Web Performance A Schrödinger's Cat

Does perfect performance even exist?

Wie geht Performance

- Server Konfiguration
- Protokolle
- Kompression
- Lazy Loading & Loading Indicator
- SSR / SSG

Fertig 🎉

.... oder doch nicht?

Prefetching

Network

TCP

Caching

Tight mode

CDN

HTTP Technologie

MPA

Web Vitals

Multiplexing

Resource Prioritization

SFA

Compression

User hardware

Worker

SSG

Prerendering

Browser behaviour

BF-cache

Header

Main Thread

SSR

Throttling

Preloading

Adaptive Loading

Unbeeinflussbare Faktoren

Browser Verhalten

Netzwerk

User Hardware

Zu mir

23 Jahre alt

Fullstack Software Engineer &
Product Owner

Dynatrace - Real User Monitoring

Enthusiastischer Feuerwehrmann

Survey Time

Grundlegendes

Browser Architektur

Browser Process

Renderer Process

Summary Bottom-up Call tree **Event log**

Aa (*) .ab Filter All Loading Messaging Scripting Rendering Painting

Start time	Self time	Total time	Activity
0.2 ms	0.2 ms	1.5 ms	Evaluate script
174.5 ms	0.0 ms	0.0 ms	Event: pagehide
174.6 ms	0.1 ms	0.4 ms	Event: visibilitychange
175.0 ms	0.0 ms	0.0 ms	Event: webkitvisibilitychange
175.1 ms	0.0 ms	0.0 ms	Event: unload
175.4 ms	0.0 ms	0.0 ms	Send request
175.5 ms	0.0 ms	0.0 ms	Receive response
176.4 ms	0.0 ms	0.0 ms	Receive data
178.1 ms	0.0 ms	0.0 ms	Finish loading
178.2 ms	0.3 ms	0.3 ms	Parse HTML
178.7 ms	0.0 ms	0.0 ms	Parse HTML
178.8 ms	0.0 ms	0.0 ms	Event: readystatechange
178.8 ms	0.0 ms	0.0 ms	Event: DOMContentLoaded
178.8 ms	0.2 ms	0.2 ms	Recalculate style
179.0 ms	0.0 ms	0.0 ms	Event: readystatechange
179.0 ms	0.0 ms	0.0 ms	Event: load
179.0 ms	0.0 ms	0.0 ms	Event: pageshow
179.1 ms	8.2 ms	8.2 ms	Layout
187.5 ms	0.0 ms	0.0 ms	Schedule style recalculation
191.9 ms	0.0 ms	0.0 ms	Event: pagereveal
191.9 ms	0.0 ms	0.0 ms	Recalculate style
191.9 ms	0.1 ms	0.1 ms	Pre-paint
192.0 ms	0.1 ms	0.1 ms	Paint
192.2 ms	0.0 ms	0.0 ms	Layerise
192.5 ms	0.0 ms	0.0 ms	Commit
208.5 ms	0.0 ms	0.0 ms	Pre-paint
208.6 ms	0.0 ms	0.0 ms	Layerise
208.6 ms	0.0 ms	0.0 ms	Commit

Select

Summary Bottom-up Call tree Event log

Range: 0 ms - 856 ms

Scripting	310 ms
System	64 ms
Rendering	41 ms
Loading	17 ms
Painting	1 ms
Messaging	1 ms
Total	856 ms

Was ist Performance?

Web performance ist

- die objektive Messung
- und wahrgenommene Nutzererfahrung

einer Webseite/-applikation

Perceived Performance

“Wie schnell fühlt sich die Seite an?”

- Lädt die Seite schnell und zeigt mir dann an das sich etwas tut oder dauert es ewig bis überhaupt mal etwas kommt.
- Verkürzen der Ladezeiten mit Ladeanzeigen
 - Bildern (siehe Videospiele) und Texten (Tipps/Witze)
 -

Objektive Messung - Einflüsse

- Benutzerseite
 - Bandbreite, Hardware (CPU/GPU)
 - Code Architektur
 - Caching
- Serverseitig
 - Bandbreite/Durchsatz, IO
 - Garbage Collection
 - Code Architektur
 - Datenanbindung (Datenbank, andere Quellen)

Core Web Vitals

(Loading)

LCP

Largest Contentful Paint

Wann ist der größte Abschnitt (im sichtbaren Bereich) seit dem Ladebeginn der Seite fertig?

