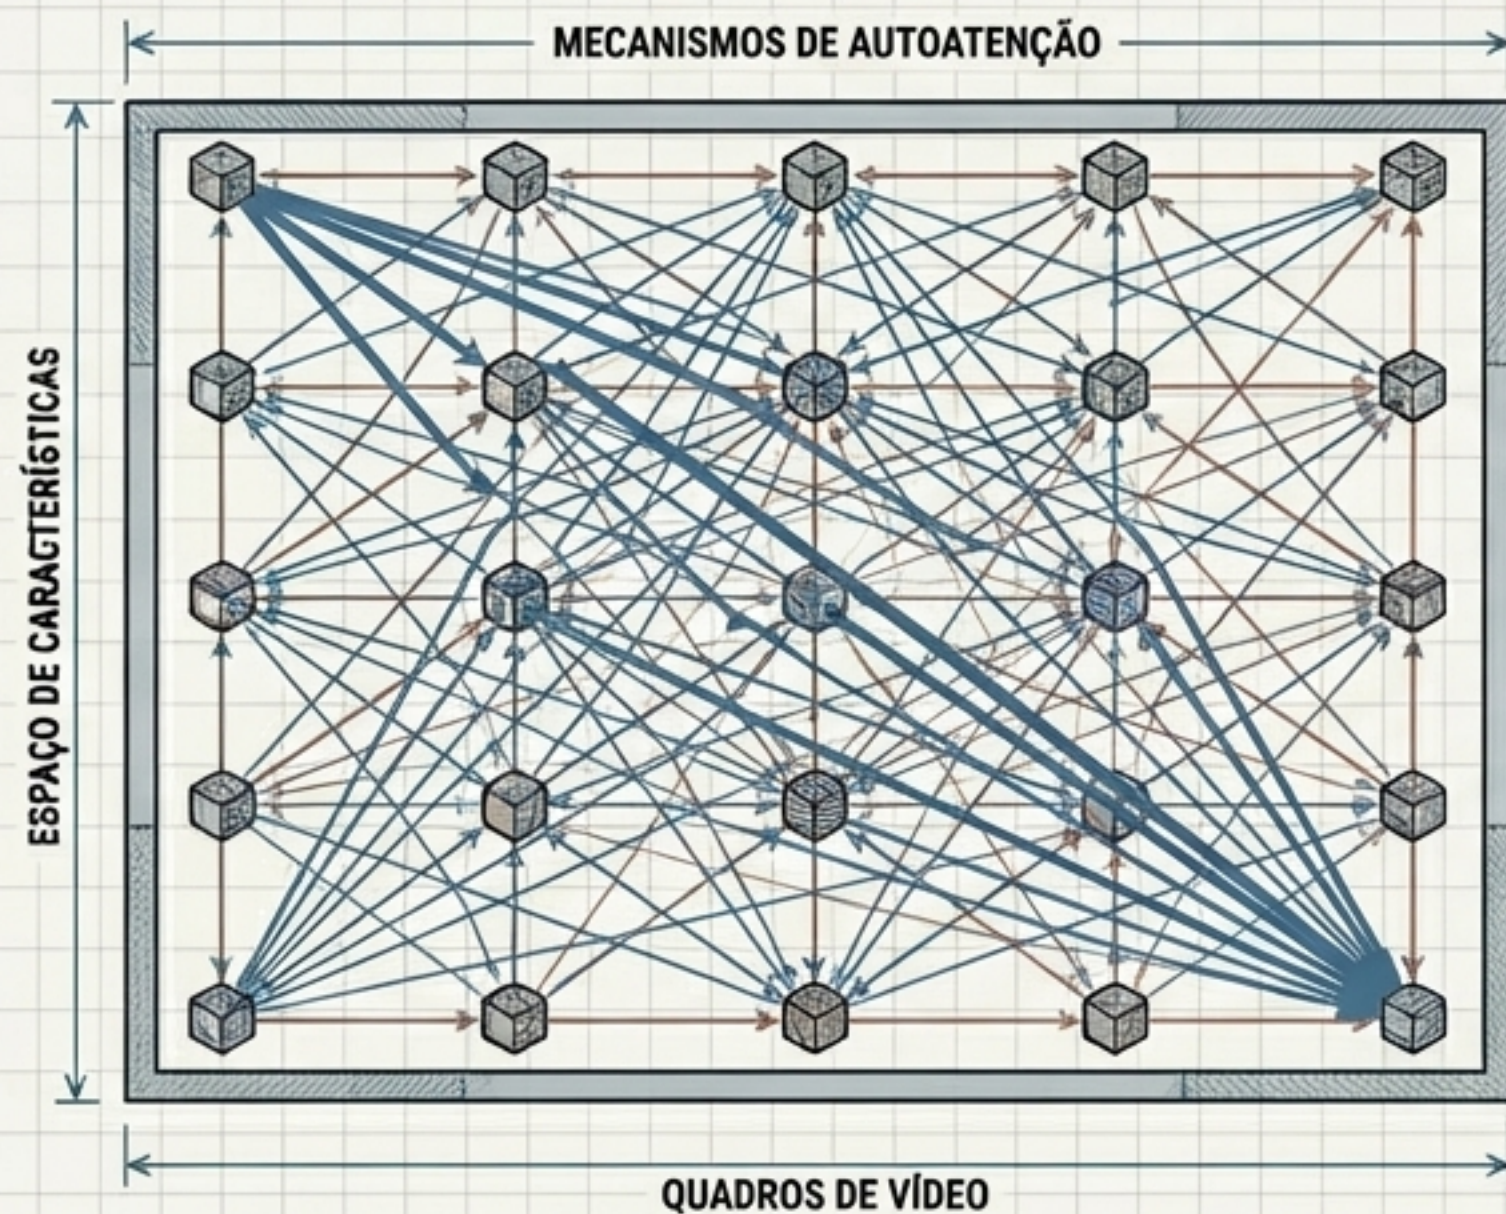
PROJETO: GERAÇÃO DE VÍDEO AVANÇADA		
TÍTULO DO ESQUEMA: A Anatomia da Coerência Temporal		
REV: A.08	DATA: 2024.11.01	ESCALA TÉCNICA 0 2 4 6 8 10

# Arquiteturas de Geração de Vídeo

O debate estrutural no processamento de imagens em movimento.

