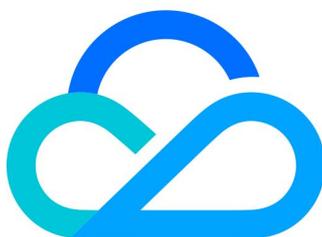


# 向量数据库 性能白皮书



腾讯云

## 【 版权声明 】

©2013–2024 腾讯云版权所有

本文档（含所有文字、数据、图片等内容）完整的著作权归腾讯云计算（北京）有限责任公司单独所有，未经腾讯云事先明确书面许可，任何主体不得以任何形式复制、修改、使用、抄袭、传播本文档全部或部分內容。前述行为构成对腾讯云著作权的侵犯，腾讯云将依法采取措施追究法律责任。

## 【 商标声明 】



及其它腾讯云服务相关的商标均为腾讯云计算（北京）有限责任公司及其关联公司所有。本文档涉及的第三方主体的商标，依法由权利人所有。未经腾讯云及有关权利人书面许可，任何主体不得以任何方式对前述商标进行使用、复制、修改、传播、抄录等行为，否则将构成对腾讯云及有关权利人商标权的侵犯，腾讯云将依法采取措施追究法律责任。

## 【 服务声明 】

本文档意在向您介绍腾讯云全部或部分产品、服务的当时的相关概况，部分产品、服务的内容可能不时有所调整。您所购买的腾讯云产品、服务的种类、服务标准等应由您与腾讯云之间的商业合同约定，除非双方另有约定，否则，腾讯云对本文档内容不做任何明示或默示的承诺或保证。

## 【 联系我们 】

我们致力于为您提供个性化的售前购买咨询服务，及相应的技术售后服务，任何问题请联系 4009100100或 95716。

## 文档目录

性能白皮书

测试环境

测试方法

测试结果

# 性能白皮书

## 测试环境

最近更新时间：2023-12-13 10:58:22

腾讯云向量数据库（Tencent Cloud VectorDB）是一款基于向量相似度搜索的数据库产品，提供高效的向量索引和快速的相似度查询服务。为了让用户更好地了解 VectorDB 的性能表现，腾讯云发布性能白皮书，详细描述 VectorDB 的性能测试环境、测试方法和性能数据等。本章节说明测试性能所需准备的环境与数据集。

### 数据库规格

腾讯云向量数据库所属地域为广州，测试实例规格如下所示。

- 节点类型：**计算型**。
- 节点规格：**P.MEDIUM**（4CPU、8GB内存）、**P.LARGE**（8CPU、16GB内存）
- 节点数量：**3节点**。

该规格所支持的最大向量规模，请参见 [产品规格](#)。请按照如上规格购买并新建向量数据库，具体操作，请参见 [新建数据库实例](#)。

### 客户端测试环境

与腾讯云向量数据库实例为同一地域同一 VPC 内的 Linux [云服务器 CVM](#)，其环境要求如下：

- 操作系统：TencentOS Server 3.1 (TK4)
- 规格：SA3.16XLARGE256。
- 已安装 Python 3.6.8 及以上版本。

#### ⓘ 说明：

使用腾讯云 CVM 连接腾讯云向量数据库（Tencent Cloud VectorDB），在腾讯云 CVM 安全组中需配置出站规则，把腾讯云向量数据库的 IP 及端口添加到出站规则中。在腾讯云向量数据库安全组中配置入站规则，把 CVM 的 IP 地址及向量数据库的端口添加到入站规则中，才能连接成功。具体操作，请参见 [安全组](#)。

### 测试工具

开源工具 `ann-benchmark` 是一个用于评估近似最近邻（ANN）搜索库的性能测试工具。它提供了一套标准的测试数据集和评估指标，可以用于比较不同量级数据库的性能表现。腾讯云向量数据库基于 `ann-benchmark` 进行数据库性能评测，与竞品公平的进行性能差异对比。如下基于运行工具的命令，介绍其关键参数。

```
python3 run.py --dataset sift-128-euclidean --local --force --algorithm vector_db --
definitions=configs/8c64g/100w-1shard.yml --batch --only_query --runs 1 -k 10
```

