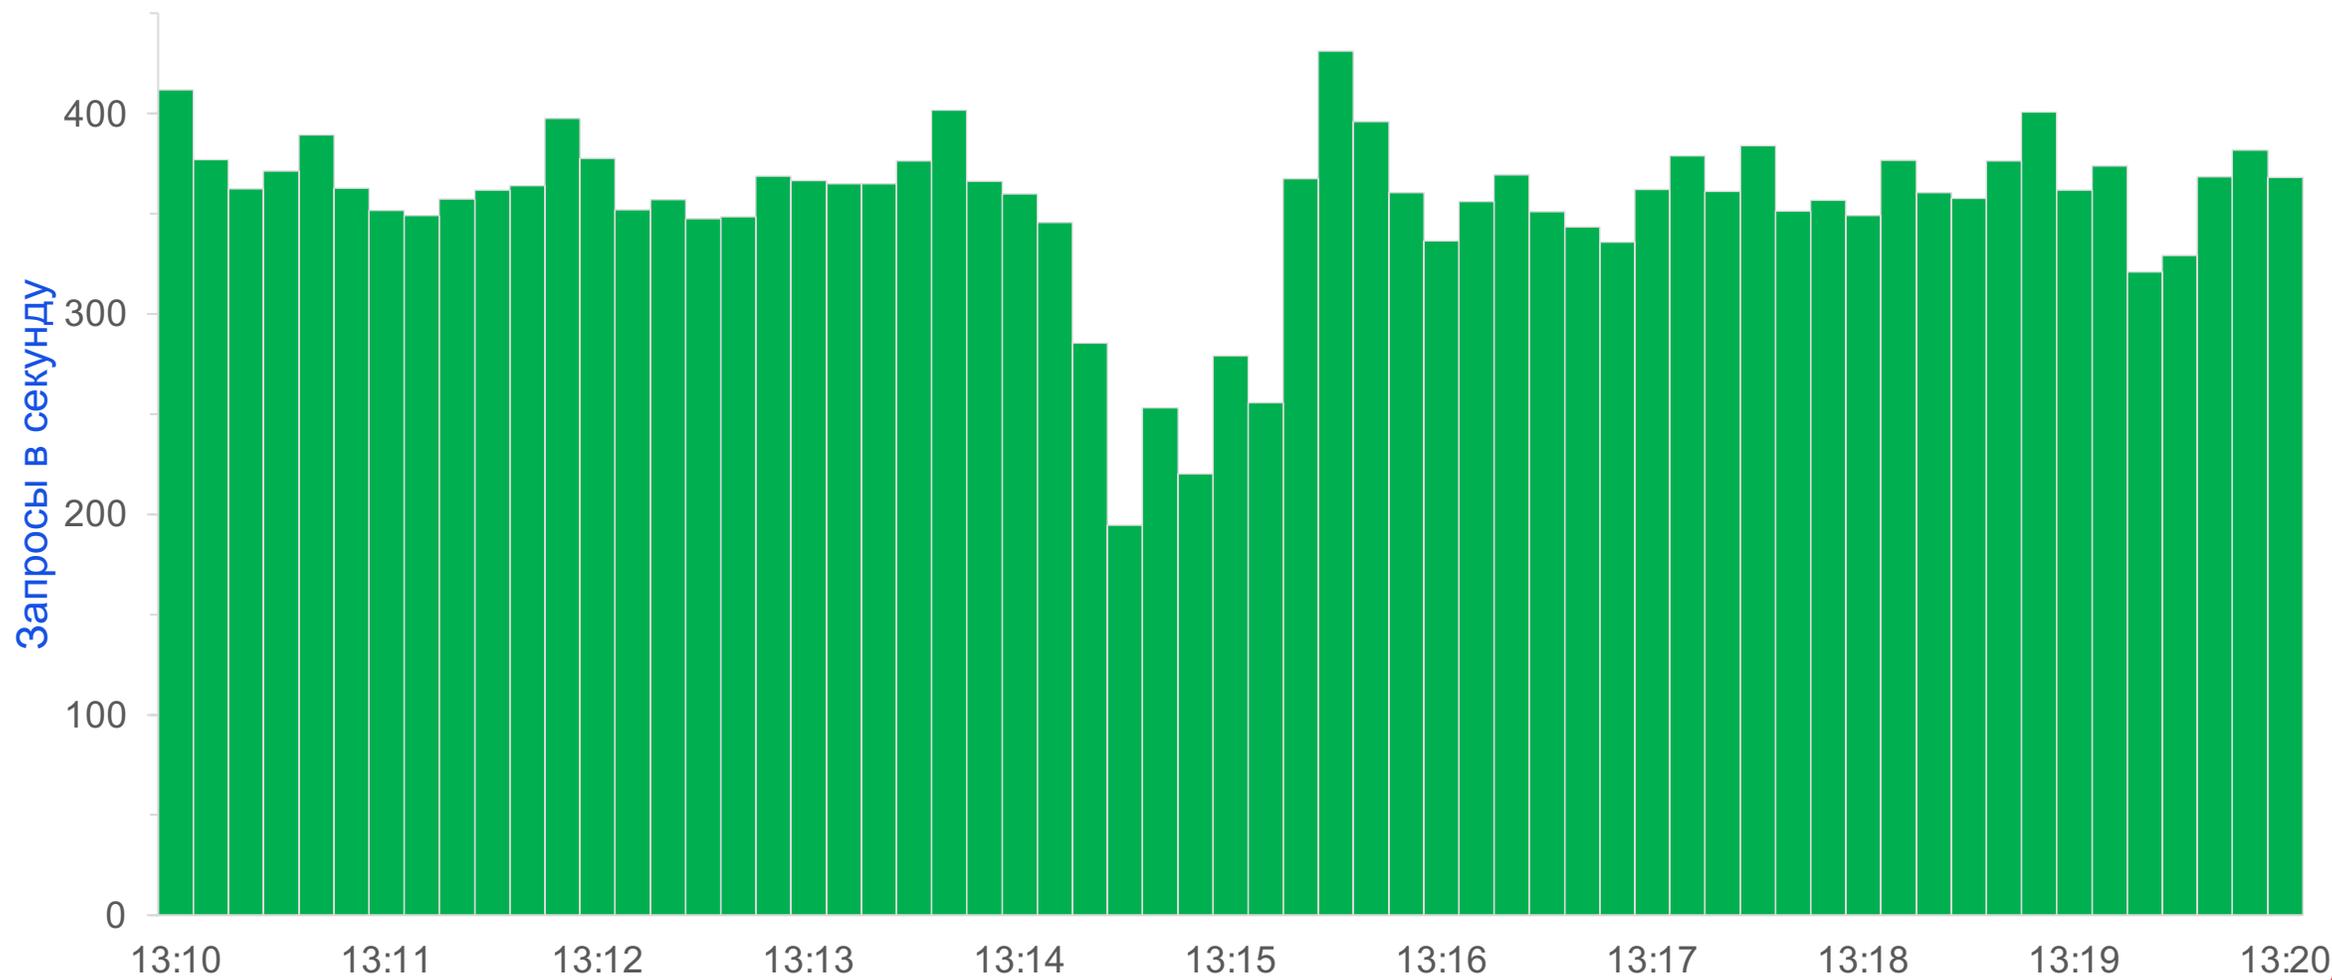


# Как сделать деплой незаметным для пользователя

