DNSサーバパフォーマンス評価

ETJP DNS-WGまとめ+α

N+I2005 DNSホットトピックス
2005/6/10

藤原和典
株式会社日本レジストリサービス(JPRS)
fujiwara@jprs.co.jp

ENUMとは

□電話番号を用いてインターネット上の様々な通信サービスへの統一的なアクセスを可能にするプロトコル

□RFC3761で定義

□電話番号をドメイン名に対応 (.e164.arpa)

- ○+81-3-1234-5678 (E.164電話番号)
- ○+81312345678 (AUS)
- ○8.7.6.5.4.3.2.1.3.1.8.e164.arpa (ドメイン名)

□インターネットのサービスをURIとして登録 (NAPTR RR)

- ○IN NAPTR 100 0 "u" "E2U+sip" "!^.*$!sip:810123456789@example.jp!" .

ENUM Trial Japan (ETJP)

□ENUMに関する技術実験を行うことを目的に設立

□基本機能と実用性の技術的検証
- ○DNSによる基盤サービス
- ○通信アプリケーション
- ○通信サービス

□サービス化に向けた技術的課題の整理と検討

□http://etjp.jp/

ETJP DNS-WG:概要と目的

概要

- □トライアルおよび将来のENUM の商用利用に向けた基礎データ収集を目的
- □日本国内で展開しうるENUM DNSのモデル
  - ○定義
  - ○要求仕様
  - ○評価基準
  - ○現在のDNS実装を性能評価
- □DNSSECのENUMへの適用について検討と評価

活動の成果

- □ENUM DNSに関するモデル・要求仕様
- □DNSサーバ評価結果
- □DNSSECのENUMへの適用についての調査結果

ENUM DNS要求条件

□背景
- ○ENUMの商用利用の形態をモデル化
- ○日本の主要な電話サービスのトラフィック情報などの数値は公開されている
  - ▹テレコムデータブック2004

□DNS-WGで想定するENUMモデル
- ○電話サービスのアドレス解決にENUMを用いる場合を想定
- ○電話契約数、通話数をもとに必要条件を決定

□登録数
- ○系全体で1～2億件程度 (日本の電話番号は約1億6000万)

□DNSパフォーマンス条件
- ○系全体で5万qps程度 (電話の平均発呼数の10倍)
  - ▹平成14年度の固定電話（公衆電話含む）、携帯電話、PHSの総通信回数 132,391(百万回)
  - ▹固定電話 最繁時（9時～10時）の発呼数は6,484(百万回)=約4,934呼／秒

□DNSデータ更新頻度条件
- ○変更までに30分以内

想定するENUM DNS Tier構造

ENUM研究グループ報告書 23,24ページ (2)と(3)を検討

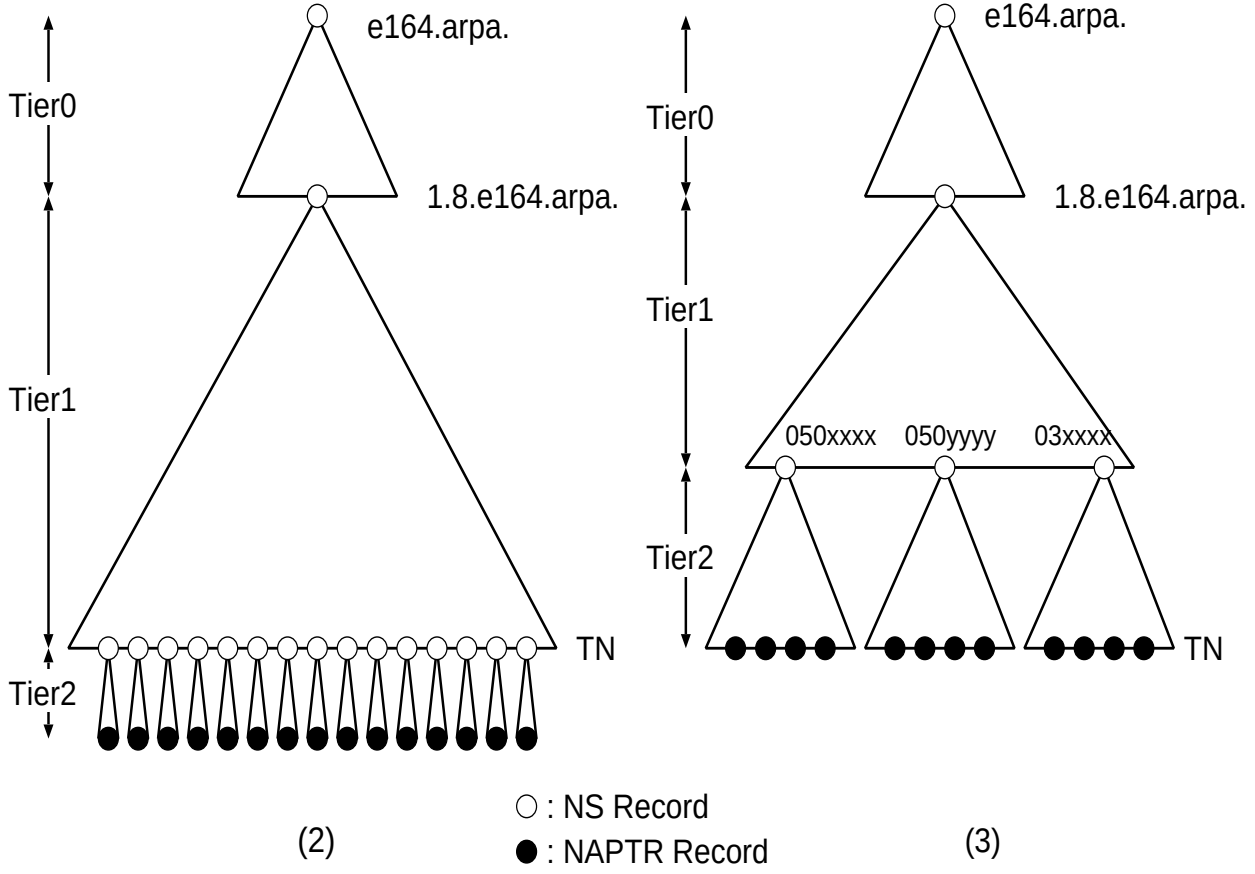

(2)たけのこモデル　　(3)割り当て単位モデル

DNSサーバ性能評価

□DNS Authoritativeサーバ単体での能力測定

□共通のテストデータ
- ○たけのこモデル、割り当て単位モデル
- ○Tier1、Tier2 それぞれ
  - ▹ただし、割り当て単位モデルTier1は件数が少ないため、たけのこモデルTier1で代用
- ○パラメータで電話番号数を指定
  - ▹データが主記憶に入り切るサイズのデータ
  - ▹主記憶の量により、測定できるエントリ数が決まる

□測定項目
- ○DNSデータロード時間・リロード時間
- ○メモリ使用量(プロセスサイズ)
- ○サーバ応答性能(queryperfを使用)

テストデータ(1)

□たけのこ Tier1

○機械的に生成するゾーンファイル
○エントリ数を指定して生成
○一つの番号あたり、NS RR 2行

9.8.7.6.5.4.3.2.1.0.1.8.e164.arpa. IN NS ns1.etjp.jp.
9.8.7.6.5.4.3.2.1.0.1.8.e164.arpa. IN NS ns2.etjp.jp.

□たけのこ Tier2

○機械的に生成する多数のゾーンファイル
○一つの番号にNAPTR RR 1行, NS RR 2行
○ゾーン数を指定して生成
○named.confも生成

```
$ORIGIN 9.8.7.6.5.4.3.2.1.0.1.8.e164.arpa.
  IN SOA
  IN NS ns1.etjp.jp.
  IN NS ns2.etjp.jp.
  IN NAPTR 100 0 "u" "E2U+sip" "!^.*$!sip:810123456789@example.jp!" .
```

テストデータ(2)

- □局番単位 Tier1
  - ○機械的に生成するゾーンファイル
  - ○局番数を指定、15万エントリ程度
  - ○一つの局番あたり、NS RR 2行

```
$ORIGIN 1.8.e164.arpa.
@ IN SOA ns0.etjp.jp. postmaster.etjp.jp. (1 1H 5M 7D 10M)
 IN NS ns1.etjp.jp.
 IN NS ns2.etjp.jp.
0.0.0.0.0.0 IN NS ns1.isp000.jp.
0.0.0.0.0.0 IN NS ns2.isp000.jp.
1.0.0.0.0.0 IN NS ns1.isp001.jp.
...
```

- □局番単位 Tier2
  - ○機械的に生成する多数のゾーンファイルとnamed.conf
  - ○各ゾーンファイルに1万番号
    - ▷1番号ごとにNAPTR RR 1行
  - ○ゾーン数を指定して生成

```
$ORIGIN 0.0.0.0.0.0.1.8.e164.arpa.
$TTL 120
@ IN SOA ns1.etjp.jp. postmaster.etjp.jp. (1 1H 5M 7D 10M)
 IN NS ns1.etjp.jp.
 IN NS ns2.etjp.jp.
0.0.0.0 IN NAPTR 100 0 "u" "E2U+sip" "!^.*$!sip:00000000@sipisp.jp!" .
1.0.0.0 IN NAPTR 100 0 "u" "E2U+sip" "!^.*$!sip:00000001@sipisp.jp!" .
2.0.0.0 IN NAPTR 100 0 "u" "E2U+sip" "!^.*$!sip:00000002@sipisp.jp!" .
...
```

DNS-WG: 評価基準

□要件を満たす実装と、その仕組み(組合せ)の提案を目指す

○各要素を実用的に実現する方法

○DNS Authoritative サーバ単体での性能測定

○Authoritative サーバを何台に分割すると要求を満たせるか

○実用台数組み合わせて実現できるモデル

▹運用可能な実用的なシステム数を10から100と想定

DNS-WG: 調査対象DNSサーバ

- BIND 8: 8.3.7
  - ISCが開発、従来の標準
  - Authoritative server機能とFull Resolver機能
- BIND 9: 9.3.1
  - ISCが参照実装として開発
  - DNSSEC対応
  - Authoritative server機能とFull Resolver機能
- NSD: 2.3.0
  - NL NetLabsが開発
  - DNSSEC対応
  - Authoritative server機能のみ
- djbdns: 1.0.5
  - D. J. Bernstein助教授が開発
  - Authoritative server機能(tinydns)とFull Resolver機能(dnscache)を分離

DNSサーバの特徴 BIND, NSD

□BIND 8, BIND 9 共通点
- ○ゾーンファイル、制御ファイルは人間が読み易いテキスト
- ○ゾーンごとに１ファイル
- ○named.conf にゾーン情報を記述
- ○namedはnamed.confに従い、ゾーンファイルを直接解釈