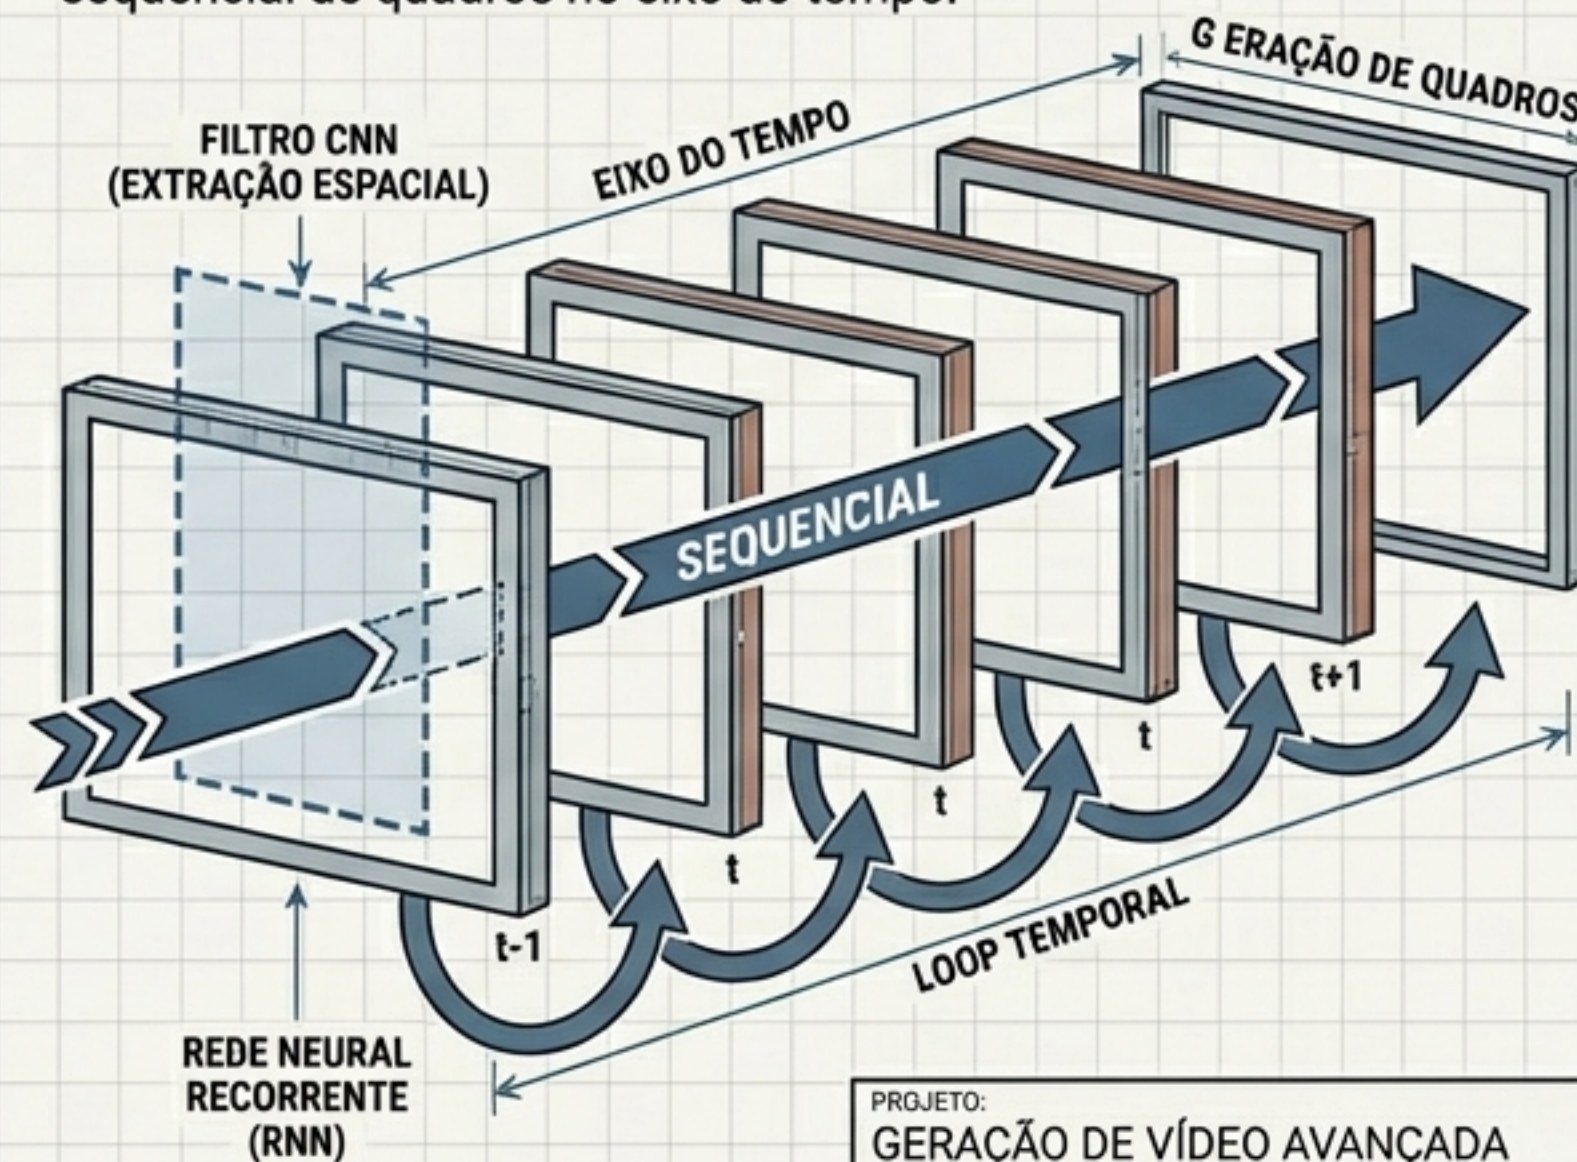
## Modelos Baseados em Transformers

Compreensão holística e de longo alcance temporal. Processamento via mecanismos de autoatenção em todos os quadros simultaneamente.