参数	参数含义
<code>--dataset</code>	指定数据集的名字，数据集放在 <code>./data</code> 目录下。
<code>--local</code>	指定是否在本地运行。
<code>--force</code>	运行查询测试时，如果历史已经测试过（存在本地测试结果），是否继续执行并覆盖。
<code>--algorithm</code>	<code>ann-benchmark</code> 默认支持多种数据库的测试，这里强制指定测试数据库为 <code>vector_db</code> 。
<code>--definitions</code>	指定测试运行时的配置文件。
<code>--batch</code>	添加该参数后，测试工具会使用 CPU 多核模式压测数据查询，使用的 CPU 核数可以通过配置文件中的 <code>Threads</code> 参数控制。
<code>--runs</code>	指定查询运行的次数。当运行性能测试时，期望工具能长时间运行时，可将该参数设置为较大值，如999999。
<code>--only_query</code>	指定是否只运行查询。因 <code>ann-benchmark</code> 默认的工作方式是先插入数据，再运行查询测试。但在实际使用中，我们可能存在插入一次数据后，多次进行查询测试的场景。增加该参数后，可以跳过 <code>ann-benchmark</code> 的数据插入阶段。
<code>-k</code>	希望查询返回的数据条数。

## 数据集

`ann-benchmark` 官方数据集无需提前下载，测试工具运行时会自动检查 `./data`（`ann-benchmark` 工具存放数据集的路径）目录下是否存在数据集文件，如果不存在则会主动连接官网下载官方数据集。`ann-benchmark` 官方不具备768维度的数据集，腾讯云向量数据库团队基于中文文本制作了768维度，从100W到1000W级别的数据集供测试选用。具体数据集信息，如下表所示。

数据集名	数据集介绍	向量维度	向量数	索引方法	距离类型
<a href="#">sift-128-euclidean</a>	官方数据集	128	1,000,000	HNSW	L2
<a href="#">gist-960-euclidean</a>	官方数据集	960	1,000,000	HNSW	L2
<a href="#">chinese100w-768-angular</a>	腾讯云向量数据库提供的数据集	768	1,000,000	HNSW	IP
<a href="#">chinese500w-768-angular</a>	腾讯云向量数据库提供的数据集	768	5,000,000	HNSW	IP

chinese1000w-768-angular	腾讯云向量数据库提供的数据集	768	10,000,000	HNSW	IP
--------------------------	----------------	-----	------------	------	----

# 测试方法

最近更新时间：2023-10-16 11:38:21

腾讯云向量数据库（Tencent Cloud VectorDB）采用开源工具 `ann-benchmark` 进行性能测试，并且为适应云上测试场景，对 `ann-benchmark` 工具进行了改造适配。本文详细介绍基于 `ann-benchmark` 工具进行数据库性能测试的方法。

## 下载并上传工具与数据集

1. 下载测试工具。

[ann-benchmarks-dev.zip](#)

2. 获取腾讯云向量数据库提供的数据集。

### 说明：

`ann-benchmark` 官方数据集默认不需要提前下载，测试工具运行时会自动检查 `./data` 目录下是否存在数据集文件，如果不存在则会主动联网下载。

3. 登录云服务器 CVM 环境，使用 `rz` 命令上传测试工具于 CVM。CVM 要求，请参见 [测试环境](#)。

4. 执行 `unzip ann-benchmarks-dev.zip` 命令解压测试工具压缩包 [ann-benchmarks-dev.zip](#)。

5. 使用 `rz` 命令上传数据集于测试工具解压目录 `../ann-benchmarks-dev/ann-benchmarks/data`。

## 测试 128 维数据在 HNSW 索引下单核查询性能

### 步骤1：安装工具环境依赖

进入已解压的测试工具包的路径，安装 `python` 运行依赖。

```
cd ann-benchmarks
pip3 install -r requirements.txt
```

### 步骤2：修改配置文件

执行如下命令，拷贝配置文件，并打开配置文件，配置相关参数。需配置的参数信息，请参见下表，其余参数保持默认值即可。

```
cp ann_benchmarks/algorithms/vector_db/config.yml mytest.yml
vi mytest.yml
```