□BIND 8
- ○ゾーンデータ読み込み、再読み込み時には無応答

□NSD
- ○BIND形式のゾーンファイルからnsd.dbを作成
  - ▹zonecコマンドでゾーンファイルをコンパイル
  - ▹nsd.zones: zone <ゾーン名> <ゾーンファイル名>
- ○nsdサーバプログラムが読むファイルは独自内部形式のnsd.db
- ○データロード時間には zonec実行時間と、nsd.db読み込み時間が含まれる

DNSサーバの特徴 djbdns

- djbdns(tinydns)
  - 独自のテキスト形式 (1文字コマンド + データ)
  - 複数ゾーンがあっても1ファイル
  - tinydns-data コマンドで、data.cdb に変換
  - tinydnsは、queryのたびに data.cdb をmmapし、検索
  - そのため、データセットの切替えは瞬時
  - データロード時間は tinydns-data コマンド実行時間
  - メモリ使用量は data.cdb のサイズ

- tinydnsパフォーマンス向上パッチ
  - 毎回mmapでは遅く、mmap頻度を1秒に一度にしても実害はない
  - mmap頻度を下げ、応答性能を上げる非公式パッチを適用したもので評価
  - Lennert Buytenhek氏作成
    - http://people.FreeBSD.org/~roam/ports/patches/dns/tinydns-persistmmap-20040418.patch

- NAPTR/SRV patch
  - Guilherme Balena Versiani氏作成
    - http://mywebpage.netscape.com/guibv/#djb

測定環境

□DNSサーバPC-------Ethernet-------測定用PC

- ○測定対象DNSサーバPC 1台
- ○測定用PC 1台
- ○同一ネットワークに接続

□テスト環境

- ○DNSサーバPC
  - ▷Pentium4-3GHz, memory 2.5GB, FreeBSD 4.11
- ○queryperf PC
  - ▷Pentium4-2.7GHz, FreeBSD 4.11
- ○Ethernet
  - ▷1000baseT