## Abordagem Híbrida (CNN + RNN)

Extração de características espaciais combinada com geração sequencial de quadros no eixo do tempo.



PRJETO:	GERAÇÃO DE VÍDEO AVANÇADA	
TÍTULO DO ESQUEMA:	Arquiteturas de Geração de Vídeo	
REV:	DATA:	ESCALA TÉCNICA
A.09	2024.11.02	0 2 4 6 8 10

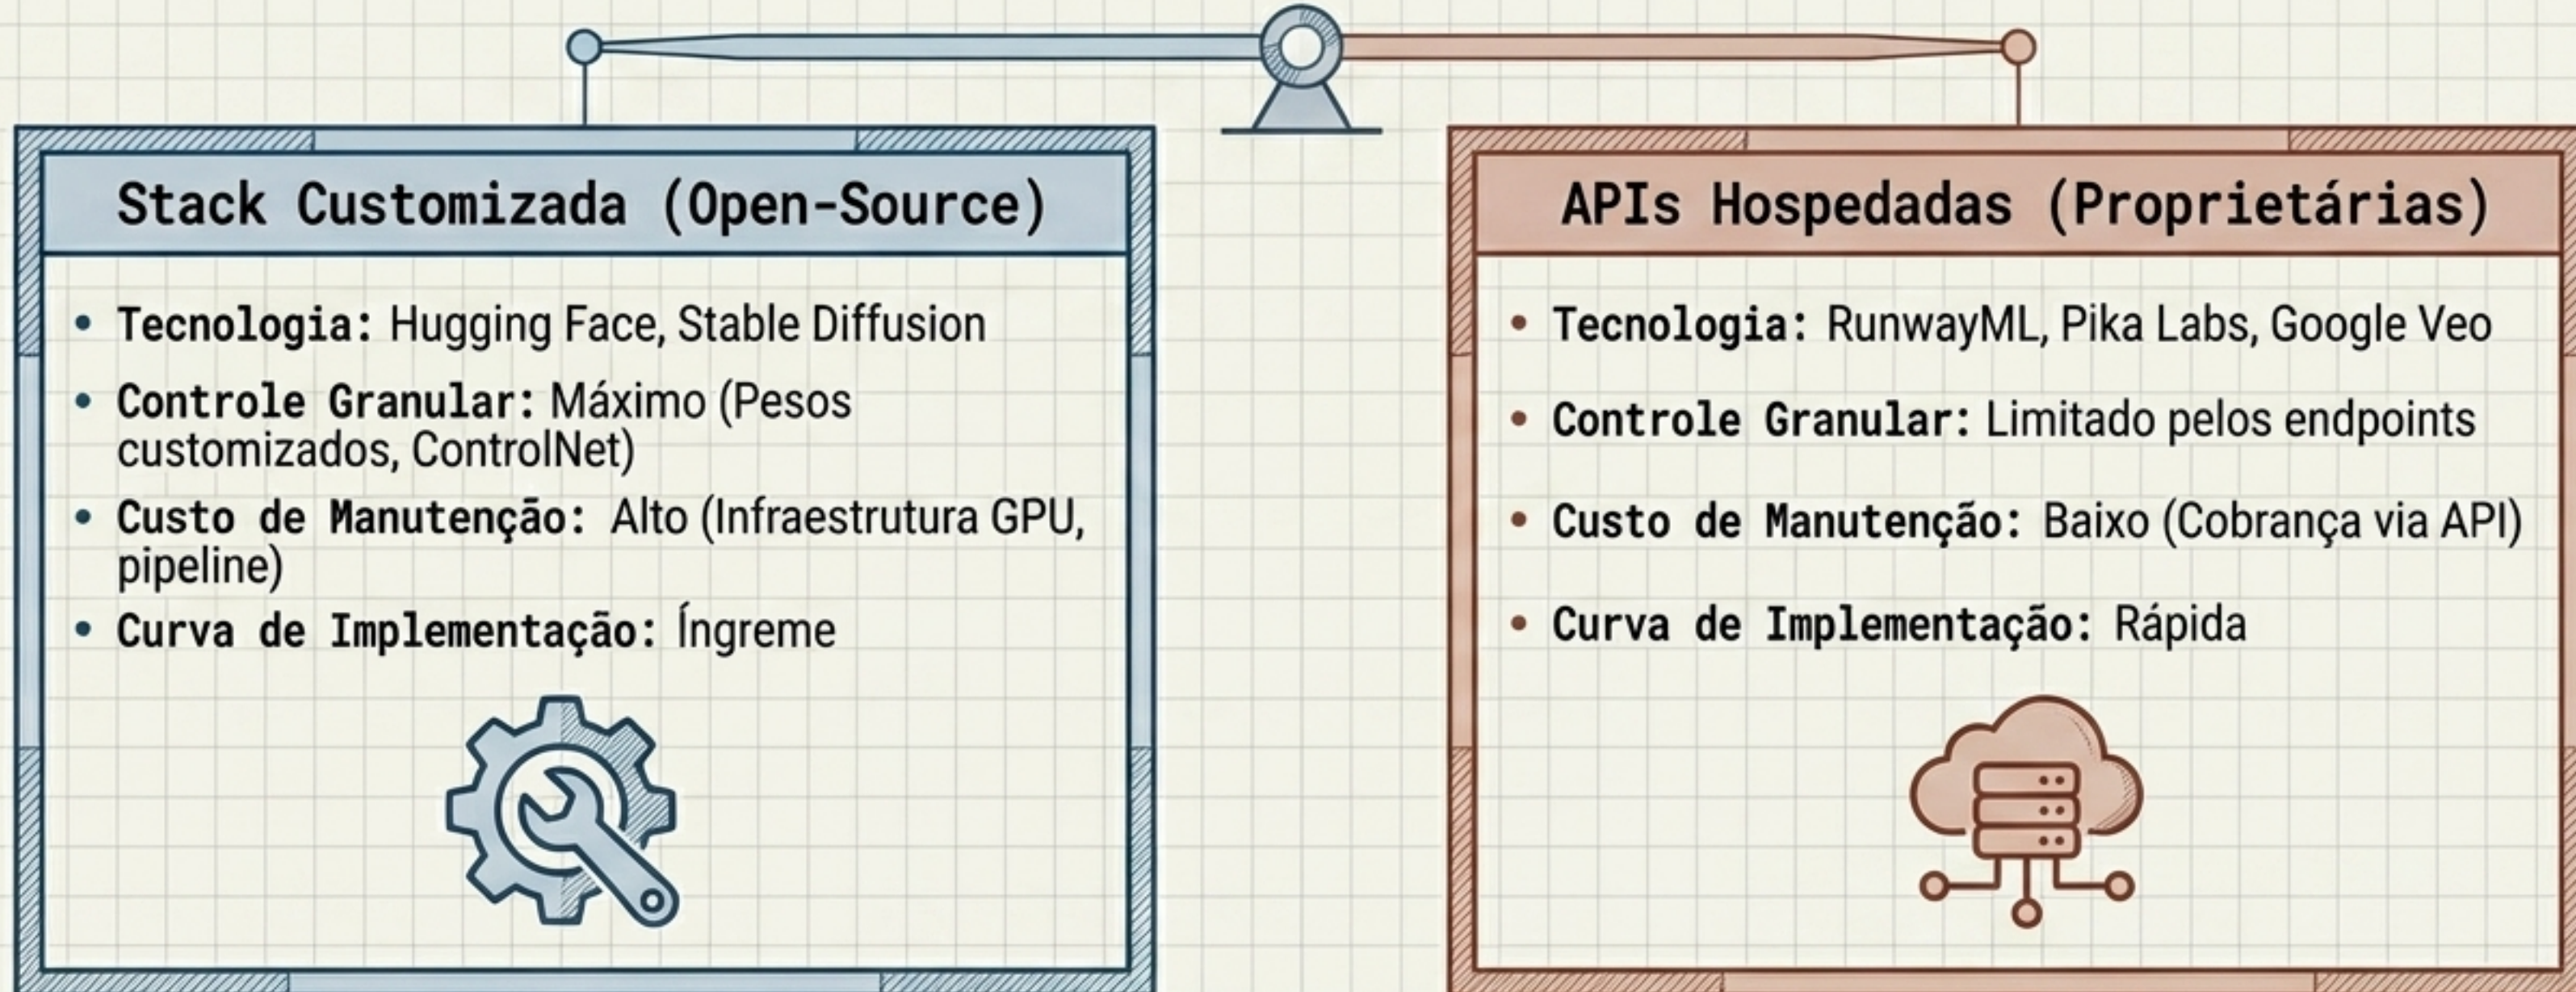
# Matriz de Geração: Imagem vs. Vídeo

Dimensão	Motor de Imagem	Motor de Vídeo
Complexidade Principal	Coerência Espacial	Coerência Temporal & Física
Arquitetura Dominante	Difusão Padrão (Stable Diffusion)	Transformers de Vídeo / CNN+RNN
Custo Computacional	Baixo/Moderado (Frame único)	Exponencial (Atenção cross-frame)
Controle de Saída	Alto (ControlNet)	Moderado (Recursos limitados de movimento)

PRGJETO: GERAÇÃO DE VÍDEO AVANÇADA		
TÍTULO DO ESQUEMA: Matriz de Geração: Imagem vs. Vídeo		
REV: A.10	DATA: 2024.11.03	ESCALA TÉCNICA 0 2 4 6 8 10