配置文件参数	参数含义	建议值

arg_groups 下的第一个参数	索引类型为 HNSW 的参数 M，指每个节点在检索构图中可以连接多少个邻居节点	设置 16
HttpBase	连接向量数据库访问地址	获取向量数据库实例的内网 IP 地址与网络端口。具体操作，请参见 <a href="#">查看实例信息</a> 。 
User	连接用户名	root
ApiKey	向量数据库的 API 访问密钥	如何获取，请参见 <a href="#">密钥管理</a> 。
IndexType	索引类型	HNSW
MetricType	相似度计算方法	L2
ColReplicaNum	副本数	2
Threads	单线程进行测试	1
ColShardNum	分片数量	3
EfConstruction	索引类型为 HNSW 的参数 ef，搜索时，指定寻找节点邻居遍历的范围	500
BuildIndexOnUpsert	指定插入数据时，同步更新索引	<ul style="list-style-type: none"> <li>• true: 重新创建索引。</li> <li>• false: 不重新创建索引。</li> </ul>
query_args	指定了在数据插入完成后，需要进行ef为 10, 15, 20 等的查询	[ 10, 15, 20, 25, 30, 35, 40, 50, 60, 80, 120, 200, 400 ]

```
float:
  any:
    - base_args: [ '@metric' ]
      constructor: VectorDb
      disabled: false
      docker_tag: ann-benchmarks-vector_db
      module: ann_benchmarks.algorithms.vector_db
      name: vector_db
```

```
run_groups:
vector_db:
  arg_groups:
    - [ 16 ]
    - DbName: db-test
      HttpBase: http://127.0.0.1:18100
      NeedAuth: true
      User: root
      ApiKey: invalid-by-default
      DropDb: false
      CreateDb: true
      ReCreateCollection: false
      DropCollectionOnDone: false
      IndexType: HNSW
      MetricType: L2
      ColReplicaNum: 2
      ColShardNum:
      EfConstruction: 500
      ExitOnError: true
      Threads: 1
      MultiCpuUpsert: true
      UpsertBatchSize: 500
      BuildIndexOnUpsert: true
      KNNSeekMode: false
      KNNSeekKStartEf: 90
      KNNSeekStep: 1
      KNNSeekExpect: 0.95
  args: { }
  query_args:
    - [ 10, 15, 20, 25, 30, 35, 40, 50, 60, 80, 120, 200, 400 ]
    - RetrieveVector: false
```

### 步骤3：运行测试工具

执行如下命令，运行测试工具。其中，`--dataset` 指明数据集名称。`vector_db` 指明了数据库名，数据库名从 `mytest.yml` 中获取。具体参数含义，请参见 [测试工具](#)。

#### 说明：

`euclidean` 使用的是 L2 相似度算法，`angular` 使用的是 IP 算法。

```
python3 run.py --dataset sift-128-euclidean --local --force --parallelism 1 --algorithm
vector_db --definitions=mytest.yml --runs 1
```

## 步骤4：查看测试运行结果

测试结束后，测试结果保存在 results 文件夹中，需要使用如下命令将结果转换为可读的 csv 文件。如下所示，可通过生成的 mytest.csv 文件，查看 128 维数据在 HNSW 索引下单核的性能表现。

```
python3 data_export.py --output=mytest.csv
```

## 探索指定召回率，需设置的查询 EF 值

### 步骤1：打开探索模式

打开配置文件 mytest.yml，修改配置文件中的 KNNSeekMode 参数为 true，该模式测试工具会反复运行不同 ef 值的查询，直到获得最匹配的召回率为止。

```
31 BuildIndexOnUpsert: true
32 KNNSeekMode: false
33 KNNSeekStartEf: 90
34 KNNSeekStep: 1
35 KNNSeekExpect: 0.95
36 args: { }
```

### 步骤2：配置探索参数

配置文件参数	参数含义	建议值
KNNSeekStartEF	指定开始查询 ef 设置的起始值，即从哪一个ef 参考值开始查询	90
KNNSeekStep	指定探索模式中，每次 ef 值变化几个单位。如1，则表示 KNNSeekStartEF+=1 或相减，每次递增或递减的步长	1
KNNSeekExpect	期望找到的召回率	0.95

### 步骤3：运行工具

具体参数含义，请参见 [测试工具](#)。

```
python3 run.py --dataset sift-128-euclidean --local --force --parallelism 1 --algorithm vector_db --definitions=mytest.yml --runs 1 --only_query
```