たけのこモデルTier1 メモリ使用量

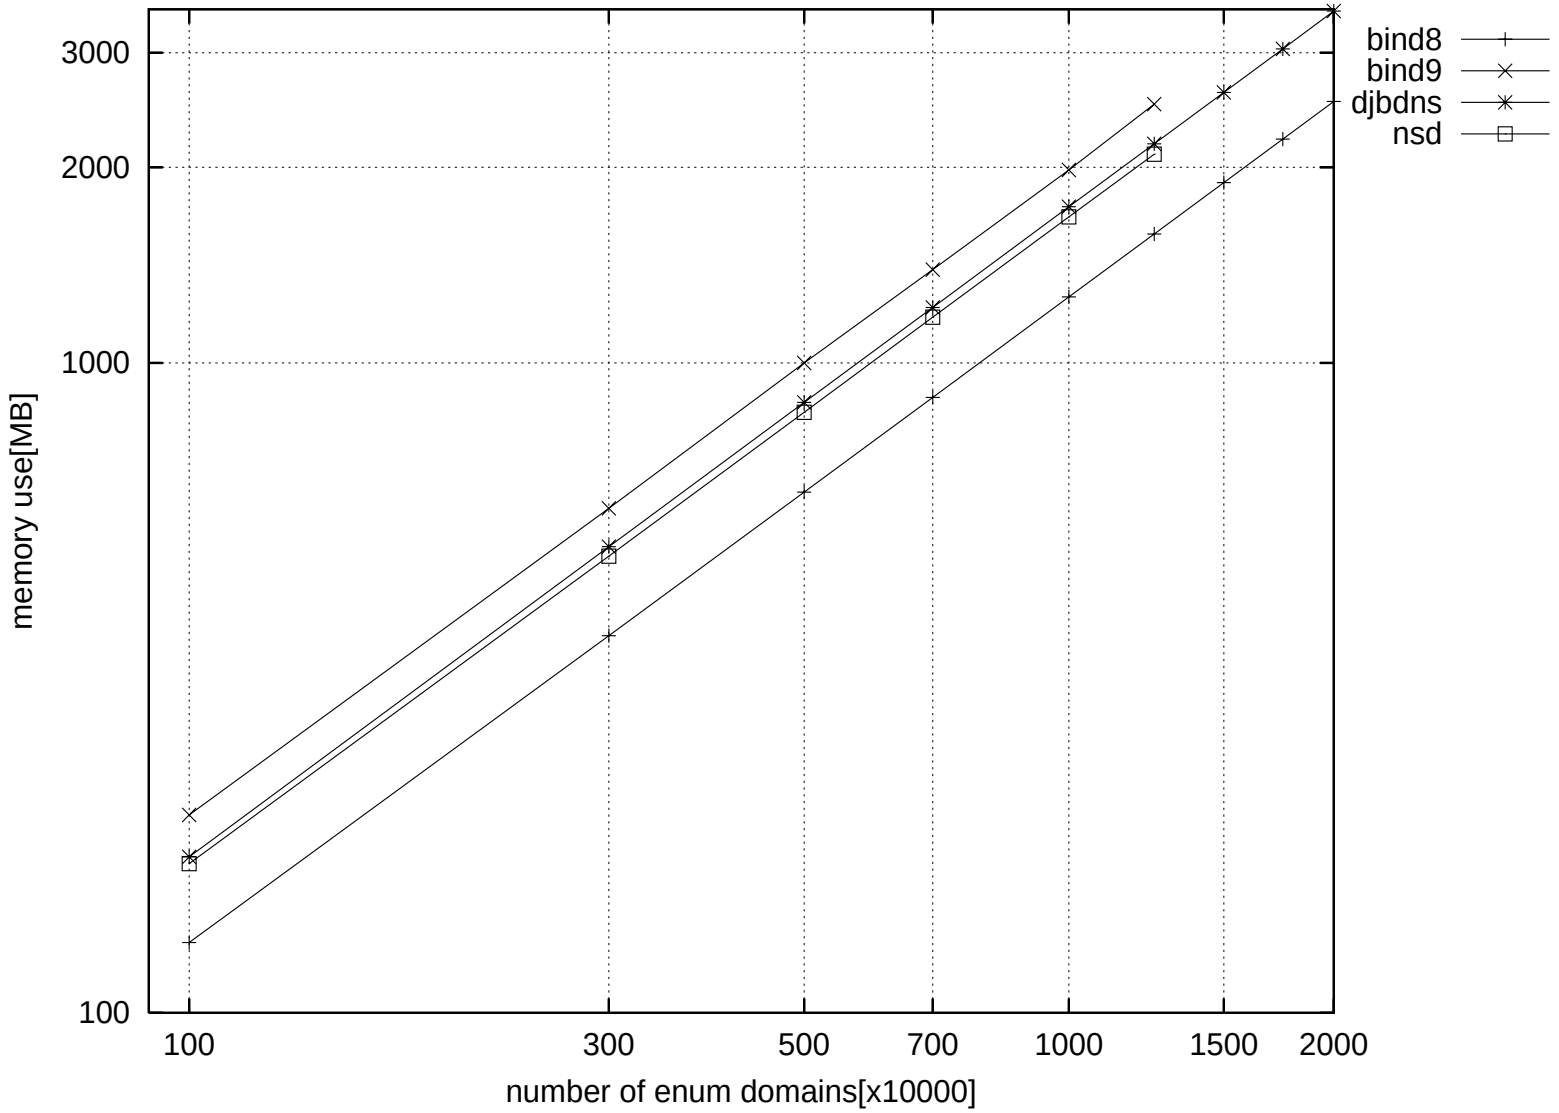

たけのこモデルTier1 ロード時間

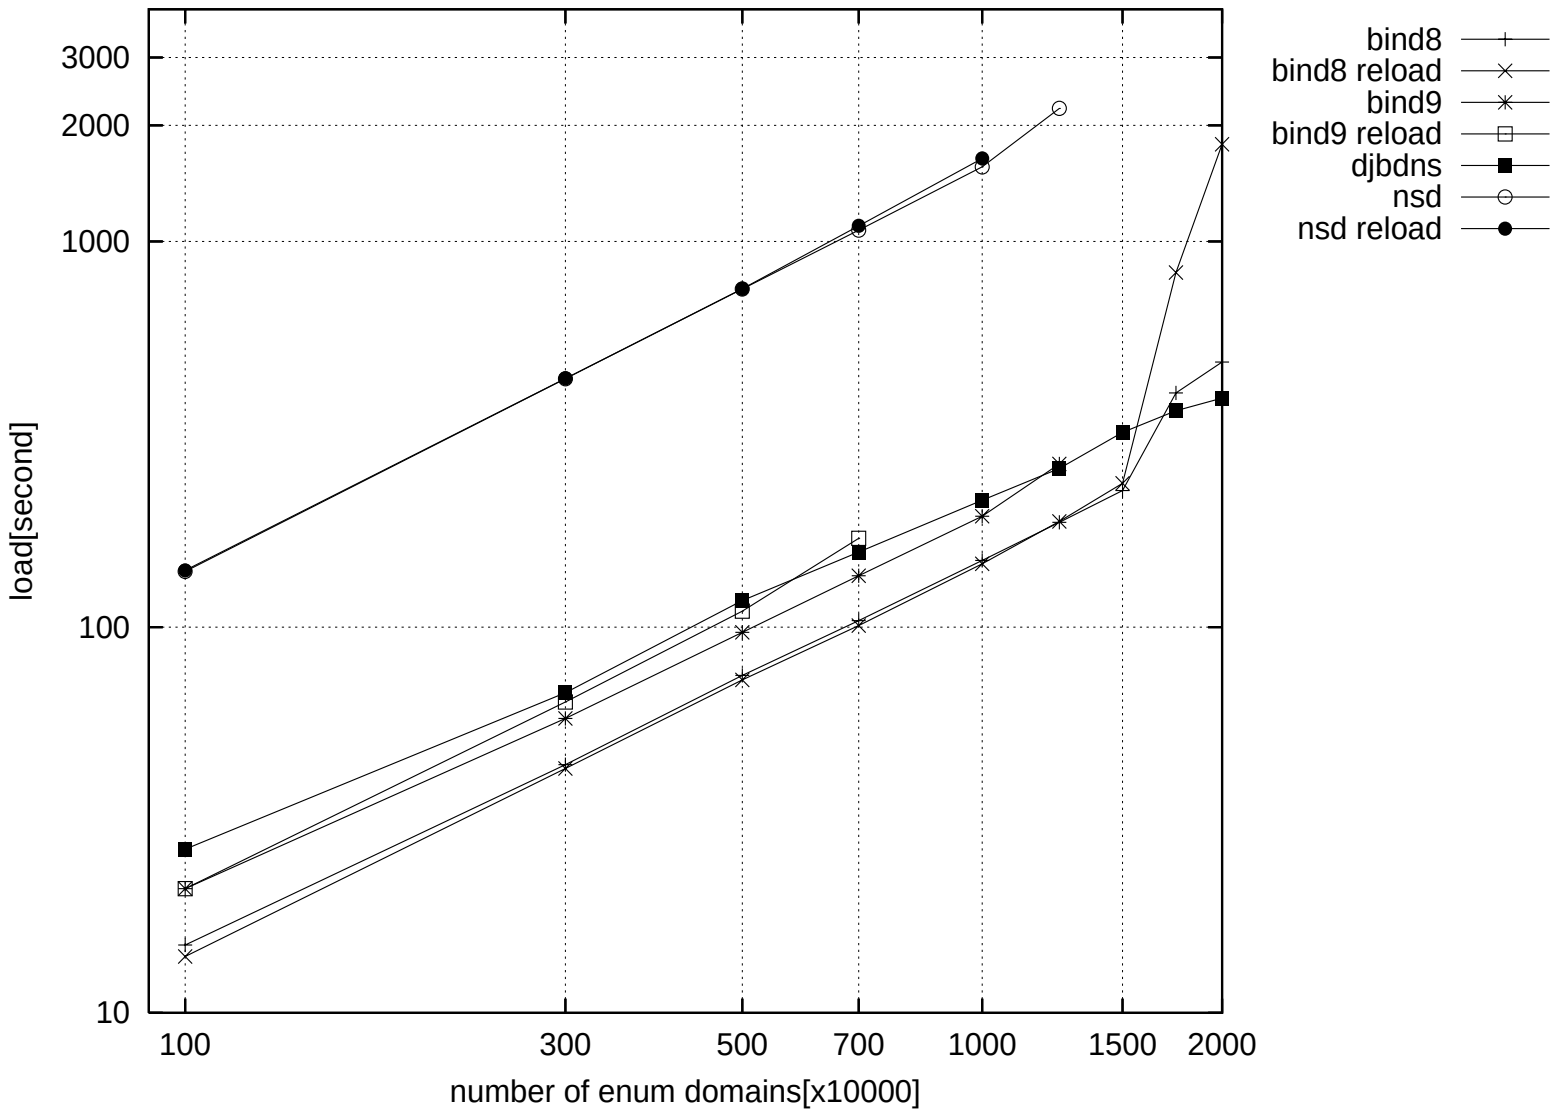

たけのこモデルTier1 応答性能

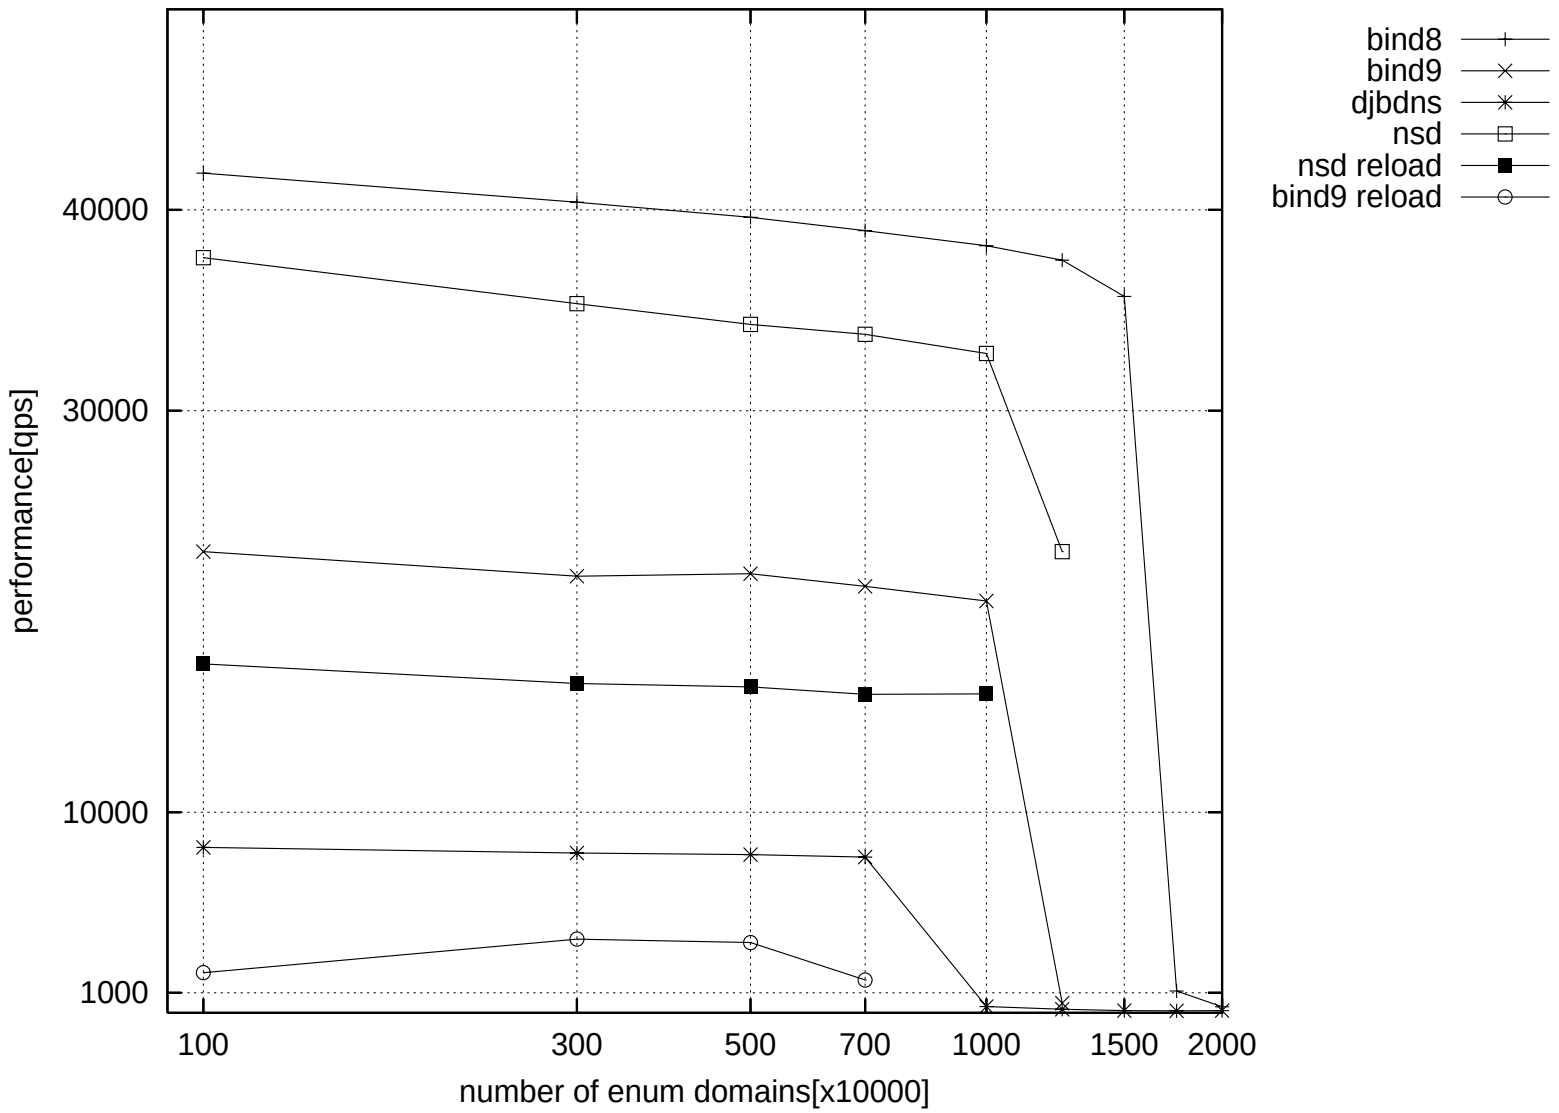

たけのこモデルTier1 評価結果(1)

- □登録数
  - ○どのサーバでも 1000万番号 2000万エントリまでは正常動作
    - ▷20システムにわけることで2億対応可
    - ▷BIND 9ではreload時にメモリが不足した
- □サーバパフォーマンス
  - ○1000万エントリで、NSDでは32000qps、BIND 8では38000qps、BIND 9では20000qps
  - ○サーバを2,3台用いることで5万qps達成
  - ○djbdnsは性能がでない
- □更新頻度条件
  - ○NSDの場合はデータのコンパイル・ロードだけで30分かかる
  - ○BIND 8, BIND 9, djbdnsの場合は5分弱でロード可能
- □まとめ
  - ○BIND 8, BIND 9を3台用いたシステムで1000万番号保持
  - ○20システム配置することで2億番号対応可能