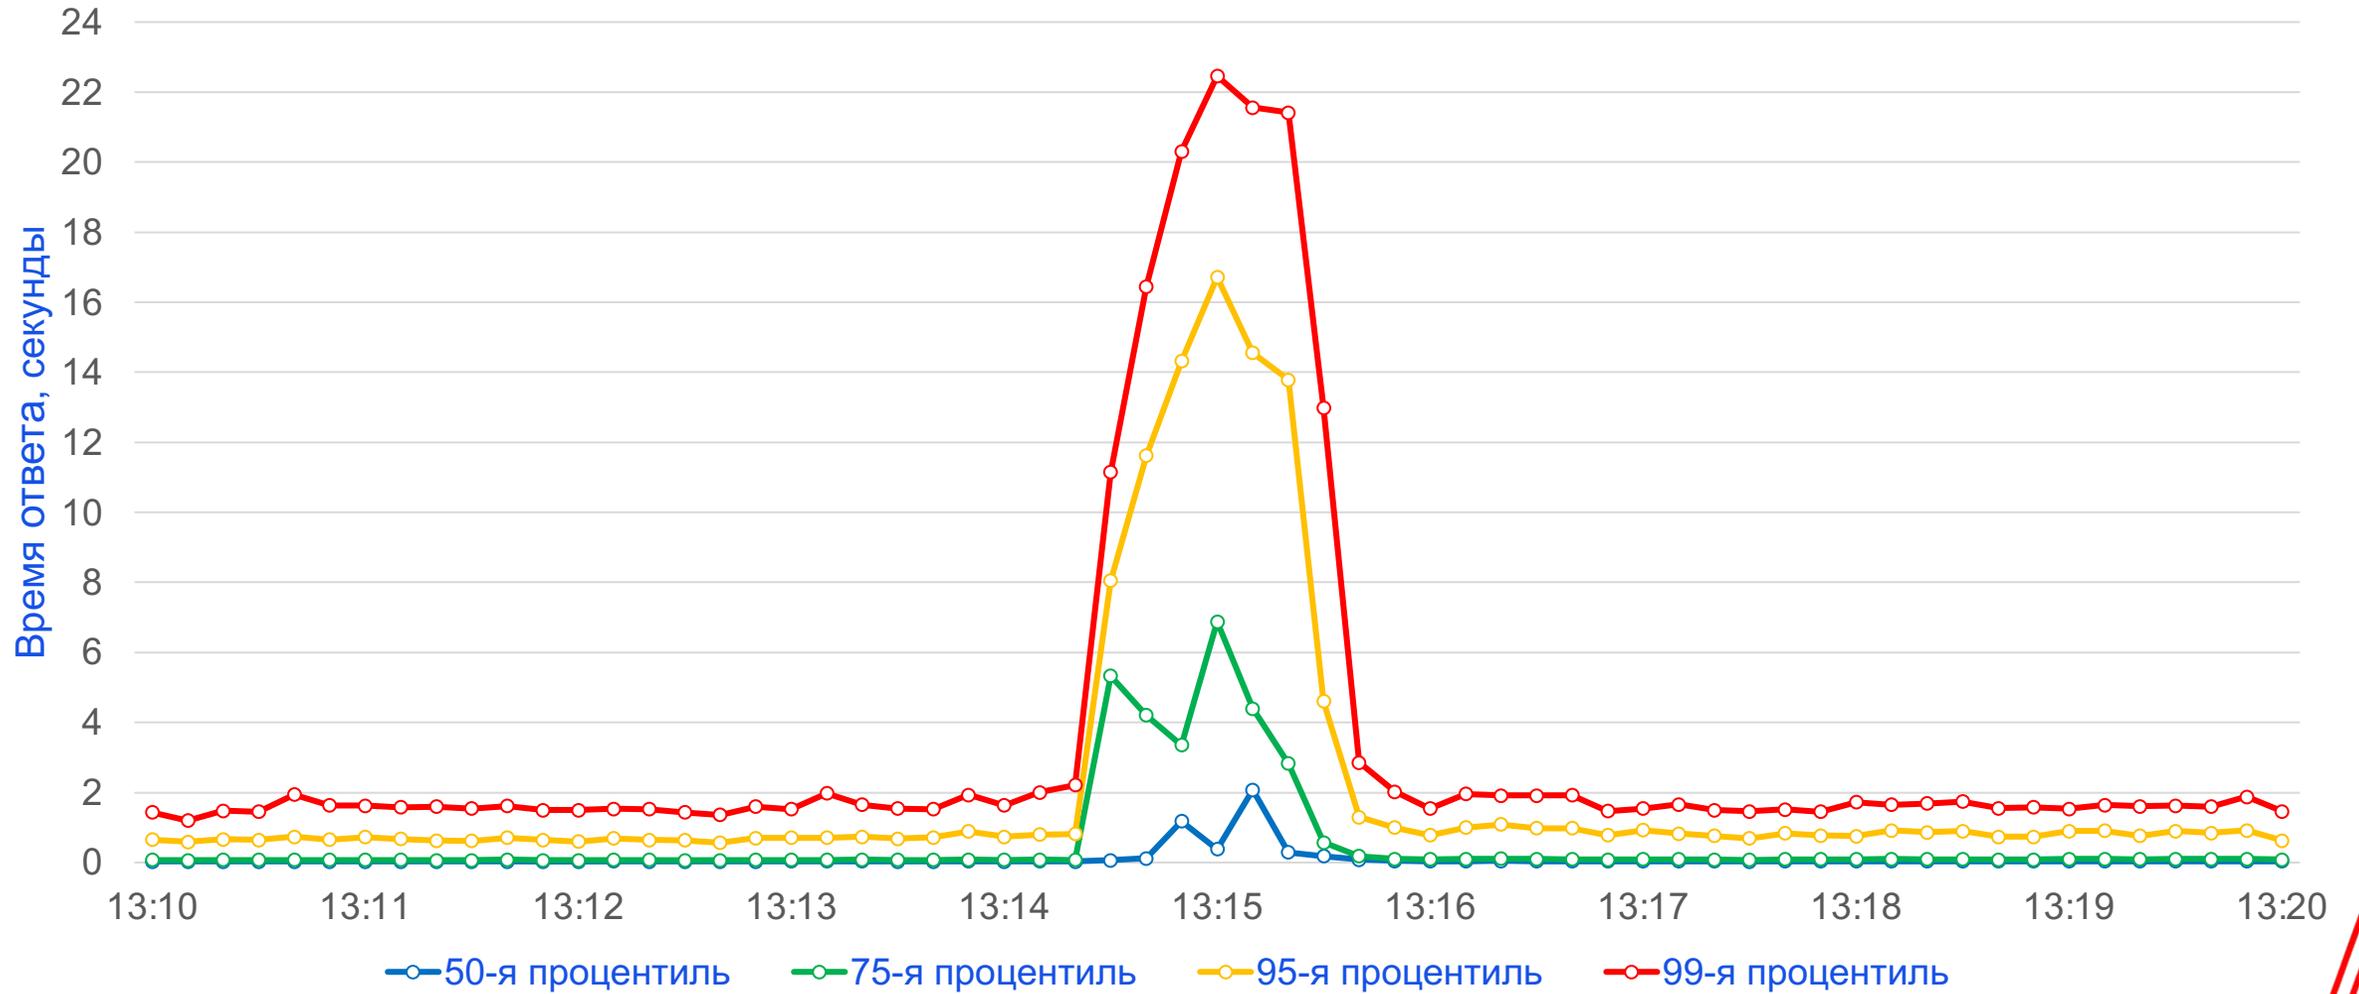


# Деплой

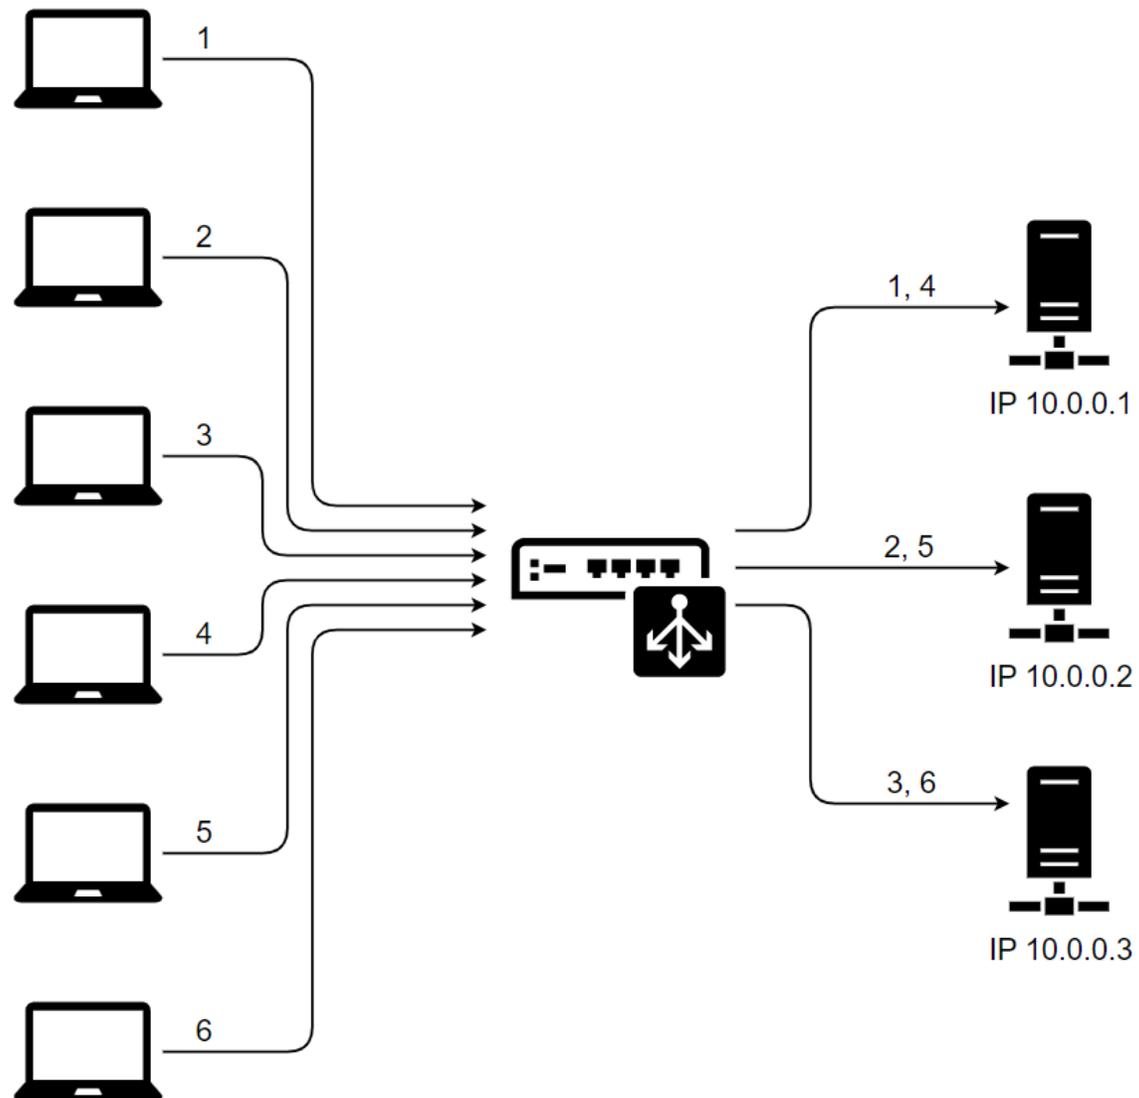




# Деплой