# Matriz de Decisão Arquitetônica

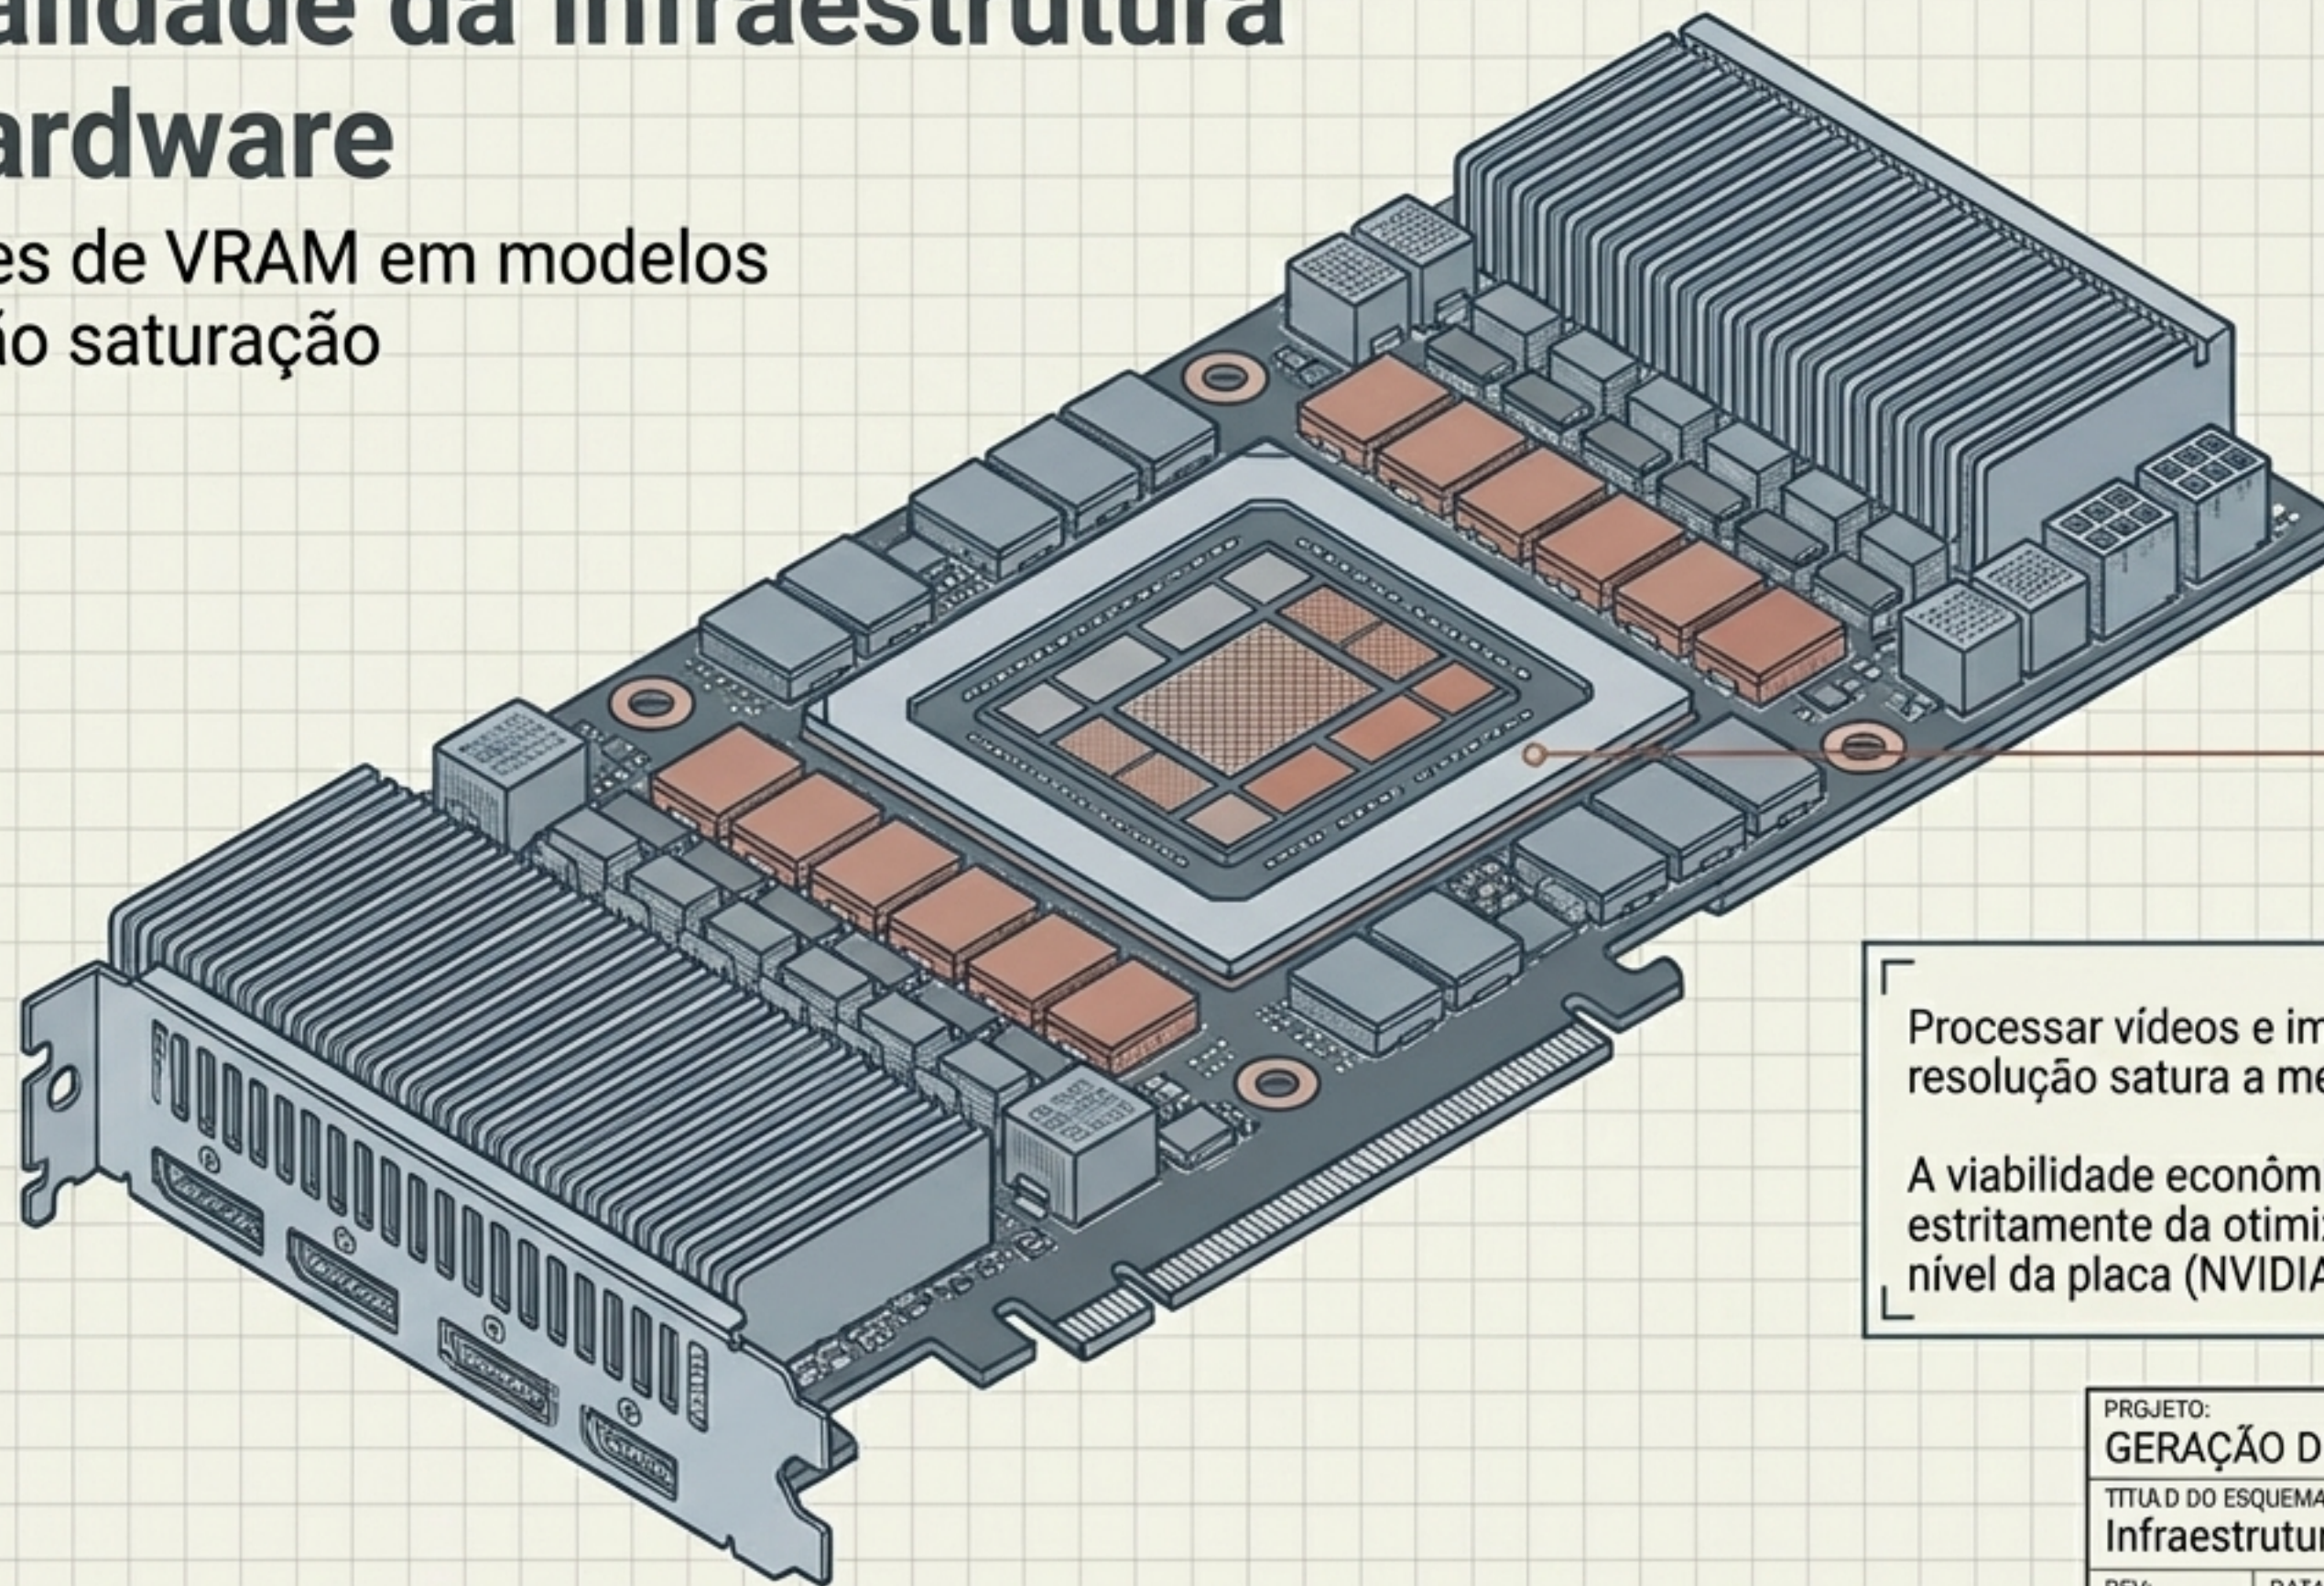
Open-Source vs. APIs Proprietárias



PRGJETO: GERAÇÃO DE VÍDEO AVANÇADA		