たけのこモデルTier2 メモリ使用量

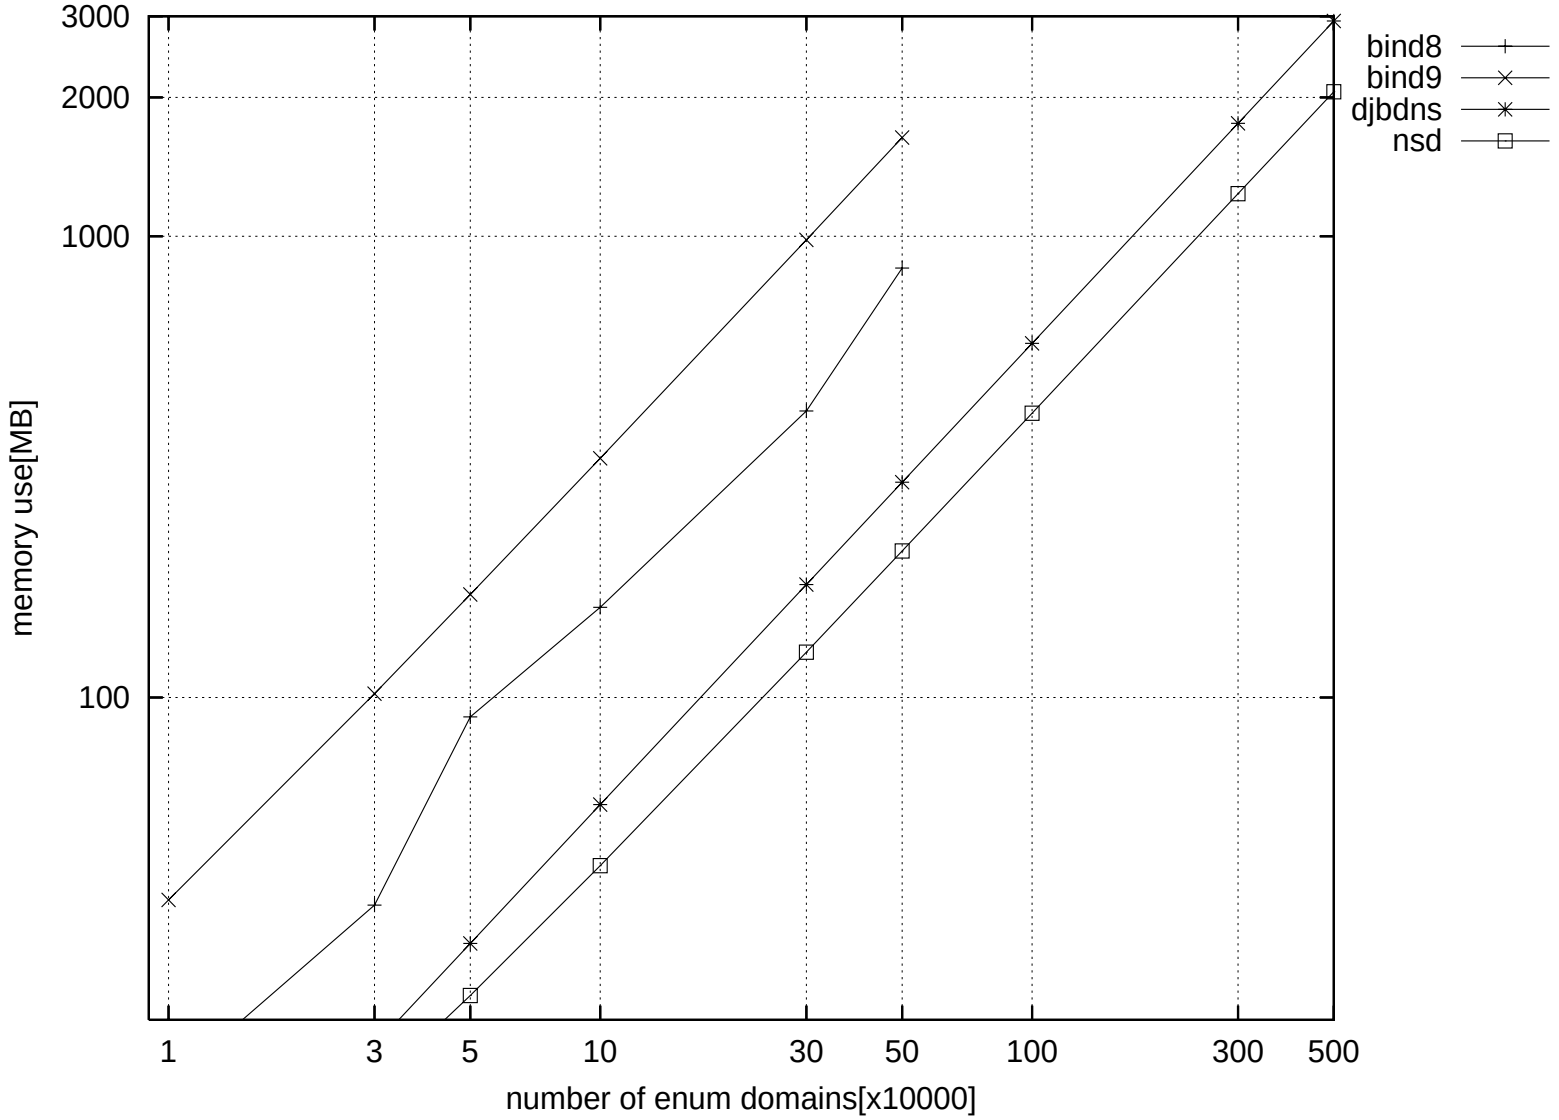

たけのこモデルTier2 ロード時間

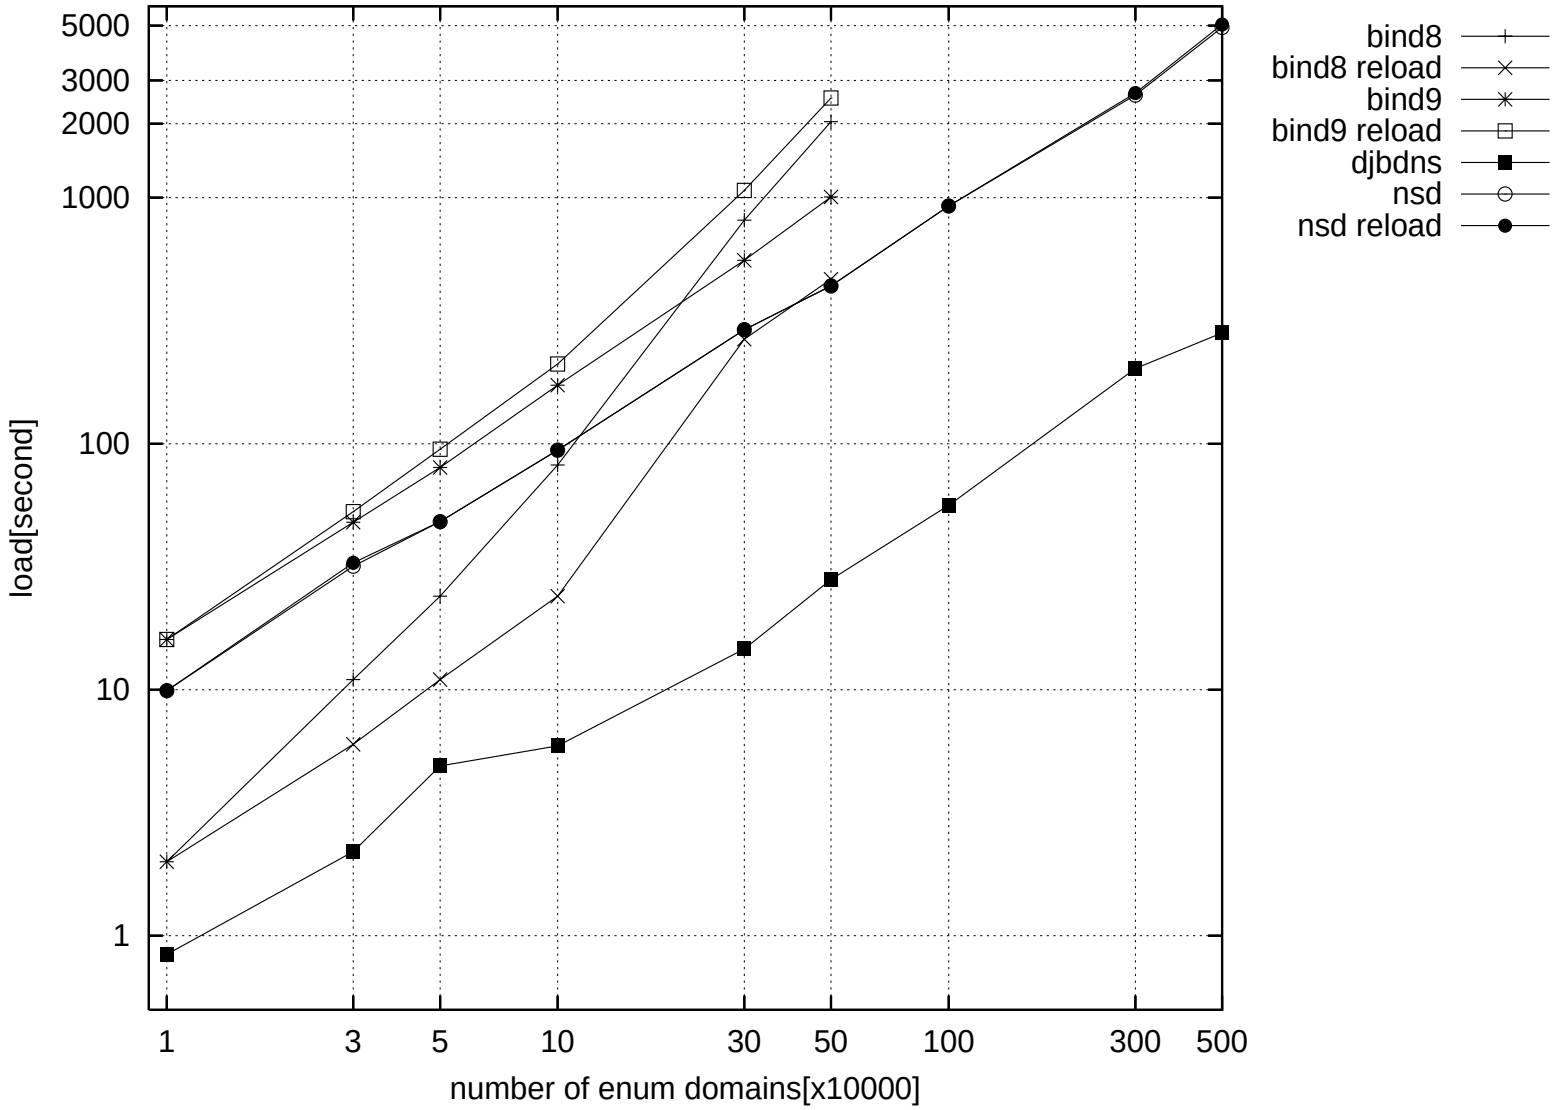

たけのこモデルTier2 応答性能

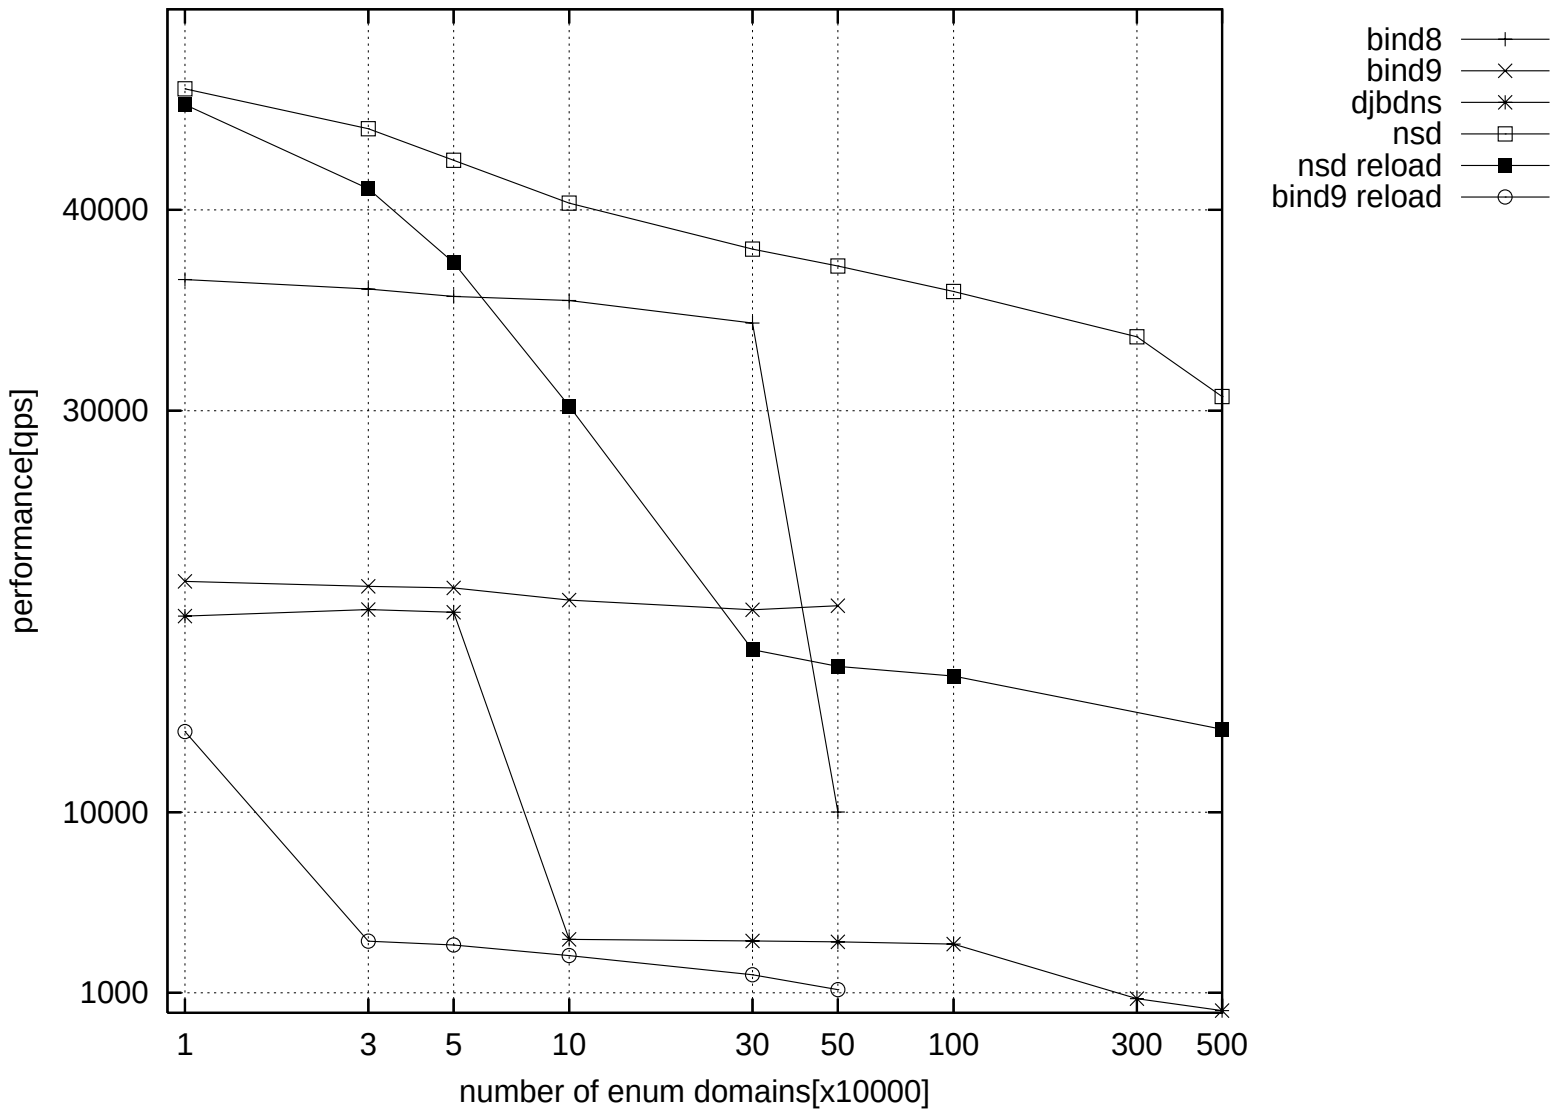

たけのこモデルTier2 評価

- 登録数(保持可能数)
  - BIND 8, BIND 9では50万
  - NSD, djbdnsでは500万
- サーバパフォーマンス
  - NSD(500万番号)、BIND 8(30万)は30000qps以上
  - BIND 9(50万番号)では20000qps
  - djbdns(100万番号)では3400qps、300万番号では700qps
- 更新頻度条件
  - NSDでは100万ドメイン名で1000秒、500万で5000秒
  - BIND 8, 9は30万ゾーンの読み込みに20分程度
  - djbdnsのデータファイル変換の時間がもっとも小さい
    - 100万番号で1分、300万番号で3分、500万番号で5分
- まとめ
  - djbdnsを用い、1システムで300万番号保持する
  - すべての番号帯に均等に問い合わせがくる場合、全体の300万/1億6000万の問い合わせ = 1000qps
  - 300万番号ごとに2台のサーバを用い、67システム配置すれば2億番号対応可能