### 步骤4：查看运行结果

结果显示如下图所示，KNNSeekExpect=0.95，即在ef=61时，可获得最接近0.95的召回率。

```
Processed Query, TopK=10 : 100% | 3000/3000 [00:03-00:00, 887.60it/s]
== Seek for ef: 61, get knn: 0.9493
All seek results: {'70': 0.9609, '69': 0.9599333333333334, '68': 0.9589333333333334, '67': 0.9576666666666668, '66': 0.9566666666666667, '65': 0.9553666666666667, '64': 0.9540333333333333, '63': 0.9526666666666668, '62': 0.9512666666666666, '61': 0.9493}
Best match ef: 61, matched KNN: 0.9493
2023-08-03 20:57:54.597 - ann - INFO - Terminating 1 workers
[root@M-4-12-tencentos ann-benchmarks]#
```

## Search 检索查询性能

### 步骤1: 设置期望的 EF 值, 压测查询配置

在配置文件中, 如下使用 8 核压测查询 `ef=111` 的情况。注意需要设置 `KNNSeekMode` 为 `false`。

```
27         ExitOnError: true
28         Threads: 8
29         MultiCpuUpsert: true
30         UpsertBatchSize: 500
31         BuildIndexOnUpsert: true
32         KNNSeekMode: false
33         KNNSeekStartEf: 90
34         KNNSeekStep: 1
35         KNNSeekExpect: 0.95
36         args: { }
37         query_args:
38         - [ 111 ]
39         - RetrieveVector: false
40
```