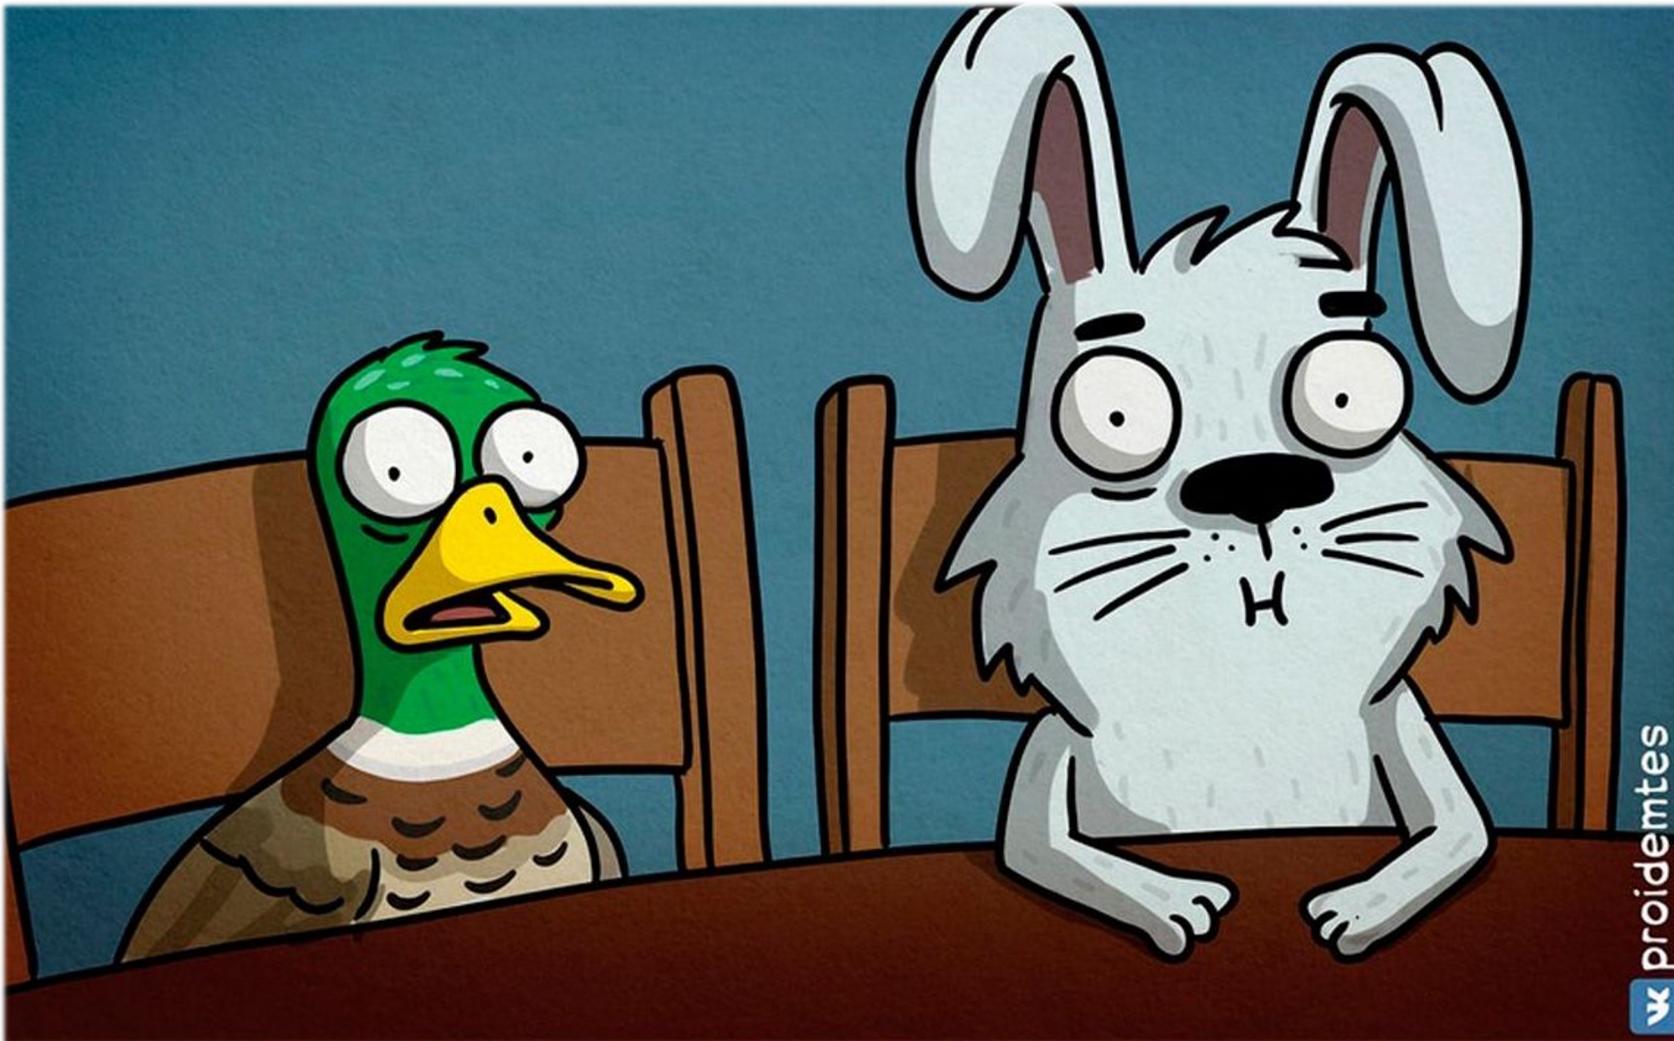
# Round robin балансировка



# Пространство решений

- уменьшить время прогрева
  - вертикальное масштабирование
  - горизонтальное масштабирование
  - оптимизация производительности
- предварительный прогрев
  - нагрузочными тестами
  - реальным трафиком
- использовать балансировку с липкими сессиями?!?!