割当単位モデルTier2 メモリ使用量

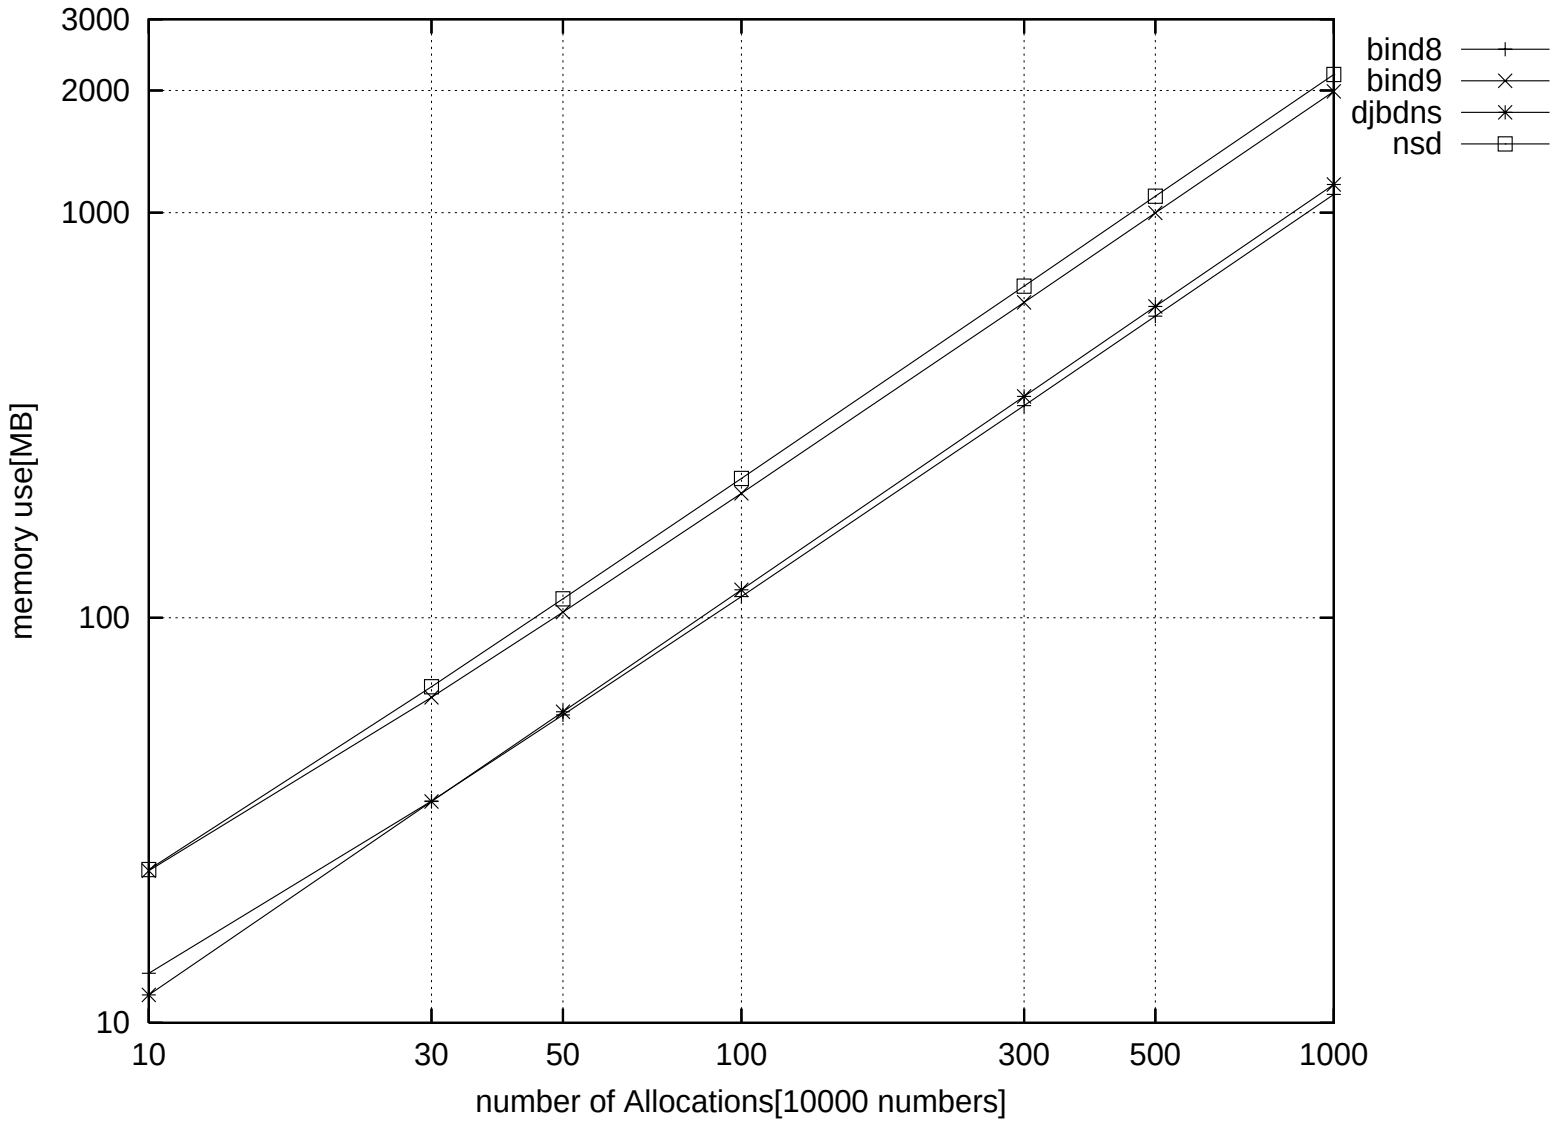

割当単位モデルTier2 ロード時間

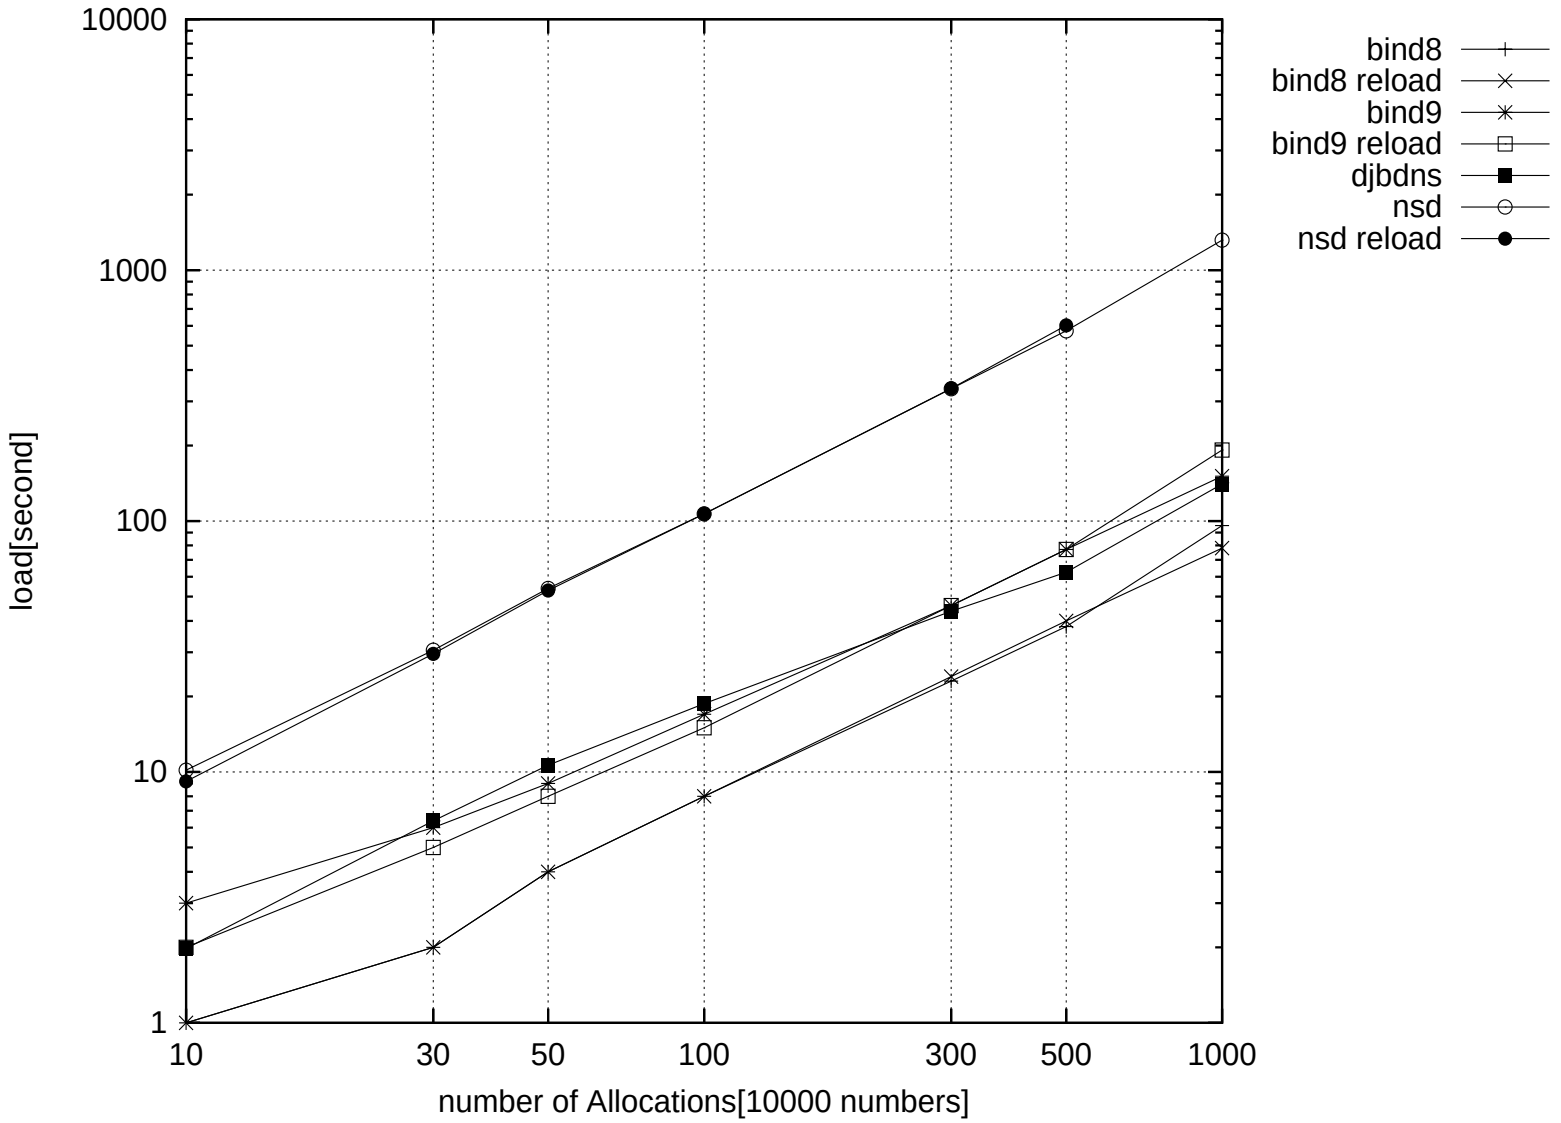

割当単位モデルTier2 応答性能

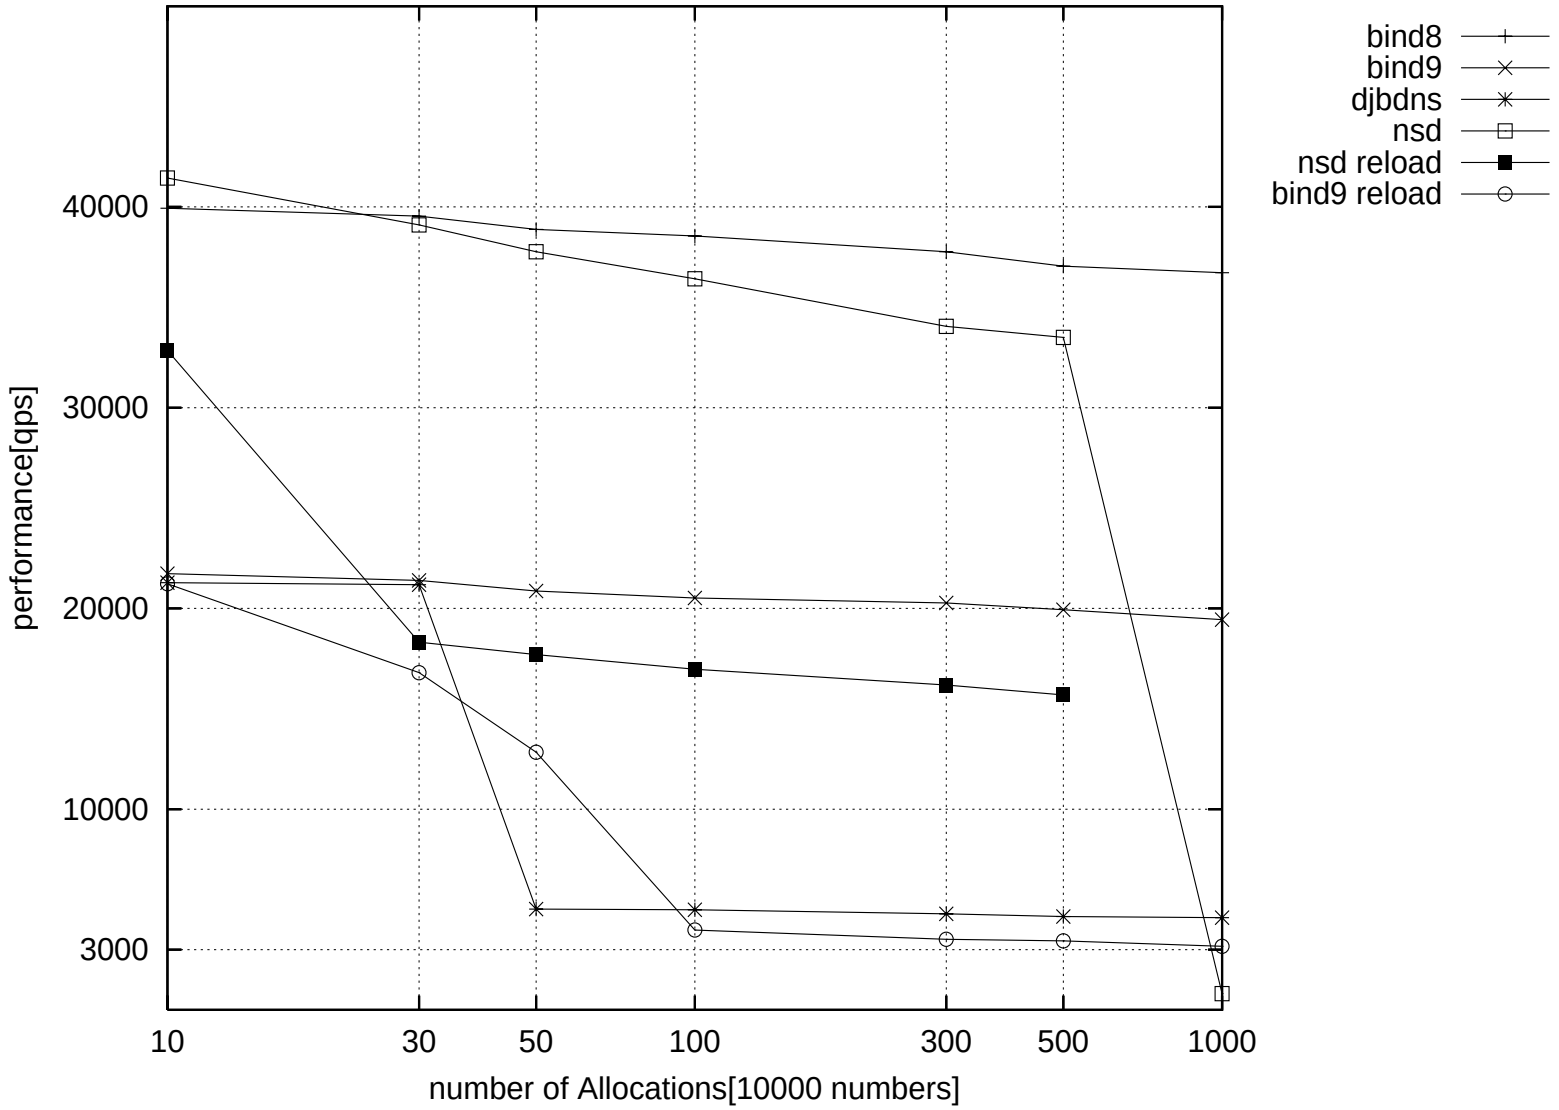

割り当て単位モデルTier2 評価

- □登録数
  - ○20000ゾーンで2億番号
  - ○どのサーバでも1万エントリのゾーンを1000ゾーン蓄積できた
- □サーバパフォーマンス
  - ○BIND 8は1000ゾーンまで3万qps以上の性能を示した
  - ○NSD, BIND 9は500ゾーンまで(メモリの制約)
  - ○djbdnsはほぼ一定であるが、他に比べ低い
- □更新頻度条件
  - ○BIND 8, 9は比較的短時間で読み込むことができる
  - ○djbdnsのデータファイル変換の時間が小さい
  - ○NSDはゾーンのコンパイル、読み込みに他の実装の10倍程度の時間がかかる
- □まとめ
  - ○BIND 8で1000ゾーンを運用する場合、1システムを3台のマシンで構成し、20システムで構成可能
  - ○BIND 9で500ゾーンを運用する場合、1システムを3台のマシンで構成し、40システムで構成可能