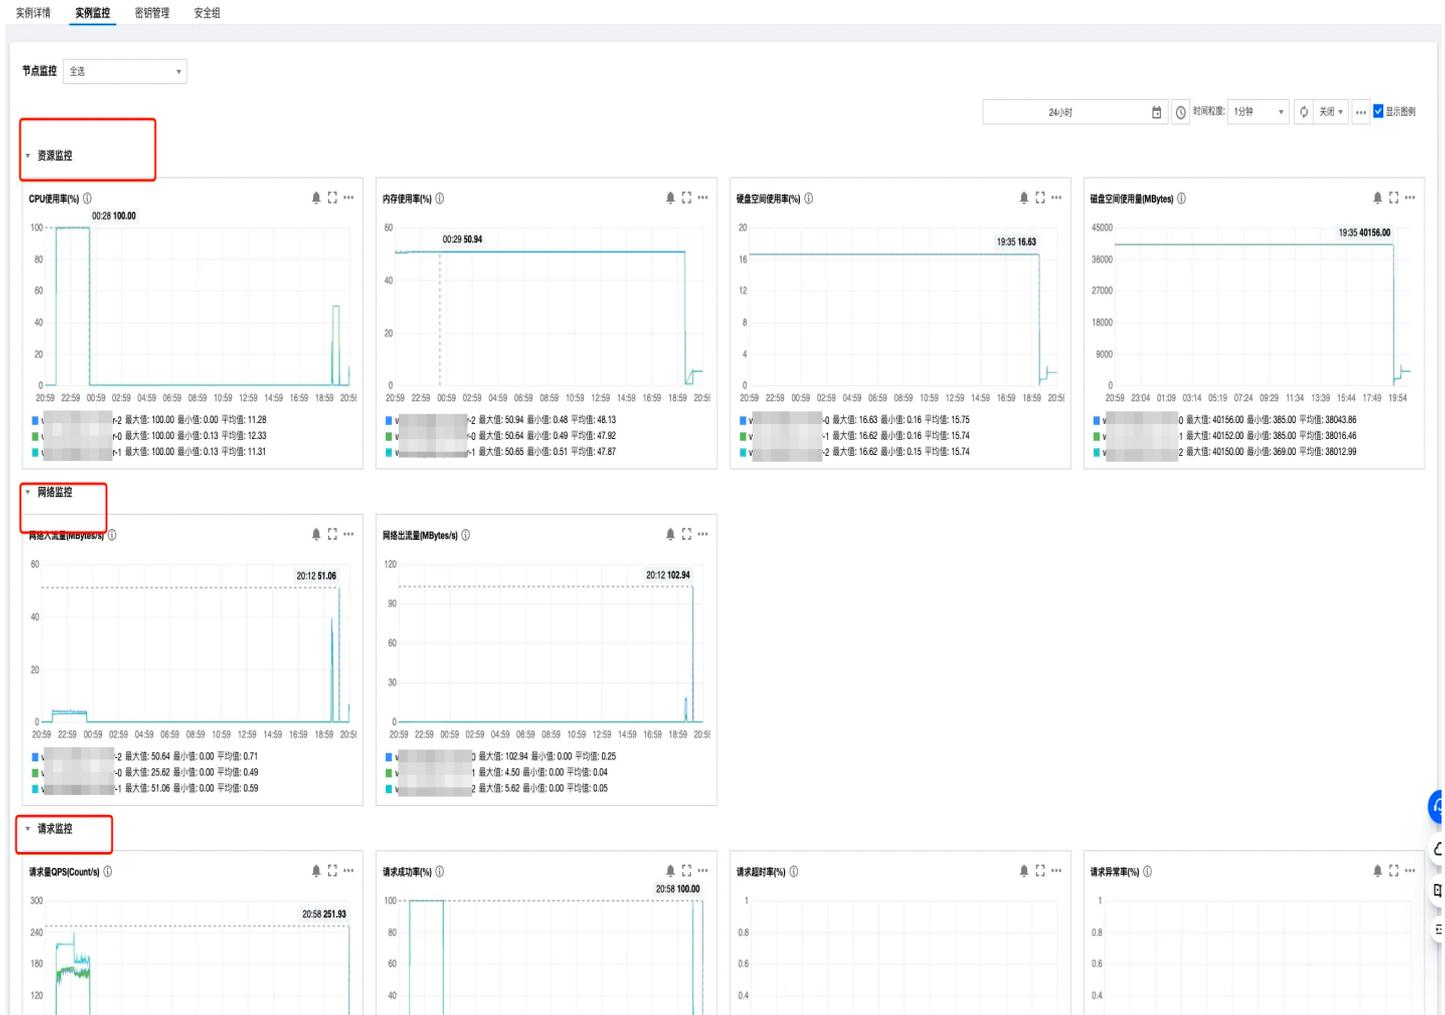
### 步骤2: 运行工具

压测命令, 压测时需要打开 `--batch` 参数, 同时设置 `--runs` 为较大值以便长时间运行。具体参数含义, 请参见 [测试工具](#)。

```
python3 run.py --dataset sift-128-euclidean --local --force --parallelism 1 --algorithm
vector_db --definitions=mytest.yml --runs 999 --only_query --batch
```