# EWMA балансировка

**EWMA** - *Exponentially Weighted Moving Average*.

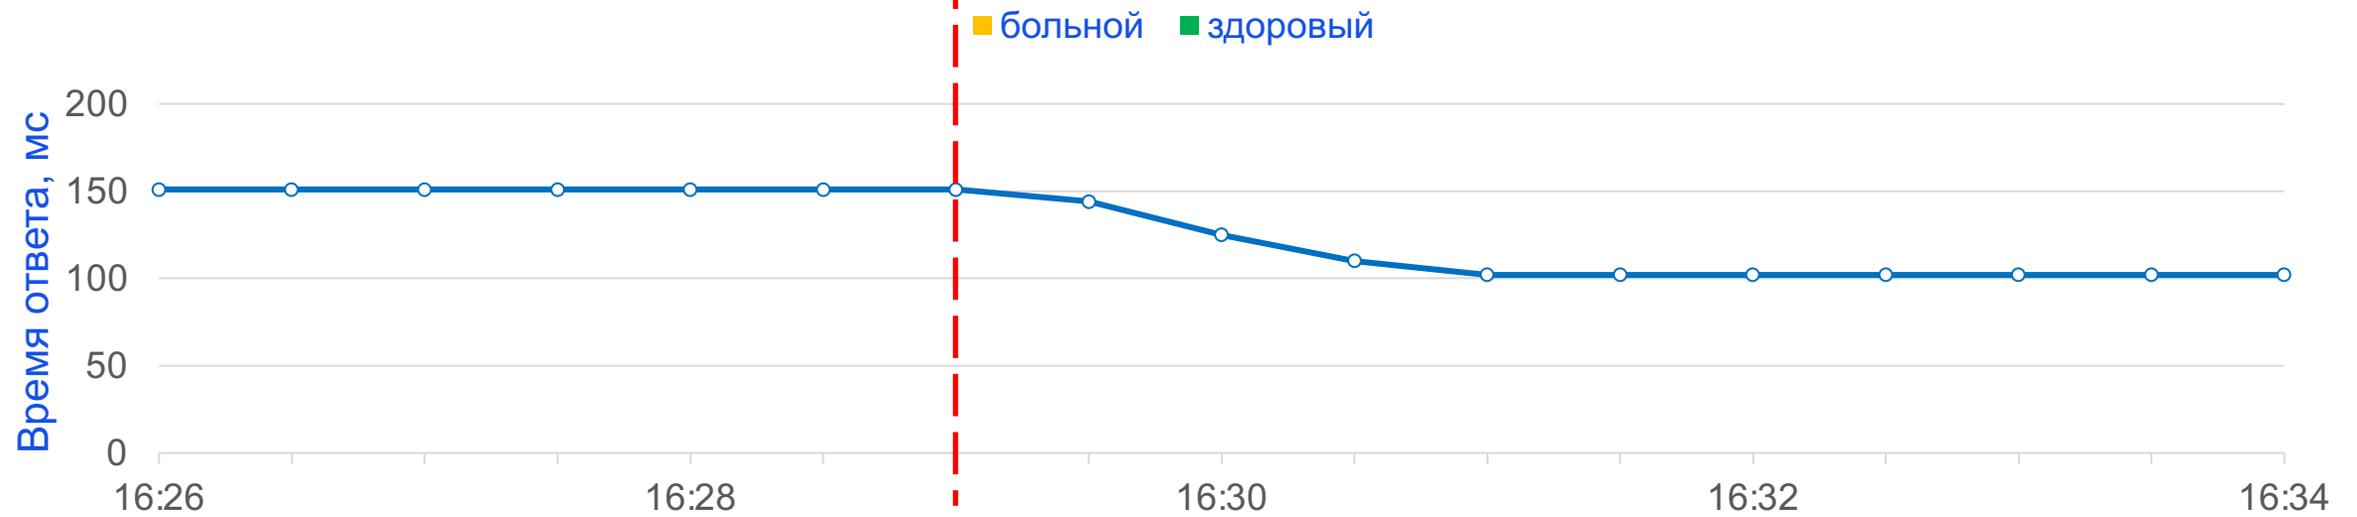
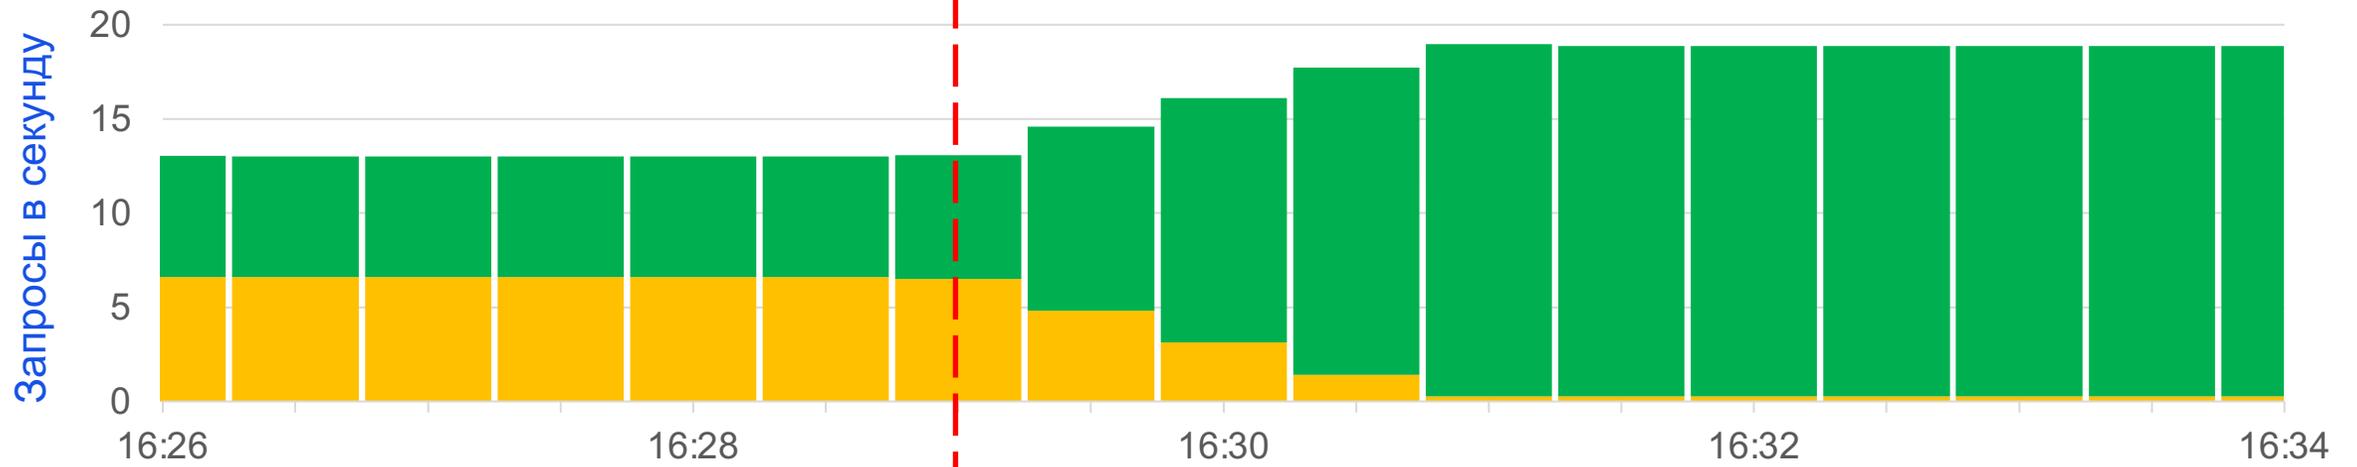