TÍTULO DO ESQUEMA: Matriz de Decisão Arquitetônica		
REV: A.11	DATA: 2024.11.04	ESCALA TÉCNICA 0 2 4 6 8 10


# A Realidade da Infraestrutura de Hardware

Restrições de VRAM em modelos de difusão saturação



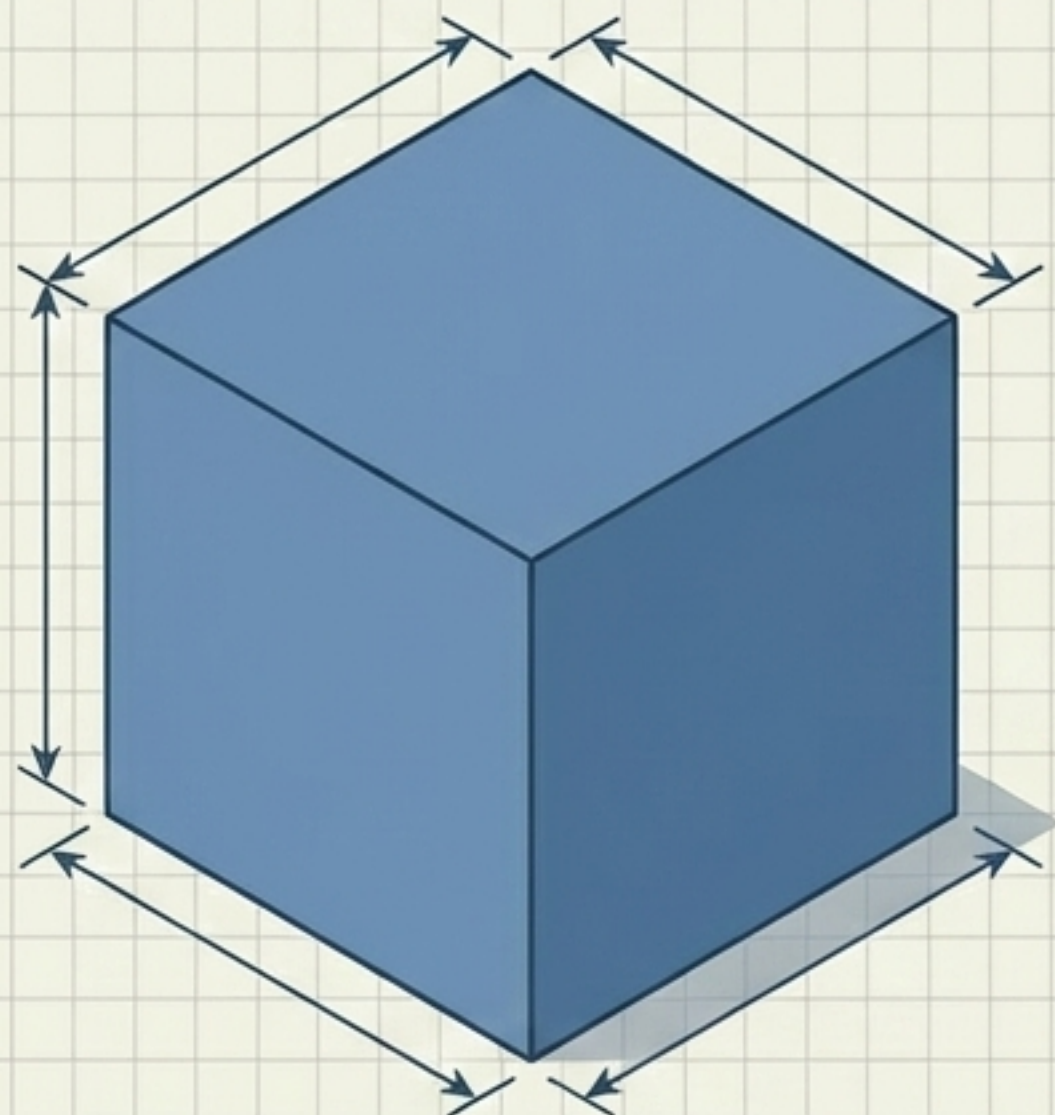
Processar vídeos e imagens em alta resolução satura a memória rapidamente.