(Interactivity)

INP

Interaction to Next Paint

Durchschnittliche Dauer zwischen Interaktion und dem nächsten Paint

(Visual Stability)

CLS

Cumulative Layout Shift

Wie stark verändert sich der Inhalt nach dem Laden

~~FID~~
First Input Delay

Ersetzt durch INP im März 24

Other Metrics

- TTFB - Time to first byte: Zeit bis zum ersten Byte
- Visually complete: Wie lange dauert es bis sich im sichtbaren Bereich nichts mehr ändert
- Speed index: VC - Nimmt auch die Größe des nicht fertigen Bereichs als Gewichtung
- DOMInteractive: Zeit, bis der Benutzer mit der Seite interagieren kann
- Total blocking time: Zeit, die die Seite nicht interaktiv war
- FCP: First contentful paint - Wann war der erste Paint
- ... many more

Wie berechnet man objektive Performance

- Lokal
 - Browser Devtools: Web Vitals, Waterfall, CPU/Netzwerk drosselung
- Extern
 - Manuell
 - <https://pagespeed.web.dev/> (Google)
 - <https://webpagetest.org> (Catchpoint)
 - Automatisierte Techniken
 - RUM
 - Synthetic

Real User Monitoring

- Performance, Errors
- Page Usage/User journeys
 - Session Replay
 - Rage Clicks
 - Neue/rückkehrende Benutzer
 - Woher kamen die Benutzer
- Welche Ressourcen werden angefordert
- Fullstack Monitoring:
 - Verlinkung mit Backend Daten (Service Level)

Synthetic

- Agenten, die eine HTTP-Anfrage durchführen oder einen Headless Browser verwenden
 - Antwort verifizieren
 - Visuelle kontrolle
- Konfigurierbar
 - Ort
 - Interval
 - Bandbreite
- Verfügbarkeit
- Alarmierung bei Problemen (baselining)

Performance Verbesserungsmöglichkeiten

(ein paar zumindest 😊)

Bilder

Grundlagen

- LCP-Image nicht lazy laden

```
<head>  
  <link rel="preload" href="/hero.png" as="image" />  
</head>  

```

- Verschiedene Bildgrößen anbieten (aber auch nicht zu viele)
- Verschiedene Bildformate

DPR

- Unterschied zwischen CSS & Physischen Pixel
- “Device pixel ratio” (DPR) bedenken
 - $500 \text{ CSS pixels} * 2 \text{ DPR} = 1000\text{px image}$

CSS Pixel

DPR: 2

DPR: 3

Bild Größen

- `srcsets` benutzen

```

```

Bild Formate

- Recherchieren Sie, welche Formate für Ihre Bedürfnisse am besten geeignet sind
- Kompressions benutzen (lossless or lossy)
- Serverseitige Bestimmung des Formats
- Zu großes HTML

```
<picture>
  <source type="image/avif" srcset="image.avif">
  <source type="image/webp" srcset="image.webp">
  
</picture>
```

```
<picture>
  <source type="image/avif"
    srcset="/image-500.avif 1x, /image-1000.avif 2x, /image-1500.avif 3x">
  <source type="image/webp"
    srcset="/image-500.webp 1x, /image-1000.webp 2x, /image-1500.webp 3x">
  
</picture>
```

465 bytes (UTF-8)

für ein Bild

Bilder

Fetch Priorities

Fetch priorities

- Zeigt dem Browser wichtige ressourcen (CSS, JS, Bilder...)
- Browser entscheiden grundsätzlich selbst was wichtig ist. Aber man kann versuchen nachzuhelfen

Wie konfiguriert man Fetch Priorities

```
● ● ●  
  
<link rel="preconnect" href="https://example.com" />  
  
<link rel="preload" href="/js/script.js" as="script"  
fetchpriority="high" />  
<link rel="preload" href="/js/script.js" as="script" fetchpriority="low"  
/>  
  
  
  
<script href="/js/script.js" async />  
<script href="/js/script.js" defer />
```

- HTML parsing
- Script downloading
- Script executing

`<script />`

`<script async />`

`<script defer />`

Das heißt:
Browsers verhalten sich bei Ressourcen alle
gleich...

oder?

