



pytorch.cuda.alloc.conf=

这个参数中的阈值变化，没有市长效应，可能看起来是安慰剂。

garbage_collection_threshold:0.5, max_split_size_mb:256 ☆

这个参数中的阈值的变化，没有可能的影响，可能看起来是安慰剂，我用**0.3-1**值进行测试。

max_split_size_mb, 当尝试在这个选项中使用**512**时，就会发生**VRAM**问题。

- 512 □
- 256 □ ☆ (I cant see differences)
- 128 □ (我看不出有什么不同)
- 更少 □ (我看不出有什么不同)

漂浮主题



--opt-split-attention

opt-split 非常重要，否则**VRAM**问题会一直存在

☆，一定要把它添加到你的命令行中 □ ☆
如果你删除这个标志，你会得到一个**VRAM**问题所有时间的 □



--medvram

与我所想的相反，性能有轻微改善，我认为这非常重要。

业绩比较

	□ 已禁用	□ ☆ 已启用
	1.21s/it	1.07s/it
	1.25s/it	1.12s/it
	1.19s/it	1.06s/it

四个家庭



默认为假
启用内存效率高的次四元交叉注意层优化。

我不确定这一点。可以说，在假的和真的情况下得到同样的性能，也许在假的情况下，作为默认情况，影响最小，性能最好的是非常小。你可以自己测试一下

现在，我更愿意保持它的真实性

--opt-sub-quad-attention

这个特殊的论证系列引起了我的注意。

它们是3个参数

--次四边形-q-chunk-size

	1024 □ ☆	512	256 ▽	128
注意：现在，当我尝试使用更高的 1024 值，如 2048 ▽ (也降低了性能{在我的Rx6750XT})，但是，它可能使用 max_split_size_mb:512 和 --sub-quad-kv-chunk-size 256 ，你可以得到更好的性能，如果你有一个 12VRAM 以上的 gpu ，你应该试试。我不确定，因为我只有 12VRAM 。	它是默认值 在我的测试中，当我使用默认值作为较高的值，并有良好的其他设置，它增加了性能。	▽ (减弱性能)	▽ (减弱性能)	▽ (减弱性能)

--sub-quad-kv-chunk-size

--sub-quad-chunk-threshold

他们与**VRAM**问题有着可爱的关系，并且一起工作，这种价值观非常非常重要！！！



kv-chunk-size默认为无

而根据数值，你必须改变**--次四分体-阈值**

64

128 □ ☆

256

512

如果你设置**--sub-quad-kv-chunk-size 64**

如果你设置**--sub-quad-kv-chunk-size 128**

如果你设置**--sub-quad-kv-chunk-size 256**

如果你设置**--sub-quad-kv-chunk-size 512**

你必须在**--次四边形-块状阈值**上测试数值

你必须在**--次四边形-块状阈值**上测试数值

你必须在**--次四边形-块状阈值**上测试数值

你必须在**--次四边形-块状阈值**上测试数值

100是最大的，否则你就会出现**VRAM**问题，如果你试图保持更高的值，可能会得到更多的性能和更少的稳定性。

80-85是最高值，否则你会遇到**VRAM**问题，如果你试图保持更高的值，可能会得到更多的性能和更少的稳定性。

60-65是最高值，否则你会遇到**VRAM**问题，如果你试图保持更高的值，可能会得到更多的性能和更少的稳定性。

50-55是最大的值，否则你就会出现**VRAM**问题，如果你试图保持更高的值，可能会得到更多的性能和更少的稳定性。