ENUM DNS評価・結論

□たけのこモデルTier1
- ○BIND 8, BIND 9を3台用いたシステムで1000万番号保持
- ○20システム配置することで2億番号対応可能
- ○合計60台

□たけのこモデルTier2
- ○djbdnsを用い、1システムで300万番号保持、2台のサーバ
- ○67システム配置すれば2億番号対応可能
- ○合計134台

□割り当て単位モデルTier1
- ○局番数 15万より、NSDのサーバを2台で構成可能

□割り当て単位モデルTier2
- ○BIND 8で1000ゾーンを運用する場合、1システムを3台のマシンで構成
- ○20システム配置することで2億番号対応可能
- ○合計60台

□たけのこモデルでも割り当て単位モデルでも実現可能

TLD(汎用jp)型ゾーンファイルの評価

- □ドメイン名リスト
  - ○/usr/share/dict/web2から生成、文字を追加
  - ○(平均ドメイン名長は実際のjpと似た値)
- □各ドメイン名ごとにネームサーバ 2
- □各ネームサーバごとに IPv4アドレス 1

```
$ORIGIN jp.
jp. IN SOA a.dns.jp. postmaster.dns.jp. (1 1H 5M 7D 10M)
jp. IN NS a.dns.jp.
jp. IN NS b.dns.jp.
a.dns.jp. IN A 10.0.0.1
b.dns.jp. IN A 10.0.0.2
...
example.jp. IN NS ns1.example.jp.
example.jp. IN NS ns2.example.jp.
ns1.example.jp. IN A 192.168.1.1
ns2.example.jp. IN A 192.168.1.2
...
```

