

USPOREDBA PERFORMANSI REST i gRPC KOMUNIKACIJE U DISTRIBUIRANIM SUSTAVIMA

Comparison of REST and gRPC Communication Performance in Distributed Systems

Nikola Jakov Pavečić | doc.dr.sc. Marin Kaluža | Ivan Šimac

Veleučilište u Rijeci, Odjel za informacijske i komunikacijske tehnologije, Rijeka, Hrvatska



Tema istraživanja

Empirijska usporedba performansi REST i gRPC komunikacijskih protokola u distribuiranim sustavima



Metodologija

Implementacija identičnog User Servicea u obje tehnologije + load testing s Locust alatom (100, 500, 1000 korisnika)



Ključni rezultat

gRPC ostvaruje do 99,92% manju latenciju i 270% veći propusni kapacitet pri visokom opterećenju



Zaključak

HTTP/2 multipleksiranje je ključni čimbenik prednosti gRPC-a; preporučuje se hibridni pristup



UVOD - Kontekst istraživanja

Zasto je ovo važno?

- Suvremeni sustavi (Google, Netflix, Uber) imaju tisuće međusobno povezanih mikroservisa
- Kašnjenje od svega par ms mnogostruko se multiplicira u lancu poziva servisa
- Izbor komunikacijskog protokola direktno utječe na korisničko iskustvo i troškove infrastrukture
- Empirijski podaci su ključni za donošenje informiranih arhitektonskih odluka

400K+

zahtjeva ukupno generirano

6

testnih scenarija (2 protokola x 3 razine opterećenja)



UVOD - Hipoteza i cilj istraživanja

PRIMARNA HIPOTEZA

gRPC, zahvaljujući binarnom formatu Protocol Buffers i HTTP/2 protokolu, postiže nižu latenciju i veći propusni kapacitet u odnosu na REST - posebno pri visokim razinama opterećenja.



Usporedba

Empirijski izmjeriti i usporediti latenciju i RPS za REST vs. gRPC pri 3 razine opterećenja



Analiza

Identificirati uzroke performansnih razlika i točku preokreta gdje gRPC prednost postaje značajna



Preporuke

Pružiti konkretne preporuke za odabir tehnologije u stvarnim arhitektonskim scenarijima



6 ključnih REST načela (Fielding, 2000)

- Client-Server odvajanje
- Stateless komunikacija
- Cacheable odgovori
- Uniformno sučelje
- Slojevita arhitektura
- Code-on-demand (opcionalno)

Prednosti

- Široka prihvaćenost i ekosustav
- JSON čitljiv za ljude / debugging
- Native browser podrška
- Standardna OpenAPI dokumentacija

Ogranicenja

- HTTP/1.1 head-of-line blocking
- Svaka TCP konekcija = 1 zahtjev istovremeno
- JSON - tekstualni format (veći payload)
- Degradacija pri visokom opterećenju



Ključne komponente gRPC-a

- HTTP/2 kao transportni protokol
- Protocol Buffers (Protobuf) serijalizacija
- .proto definicija sučelja → auto-generacija koda
- Type safety i kompilacijska provjera
- 4 vrste komunikacije: Unary, Server/Client/Bidirectionalni streaming

HTTP/1.1

Jedan zahtjev po TCP konekciji → queue buildup → latencija raste eksponencijalno

HTTP/2

Multipleksiranje: više paralelnih streama na jednoj TCP konekciji → eliminira HOL blocking

Protobuf

Binarni format, 3–10× manji od JSON-a → brže parsiranje, manji mrežni promet



Pregled područja - Komparativna istraživanja

**Gupta et al.
(2020)**

Značajne performanske prednosti gRPC-a u mikroservisnoj arhitekturi pri visokom opterećenju; minimalne razlike pri niskom

**Indrasiri &
Siriwardena (2021)**

Prednosti gRPC-a rastu s velicinom podataka i brojem zahtjeva; HTTP/2 multipleksiranje kao ključni faktor

**Microsoft
(2023)**

Preporučuje gRPC za backend-to-backend komunikaciju s visokim performansnim zahtjevima; REST za web i javne API-je

**Netflix TechBlog
(2020)**

Migracija na gRPC donosi 30–40 % smanjenje latencije u produkciji, hibridni REST+gRPC pristup u produkciji

**Uber Engineering
(2019)**

Kombinirani pristup: REST za javne API-je i gRPC za internu mikroservisnu komunikaciju istovremeno