### 步骤3: 查看结果

腾讯云向量数据库控制台提供了实例的 CPU，内存、QPS，时延等关键性能指标监控。具体操作，请参见 [查看监控数据](#)。



**说明:**

受限于 python 语言的线程模型，有时测试工具无法把测试压力打满，导致实例性能无法达到极限，此时可使用多进程或多台 CVM 同时进行压测。

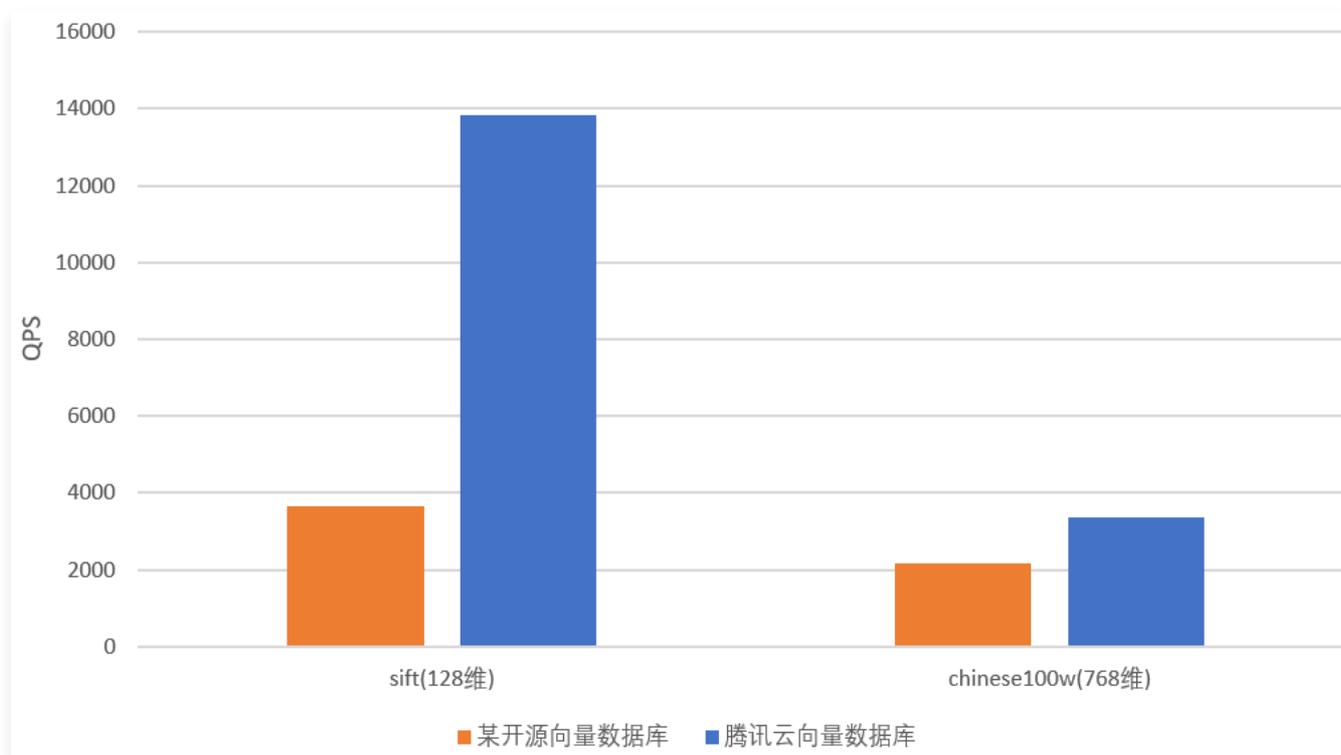
# 测试结果

最近更新时间：2023-12-08 16:15:50

本文提供了腾讯云向量数据库（Tencent Cloud VectorDB）采用开源工具 ann-benchmark 进行性能测试的详细数据。吞吐量 QPS 是指系统在单位时间内能够处理的查询请求数量，是衡量系统查询处理能力的重要指标。该性能测试集中测试不同维度的 QPS 数据、不同召回率下的 QPS 数据、不同数据规模的 QPS 数据。

## 不同维度最大 QPS 对比

- **测试目标：**检索不同维度的数据集，向量索引选择 HNSW 类型，在召回率达到 99% 的情况下，获取最相似的 Top10 的文档，对比某开源向量数据库与腾讯云向量数据库的 QPS 数据。
- **测试规格：**向量数据库 P.MEDIUM（4CPU、8GB 内存）、节点数量为 3。
- **测试数据集：**数据量级 100w，128、768、960 三档维度的数据集
- **测试结论：**数据集 128 维与 768 维某开源向量数据库与腾讯云向量数据库的 QPS 对比测试数据，如下所示。通过如下对比视图，可看出腾讯云的 QPS 性能具有显著优势。通过该项测试，可得出如下结论：
  - 在不同维度的数据集下，HNSW 索引都可以达到 99% 以上的召回率。
  - 在数据量相同的情况下，随着向量维度的增加，检索时资源开销增加，腾讯云向量数据库 QPS 会有所降低。
  - 同一数据集，与某开源自建向量数据库对比，腾讯云向量数据库的 QPS 有 36% 到 279% 的提升。对比视图，如下所示。