TLD(汎用JP)型 メモリ使用量

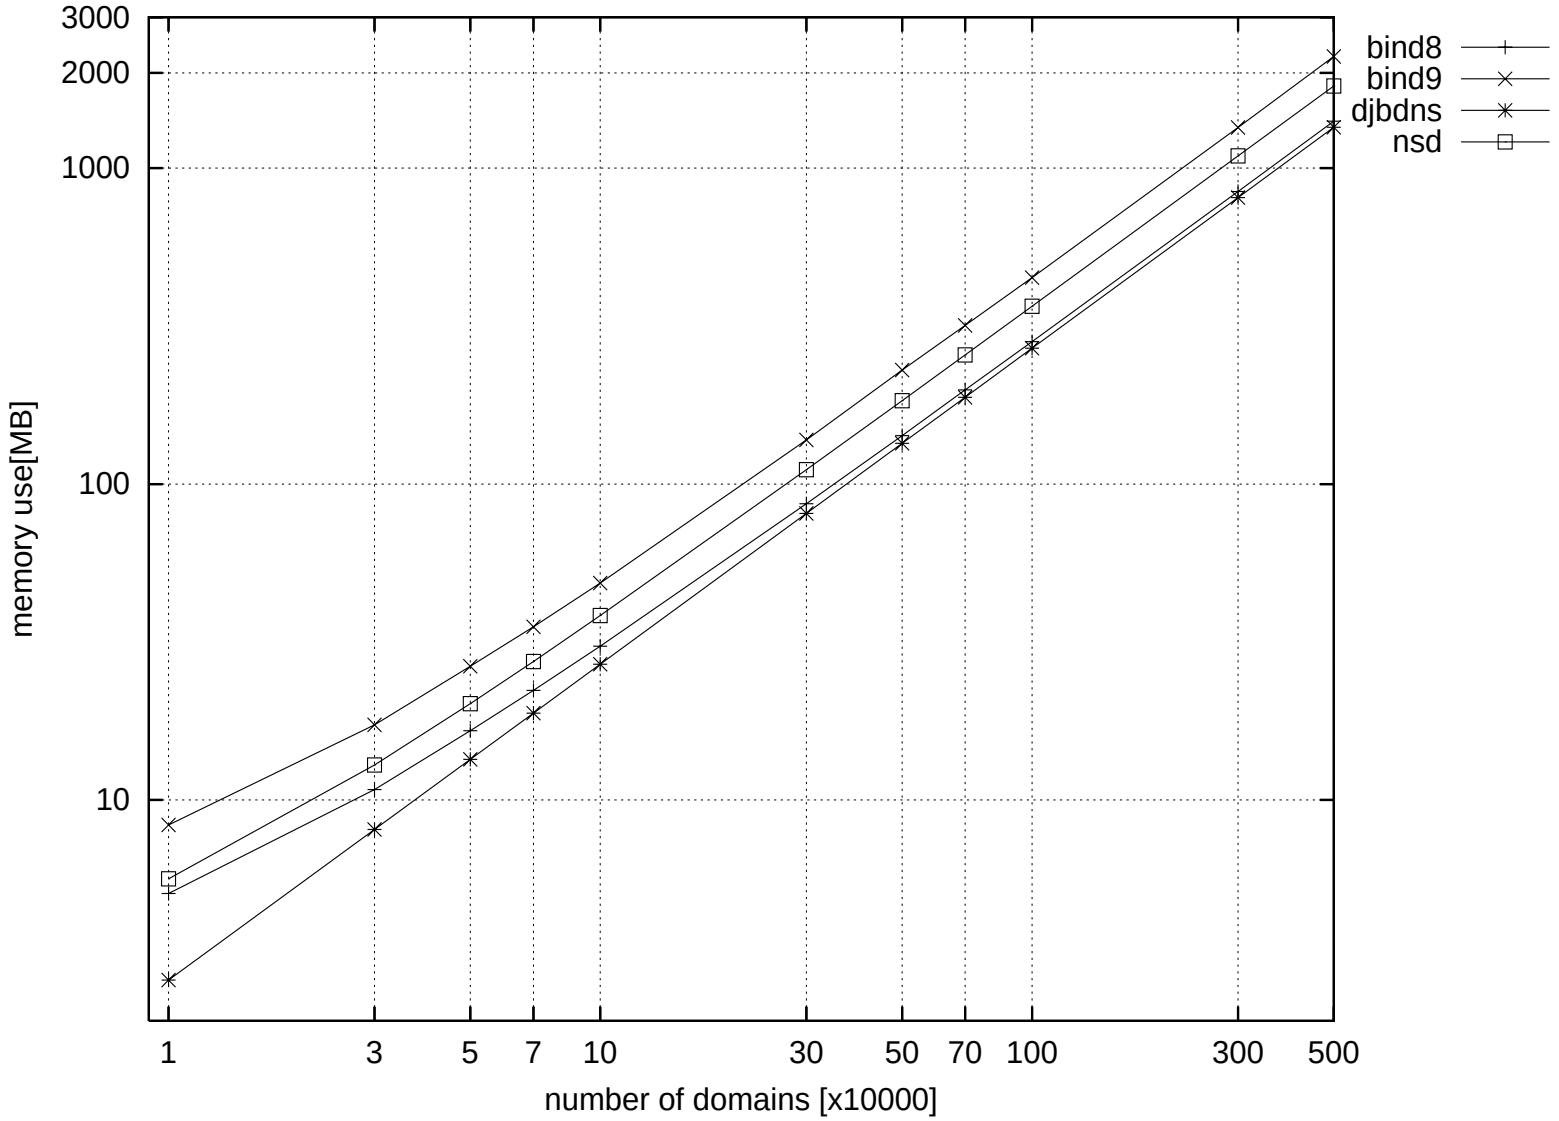

TLD(汎用JP)型 ロード時間

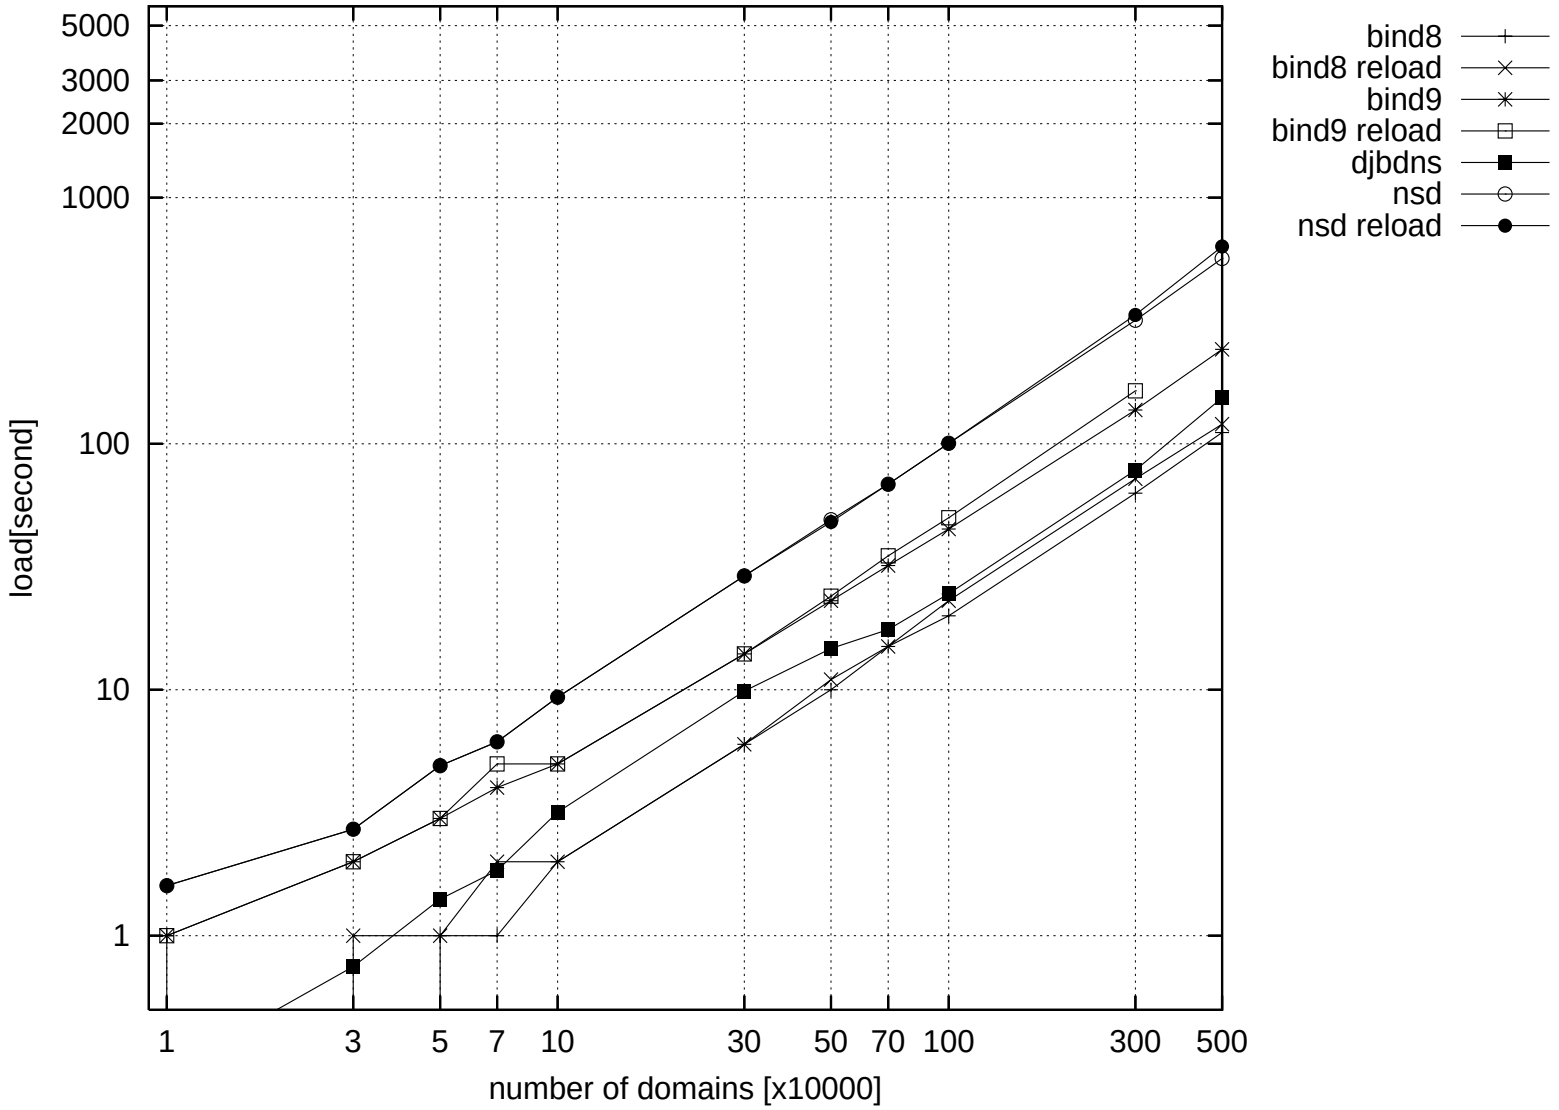

TLD(汎用JP)型 応答性能

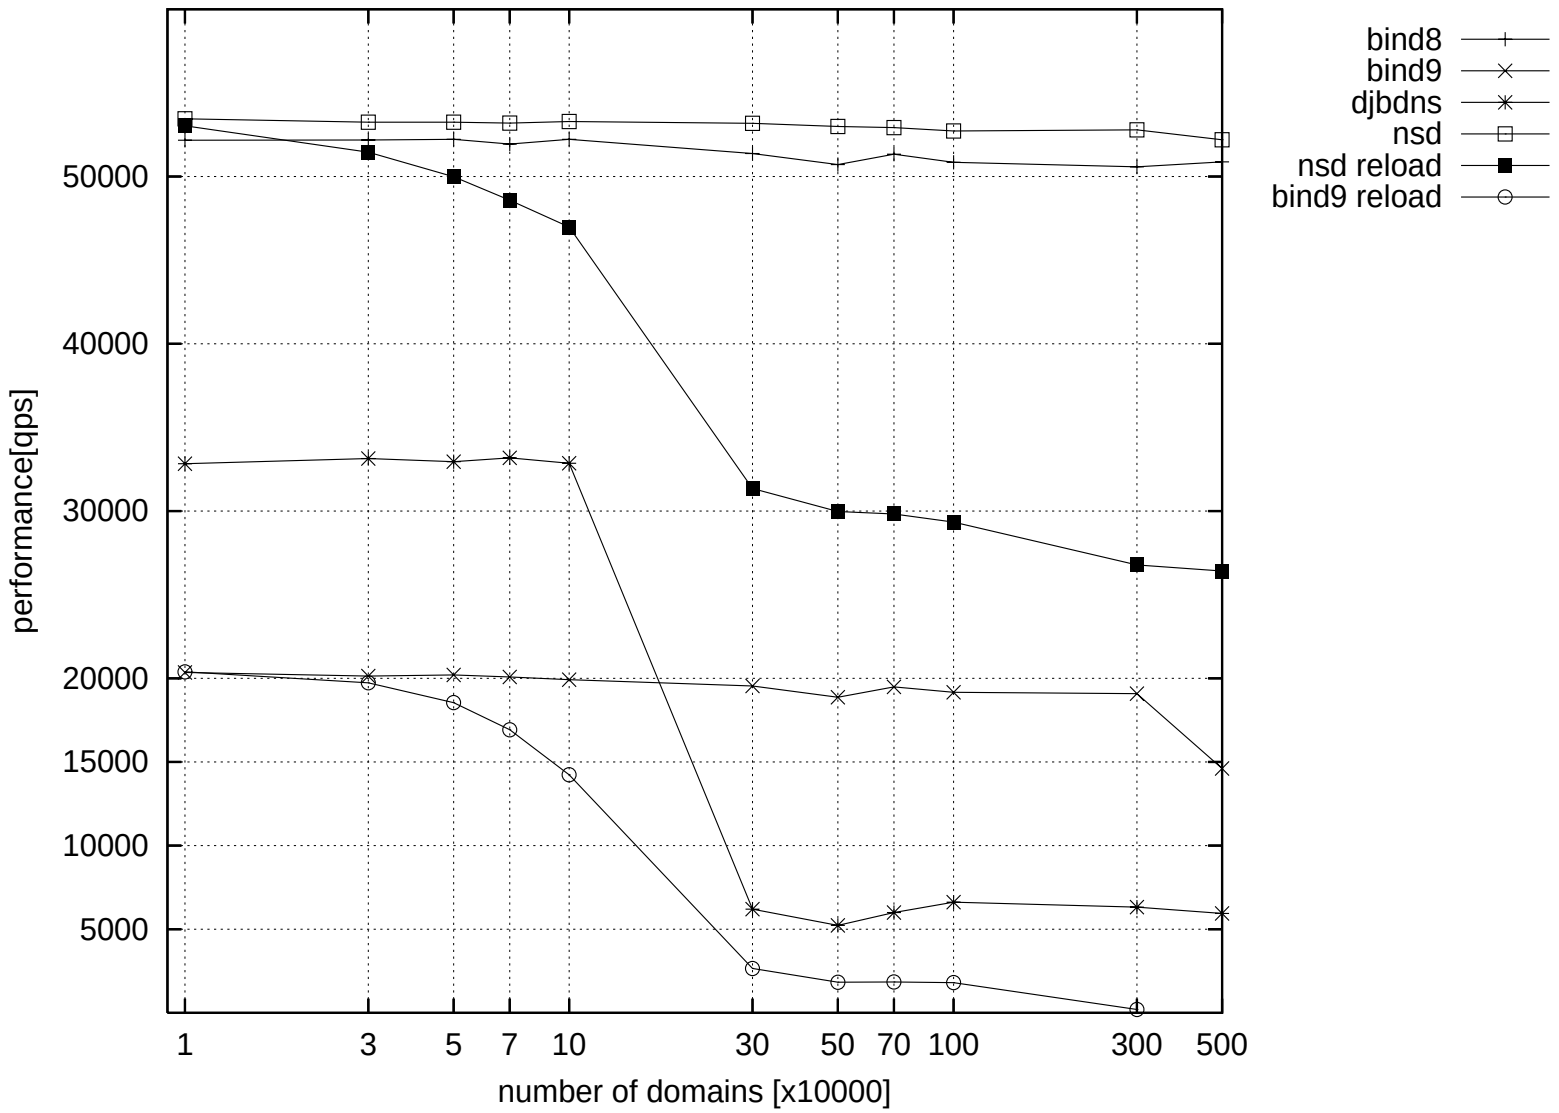

TLD(汎用JP)型 評価

- □メモリ使用量はドメイン名数にほぼ比例
  - ○ENUM型それぞれ、TLD型共に
  - ○500万ドメイン名で32bit CPUの限界に達する
- □ロード時間はドメイン名数にほぼ比例
  - ○更新頻度を考えなければ500万ドメイン名でも動く
- □リロード時間は、それぞれロード時間とほぼ同じ
- □応答性能
  - ○BIND 8, 9, NSDの場合、ドメイン名数が増えても、ほぼ一定(1割程度の劣化)
    - ▹メモリが足りなくなると急激に劣化する
  - ○djbdnsの場合、ドメイン名数が増えるに伴い、突然性能が劣化するが、劣化後も条件によっては有効な応答性能を示す
- □リロード中の応答性能
  - ○NSDの再読み込み中の応答性能は定常時の50%
  - ○BIND 9の再読み込み中の応答性能は定常時の10%

その他 DNSサーバについての情報

- BIND 8
  - DNSSECなしの場合、選択肢として考えられる
  - 読み込み中は問い合わせに答えない(運用上の考慮が必要)

- BIND 9.3.1
  - ロード、リロード後、新しいデータを答えるようになってから、しばらく内部で重い処理を行なっている
  - その間は応答性能が悪い
  - 内部処理が終るとよい性能がでる
  - 今回は、CPU負荷が1%になるまで待ち、そのあと応答性能を評価した

  - BIND 9.3.0は、ENUM型ドメイン名(. を多く含むドメイン名)の場合に応答性能が劣化したが、9.3.1で改善

その他 DNSサーバについての情報

- djbdns (tinydns)
  - 大量のデータを取り扱うと応答性能は悪くなるが、データ変換時間は短く、サーバへのロード時間はゼロなので更新に強い
  - 大量のゾーンを扱う場合、djbdnsでは一つのファイルで済む
    - BINDやNSDではゾーン数分のファイルを管理する必要あり
  - 非公式パッチのチェックが必要

- NSD
  - よいパフォーマンス、長いデータ準備・ロード時間
  - 周辺ツールにいくつか不具合があった
    - すでにpatchを送り、修正済み