A viabilidade econômica do software depende estritamente da otimização matemática no nível da placa (NVIDIA A100 / H100).

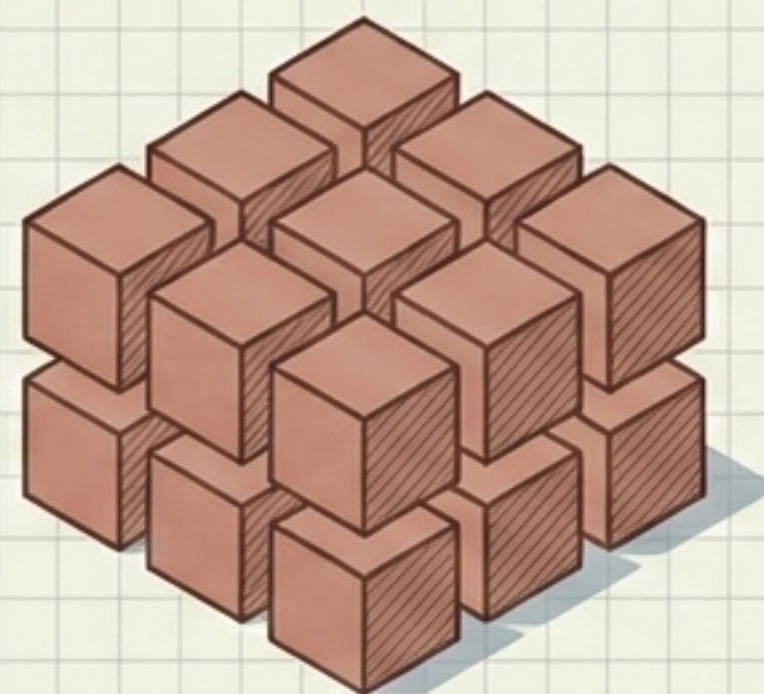

PRGJETO: <b>GERAÇÃO DE VÍDEO AVANÇADA</b>		
TÍTULO DO ESQUEMA: <b>Infraestrutura e VRAM</b>		
REV: <b>A.12</b>	DATA: <b>2024.11.05</b>	ESCALA TÉCNICA 

# Otimização via Quantização

Implementação via biblioteca BitsAndBytes: comprimindo parâmetros para reduzir o gargalo de memória sem sacrificar a coerência visual.