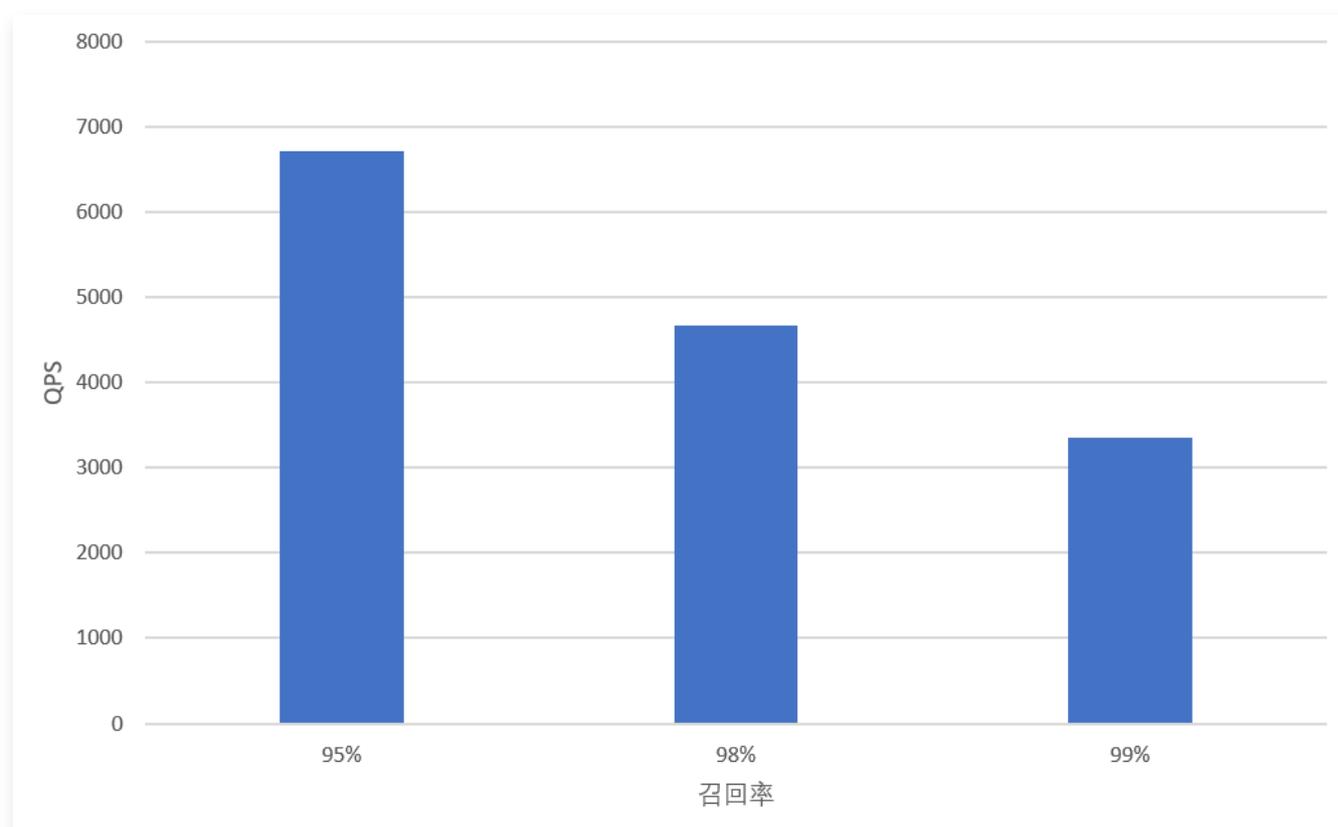


数据集	分片和	索引类型	召回	QPS

	副本		率	某开源向量数据库	腾讯云向量数据库
sift-128-euclidean	shard Num=1 replica Num=2	HNSW (m=16,efConstruction=200)	99%	3653	13843 (↑279%)
chinese100w-768-angular				2166	3346 (↑54%)
gist-960-euclidean				480	651 (↑36%)

