



"What is the dog up to?"

visual token + text token



LLM

layer 1

layer 2

.....

layer K

Compression Ratio

$$\frac{N \cdot L}{(N - K) \cdot L_{out} + K \cdot L}$$

Visual Compressor

layer K+1

.....

layer N

ANS