REST - Flask

- Python 3.10 + Flask 3.0.0
- Port 5000
- GET /user/<id> - dohvat jednog korisnika
- GET /users - dohvat svih korisnika
- JSON serijalizacija (jsonify())
- HTTP/1.1 transportni protokol
- 10 korisničkih zapisa u memoriji

gRPC

- Python 3.10 + grpcio 1.60.0
- Port 50051
- .proto definicija: GetUser + ListUsers RPC
- Auto-generiran Python kod iz protobuf-a
- ThreadPoolExecutor za konkurentnost
- HTTP/2 transportni protokol
- Identični podaci (10 zapisa u memoriji)



Metodologija - Testni sustav (Locust)

Locust - Load Testing Tool

- Open-source Python-baziran alat
- Definiranje ponasanja korisnika kroz Python klase
- Interaktivni dashboard (Statistics, Charts, Failures)
- Testiranje u GitHub Codespaces okruženju

Okruženje

- Ubuntu 24 LTS
- 2 CPU jezgre, 8 GB RAM
- Localhost (bez mreznog kašnjenja)
- Podaci isključivo u memoriji

Testni scenariji

100

korisnika

Spawn: 10/s | Nisko opterećenje

500

korisnika

Spawn: 50/s | Srednje opterećenje

1000

korisnika

Spawn: 100/s | Visoko opterećenje



Metodologija - Mjerene metrike



Latencija

- Prosjek (mean)
- Medijan (P50)
- P90 - 90. percentil
- P99 - 99. percentil
- Min / Max



Propusni kapacitet

- RPS - Requests per Second
- Ukupni broj zahtjeva
- 75% GetUser + 25% ListUsers distribucija



Stabilnost

- Broj neuspjelih zahtjeva
- Stopa grešaka (%)
- Carry-over eliminacija (restart medu testovima)

Distribucija zahtjeva po testu:

75% GetUser


25% ListUsers



Rezultati - 100 istovremenih korisnika

Nisko opterećenje - obje tehnologije prihvatljive performanse s minimalnim razlikama

Metrika	REST	gRPC	Poboljšanje
Prosječ. latencija	5 ms	<1 ms	~80% brže
99. percentil latencije	39 ms	1 ms	97,4% brže
Propusni kapacitet (RPS)	329,6	333,7	+1,2%
Ukupni zahtjevi	20.611	21.260	+3,1%
Stopa grešaka	0%	0%	-






Rezultati - 500 istovremenih korisnika

Srednje opterećenje - REST značajna degradacija; gRPC gotovo linearno skalira (+159% RPS)

Metrika	REST	gRPC	Poboljšanje
Prosjec. latencija	463 ms	<1 ms	99,8% brže
P90 latencija	2.200 ms	<1 ms	99,95% brže
Propusni kapacitet (RPS)	635,9	1.649,4	+159%
Ukupni zahtjevi	59.839	139.606	+133%
Stopa grešaka	0%	0%	-






Rezultati - 1000 istovremenih korisnika

Visoko opterećenje - REST prešao granicu kapaciteta, gRPC nastavlja linearno skalirati

Metrika	REST	gRPC	Poboljšanje
Prosjec. latencija	1.185 ms	<1 ms	99,92% brže
P90 latencija	6.600 ms	<1 ms	99,98% brže
Propusni kapacitet (RPS)	614,5 (pada)	2.275,1	+270%
Ukupni zahtjevi	51.306	155.840	+204%
Stopa grešaka	0%	0%	-






Trendovi - Latencija kroz sva opterećenja

REST latencija raste eksponencijalno: 5 ms → 463 ms → 1.185 ms. gRPC: konstanta <1ms kroz sva opterećenja.

Prosjec. latencija (ms) - REST vs gRPC





Trendovi - Propusni kapacitet (RPS)

gRPC RPS raste linearno: 333 -> 1.649 -> 2.275. REST doseže maximum pri 500k i zatim PADA (614 vs 635 RPS).

Propusni kapacitet (RPS) - REST vs gRPC





Usporedni prikaz - Poboljšanje gRPC-a vs REST-a

100 k.

Latencija brza za:

~80%

RPS veći za: +1,2%

500 k.

Latencija brza za:

99,8%


RPS veći za: +159%

1000 k.