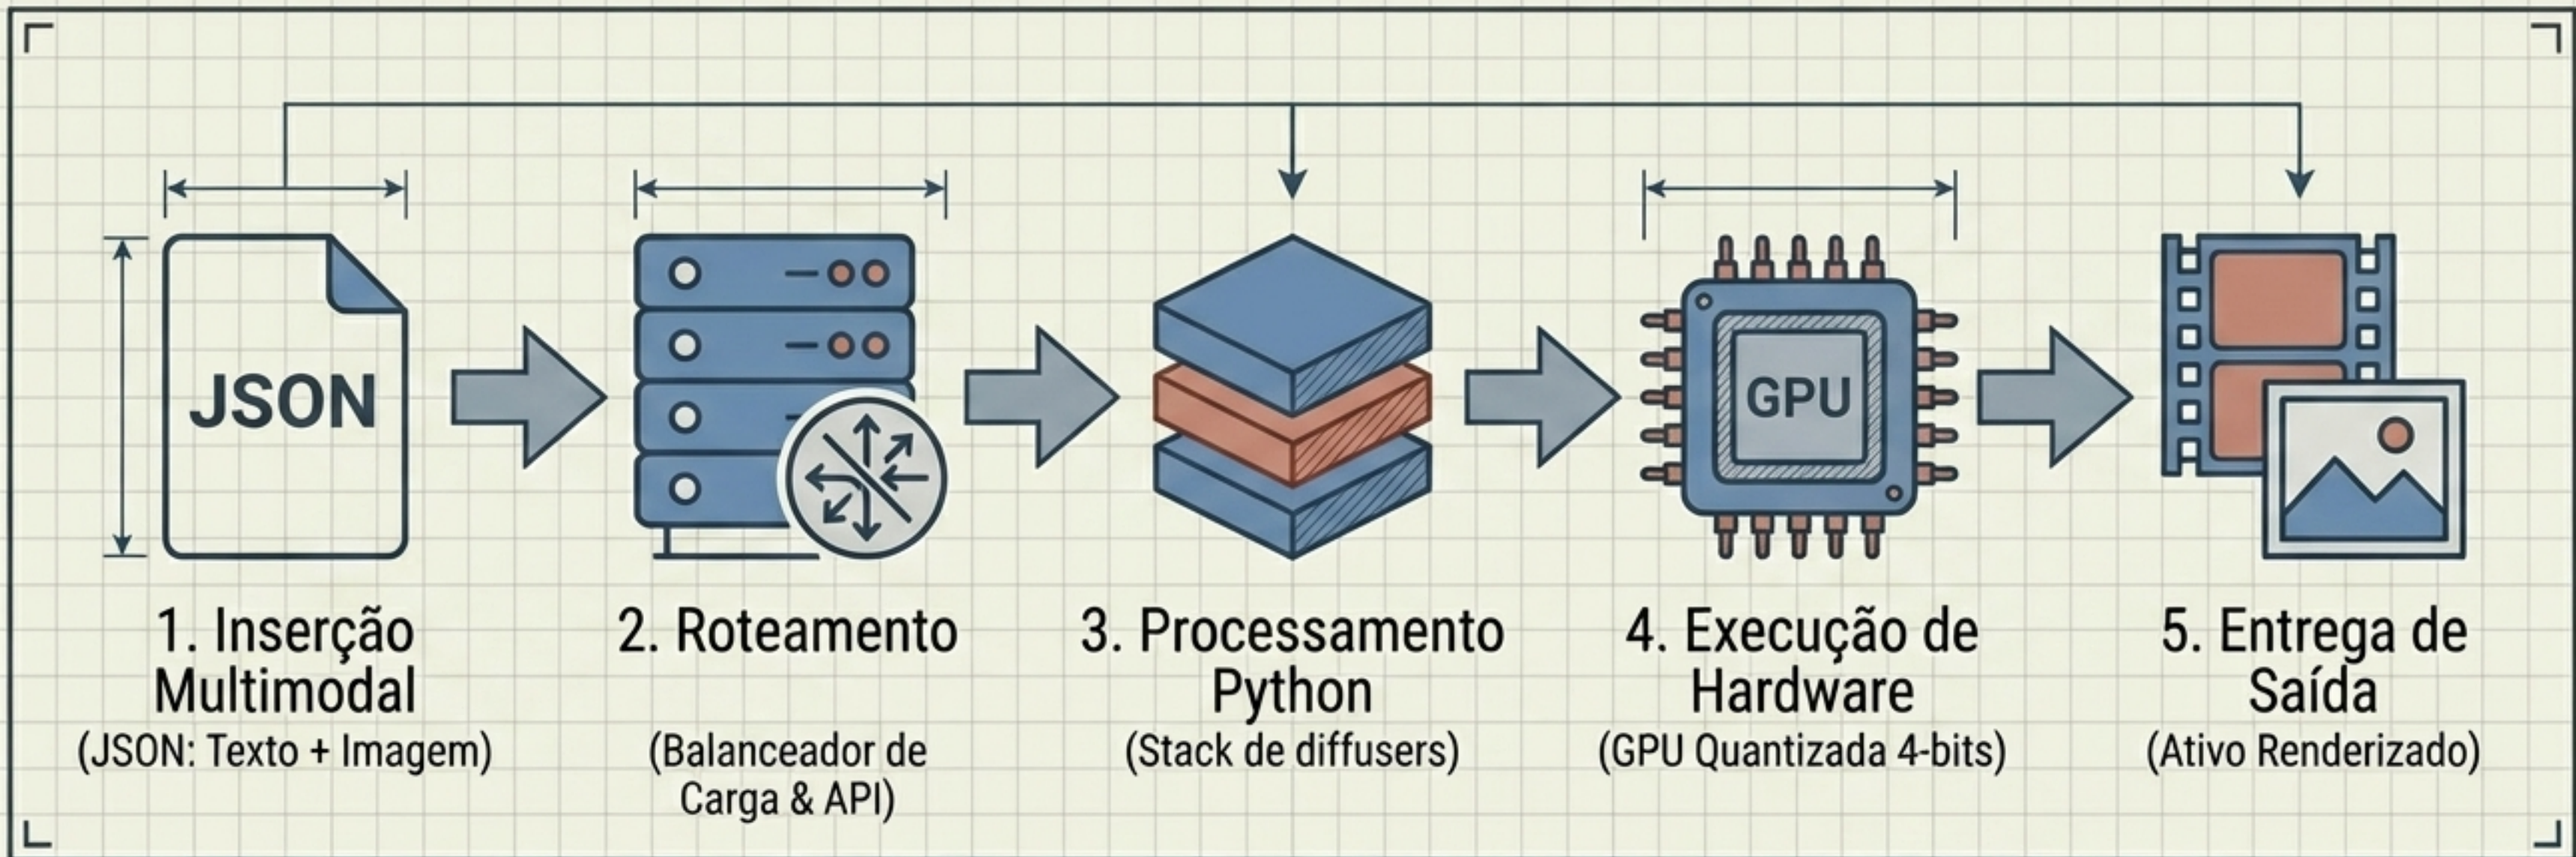
Precisão 32-bit  
(Antes)



Quantização 4-bit  
(Depois)

PRGJETO: GERAÇÃO DE VÍDEO AVANÇADA		
TÍTULO DO ESQUEMA: Otimização via Quantização		
REV: A.13	DATA: 2024.11.06	ESCALA TÉCNICA 0 2 4 6 8 10

# Arquitetura Multimodal Unificada (End-to-End)



PRGJETO:  
GERAÇÃO DE VÍDEO AVANÇADA  
TÍTULO DO ESQUEMA:  
Arquitetura Multimodal

REV:  
A.14

DATA:  
2024.11.07

ESCALA TÉCNICA  
0 2 4 6 8 10

# O Futuro em Código e Tensores

A verdadeira vantagem competitiva em IA multimodal não reside apenas nos modelos que você escolhe, mas na precisão com que você orquestra a coerência, otimiza o silício e unifica o pipeline.

> [END\_OF\_TRANSMISSION]