## 不同召回率下的 QPS 对比

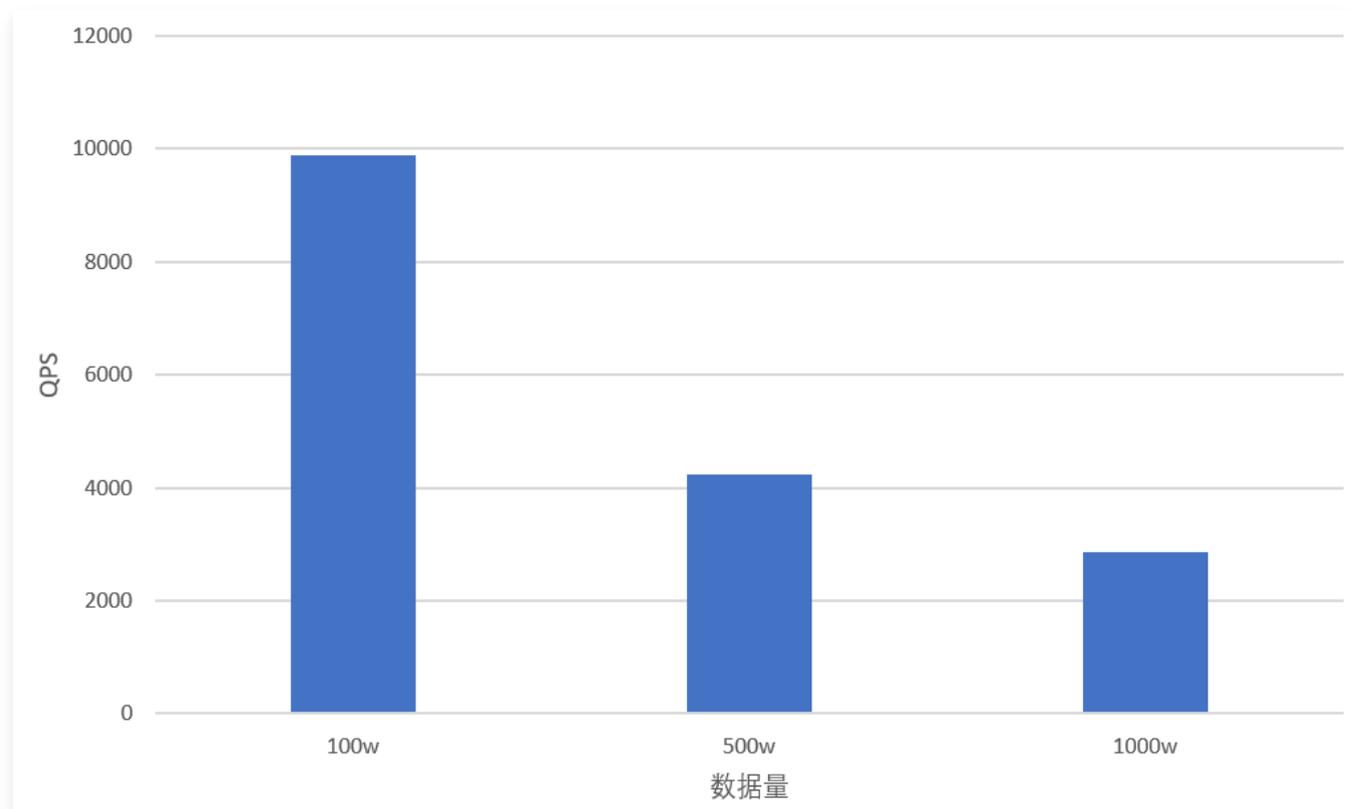
- **测试目标：**检索100w数据量级，向量索引类型为 HNSW，设置不同的查询参数 ef（指定寻找节点邻居遍历的范围），分析召回率的变化，对比 QPS 数据。
- **测试规格：**向量数据库 P.MEDIUM（4CPU、8GB内存）、节点数量为 3。
- **测试数据集：**chinese100w-768-angular，数据量级100w，768维度的数据集。
- **测试结论：**测试数据，如下表所示。分析可得出如下结论。
  - 同一数据集，召回率要求越高，即 ef 参数设置越大时，QPS 越低。不同召回率 QPS 的对比视图，如下所示。
  - 同一数据集，在其他配置不变的情况下，若需提高召回率，可适当增加查询参数 ef。



数据集	分片和副本	索引类型	查询参数	召回率	QPS
chinese100w-768-angular	shardNumber=1 replicaNumber=2	HNSW (m=16,efConstruction=200)	ef=85	95%	6708
			ef=149	98%	4671
			ef=200	99%	3346

## 不同数据规模 QPS 对比

- **测试目标：**检索不同数据规模的数据集，在召回率达到95%的情况下，获取最相似的 Top10的文档，分析不同数据量级的 QPS 数据。
- **测试规格：**向量数据库 P.LARGE (8CPU、16GB内存)、节点数量为 3。
- **测试数据集：**chinese100w-768-angular、chinese500w-768-angular、chinese1000w-768-angular 768维度不同数据量级的数据集。
- **测试结论：**测试数据，如下表所示。分析可得出如下结论。
  - 向量维度相同时，随着数据规模量级增加，检索时资源开销增加，QPS 有所降低。具体对比视图，如下所示。
  - 从数据中可以看出，数据量越大，达到相同召回率时，需要设置的查询参数 ef 就会越大，检索过程中便需要遍历更大的搜索范围。因此，在实际应用HNSW 索引时，需要根据业务规模和召回率要求，提前测试并设置合理的 ef 参数。



数据集	数据量	分片和副本	索引类型	查询参数	召回率	QPS
chinese100w-768-angular	1,000,000	shard Num=1 replica Num=2	HNSW ( m=16,efConstruction=500 )	ef=12	95%	9891
chinese500w-768-angular	5,000,000		HNSW ( m=16,efConstruction=500 )	ef=93		4223
chinese1000w-768-angular	10,000,000		HNSW ( m=16,efConstruction=500 )	ef=224		2864