Latencija brza za:

99,92%

RPS veći za: +270%





Diskusija - Uzroci performansnih razlika

HTTP/1.1 - Problem

- Jedna TCP konekcija = 1 zahtjev istovremeno
- Head-of-line blocking: zahtjevi čekaju u redu
- Pri 1000 korisnika: gomilanje zahtjeva → akumulacija kašnjenja na >1 sec
- Problem nije brzina obrade servera - vec transportni sloj koji serijalizira zahtjeve

HTTP/2 - Rješenje

- Multipleksiranje: jedna TCP konekcija hendla više paralelnih zahtjeva
- Svaki zahtjev dobiva vlastiti stream ID → podaci isprepleteni u frame-ovima
- Svi zahtjevi mogu biti poslani kroz mali broj TCP konekcija bez gomilanja
- Protocol Buffers: sekundarni faktor - binarni format smanjuje velicinu payloada 3–10×



Diskusija - Verifikacija hipoteze

Polazna hipoteza: gRPC ce ostvariti 30% nižu latenciju i 50% veći propusni kapacitet

100 k.

Predviđeno: 30% niža latencija

Stvarno: 80% niža latencija

POTVRĐENO

500 k.

Predviđeno: 50% veći RPS

Stvarno: 99,8% niža lat. | +159% RPS

POTVRĐENA

1000 k.

Predviđeno: linearan rast

Stvarno: 99,92% niža lat. | +270% RPS

EKSPONENCIJALNO

Zaključak: Hipoteza je potvrđena. Prednosti gRPC-a nisu linearne jer rastu eksponencijalno s opterećenjem.



Preporuke - Kada koristiti REST?

REST - Idealan za javne API-je i web aplikacije



Javni API-ji

Razvojni inženjeri poznaju REST | OpenAPI/Swagger dokumentacija | Lak onboarding za vanjske korisnike



Web aplikacije

Browseri nemaju native gRPC podršku | REST jedina opcija za frontend-backend komunikaciju



Nisko opterećenje

Do ~50 RPS razlika zanemariva | Dodatna kompleksnost gRPC-a nije opravdana za jednostavne CRUD operacije



Caching

HTTP caching mehanizmi (Cache-Control, ETag) standardizirani i lako implementirani uz REST



Preporuke - Kada koristiti gRPC?

gRPC - Superioran za internu mikroservisnu komunikaciju s visokim opterećenjem



Mikroservisi

1000+ korisnika | Jedan servis poziva 5-10 drugih servisa -> latencija se multiplicira u lancu



Streaming

Bidirectional streaming za real-time aplikacije | Server/Client streaming nativno podržano



Mobile/IoT

Protocol Buffers: manji payloadi -> ušteda propusnosti na mobilnim mrežama i IoT uređajima



Polyglot sustavi

Auto-generacija koda iz .proto za 10+ jezika | Type safety i konzistentnost sučelja



Preporuke - Hibridni pristup (Best of Both Worlds)



Netflix

REST za streaming API i korisničke zahtjeve | gRPC za internu mikroservisnu komunikaciju

Uber

REST za rider/driver API | gRPC za dispatch, routing i pricing servise



Buduca istraživanja



Realni DB scenariji

Testiranje uz PostgreSQL/Redis radi I/O varijabilnosti i transakcijskih troškova



Veći payloadi

Različite velicine (1 KB–1 MB) za procjenu dominantnosti Protocol Buffers prednosti



Streaming scenariji

Server/bidirectional streaming - gRPC napredne mogućnosti koje REST ne može replicirati



Cloud infrastruktura

Testiranje na AWS/GCP/Azure s realnim mrežnim kašnjenjima i produkcijskim opterećenjem



Alt. frameworkovi

Express.js / Spring Boot / Go net/http - usporedba REST implementacija u različitim jezicima



Produkcijski REST server

Gunicorn/uWSGI s više worker procesa umjesto Flask dev servera za fer usporedbu

ZAKLJUČAK



Hipoteza potvrđena: gRPC do 99,92% manja latencija i 270% veći RPS



Prednosti gRPC-a rastu eksponencijalno s opterećenjem - nisu linearne!



Ključni uzrok: HTTP/2 multipleksiranje eliminira HOL blocking prisutan u HTTP/1.1



Točka preokreta: ~500 istovremenih korisnika gdje gRPC prednost postaje kritična



Preporuka: hibridni pristup - REST za javne API-je/web, gRPC za internu mikroservisnu komunikaciju



Oba sustava: nulta stopa grešaka kroz svih 6 testnih scenarija s 400.000+ zahtjeva

Hvala na pažnji!

Pitanja i diskusija

Nikola Jakov Pavečić

doc.dr.sc. Marin Kaluza | Ivan Simac

Veleučilište u Rijeci | CASE 2026

400K+

zahtjeva

99,92%

manja latencija

+270%

veći RPS