Main Resource & Font

? Type / Priority ?	Highest	High	Medium	Low	Lowest
Main resource (HTML)
Font (preload)
Font (@font-face)

CSS

? Type / Priority ?	Highest	High	Medium	Low	Lowest
CSS (preload)
CSS (head)
CSS (import)
CSS (print)
CSS (bottom)

JS

? Type / Priority ?	Highest	High	Medium	Low	Lowest
JS (preload)
JS (prefetch)
JS (head)
JS (async)
JS (defer)
JS (body)
JS (bottom)

Image

? Type / Priority ?	Highest	High	Medium	Low	Lowest
Image (preload)
Image (preload + fetchpriority)
Image (body)
Image (lazy)
Image (hidden)
Image (CSS bg)
Image (poster)
video

Fetch

? Type / Priority ?	Highest	High	Medium	Low	Lowest
Fetch (inline)
Fetch (defer)
Fetch (fetchpriority)
Fetch (manual priority)

Fetch Priorities

Main Thread & Long Tasks

Main Thread & Long tasks

- JS ist Single Threaded
- Aufgaben
 - Skript Ausführung
 - Inputs/Events verarbeiten
 - Paints/Layout-Berechnung
- Frame duration: $1\text{s} (1000) / 60\text{Hz} = 16\text{ms}$
- Long Tasks: Blockieren Main Thread $\geq 50\text{ms}$ ($\Rightarrow$ 3 frames)

Long task Verbesserungen

Tasks unterbrechen:

- *setTimeout*

```
return new Promise(resolve => {  
  setTimeout(resolve, 0);  
});
```

- Scheduler Api (eingeschränkte Verfügbarkeit)

Auslagern:

- Web workers
 - Komplexer, wann haben sie Sinn?

Web Worker

- Tasks in einem separaten Thread laufen lassen
- Typen:
 - Workers: führen ein Skript aus
 - lange/große Berechnungen auslagern (z.B. Rendering)
 - SharedWorkers
 - können von mehreren Skripten ausgeführt werden, solange nur eine Domain verwendet wird
 - Laufen über einen Port
 - ServiceWorker
 - Proxy Server (Browser ↔ Netzwerk)
 - => Siehe PWAs
 - => Offline usage, Hintergrund aktualisierungen, Netzwerkanfragen intercepten...

Operation	
Instantiation of a web worker	40 ms
Instantiation of a broadcast channel	1 ms
Communication latency with postMessage	0.5 ms
Communication latency with broadcast channel	1.5 ms
Communication speed with postMessage	80 kB/ms
Communication speed with broadcast channel	12 kB/ms
Maximum message size with postMessage	1300 kB (16ms)
Maximum message size with broadcast channel	200 kB (16ms)

Worker Beispiele (main thread => worker)

- JSON parsing
 - 15 kb: 30-50ms => 5-10ms
 - 1.5 mb: 40-50ms => 15-20ms
 - 15 mb: 90-110ms => 70-95ms
- Arrays sortieren
 - 100k: 10ms => 1ms
 - 1m: 200ms => 10ms
 - 10m: 2.s => 100ms
- Bildmanipulation
- Andere komplexe Kalkulationen

Main Thread & Workers

Back Forward Cache

Navigation types

Back/Forward

Reload

Navigate

BF Cache

- Seiten cachen
- Back/Forward Navigation => Seite sofort darstellen

Application

- Manifest
- Service workers
- Storage

Storage

- ▶ Local storage
- ▶ Session storage
- IndexedDB
- ▶ Cookies
- Private state tokens
- Interest groups
- ▶ Shared storage
- Cache storage
- Storage buckets

Background services

- Back/forward cache

Back/forward cache

Successfully served from back/forward cache.

URL:

Test back/forward cache

[Learn more: back/forward cache eligibility.](#)

Back/Forward Cache Probleme

- Mögliche Probleme
 - Header: `Cache control: no-store`
 - Javascript: `unload` event handler
- Serverseitige Lösung:
 - Header: `Permission Policy: unload=()`
 - Unload event => zu `pagehide` Event wechseln

Abschluss

Abschließend

- Es gibt immer Raum für Verbesserung
- Perfekte Performance existiert nicht wirklich
 - jedoch kann man viel verbessern
- “Ich weiß, dass ich nichts (wenig) weiß”

Generelle Empfehlungen

- Web-Performance zum Bestandteil des Entwicklungszyklus machen
- Reguläre checks (manuell und/oder automatisiert)
- Am neuesten Stand der Zeit bleiben

Danke

Die Katze ist aus der Box