Запросы распределяются таким образом, чтобы выравнять **время ответа** на всех сервисах. Предпочтение отдаётся тому сервису, который быстрее отвечает.

**Время ответа** вычисляется как экспоненциально взвешенное скользящее среднее.

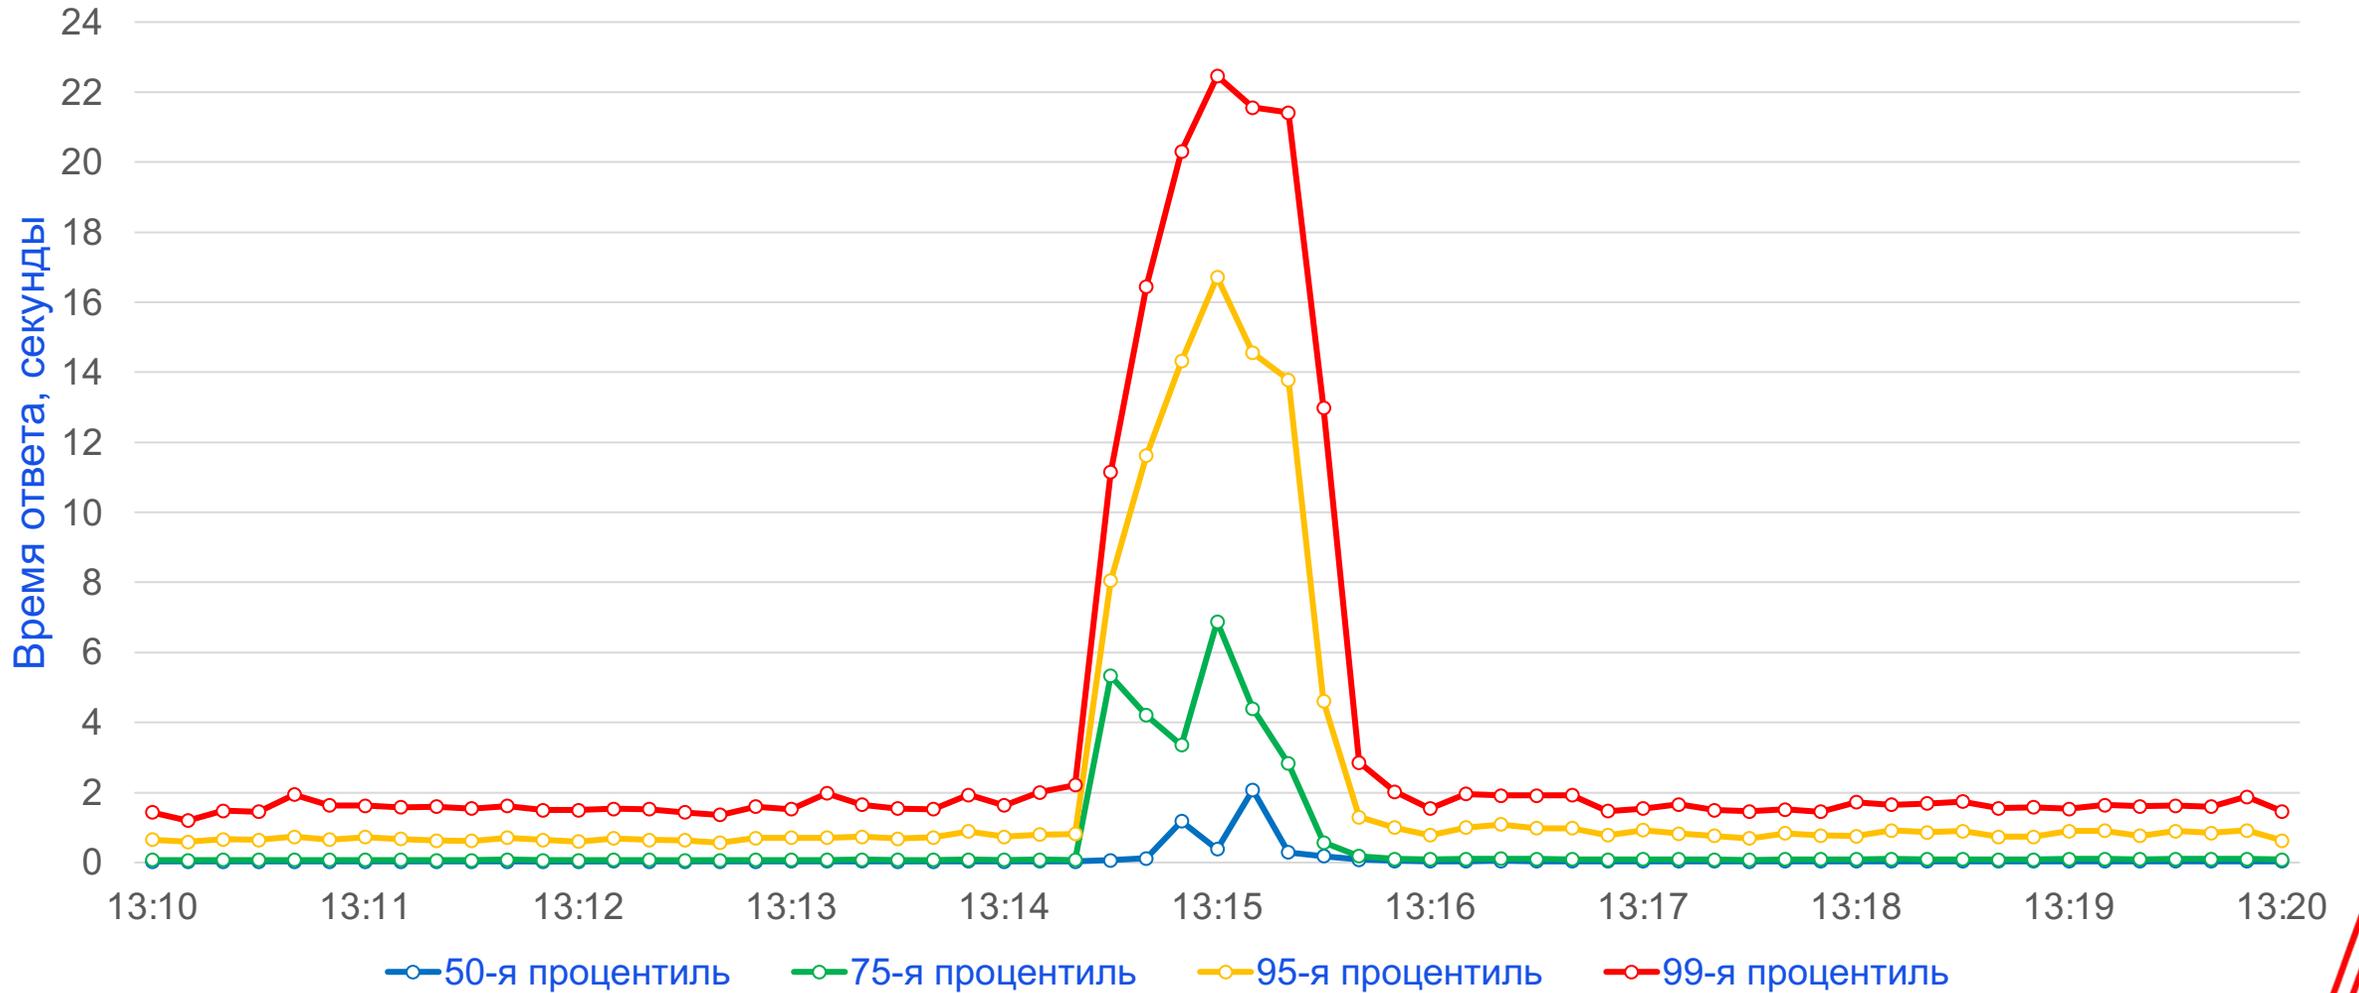
В production впервые начали использоваться в 2014г.

- Finagle - Twitter
- Linkerd - Service Mesh для Kubernetes

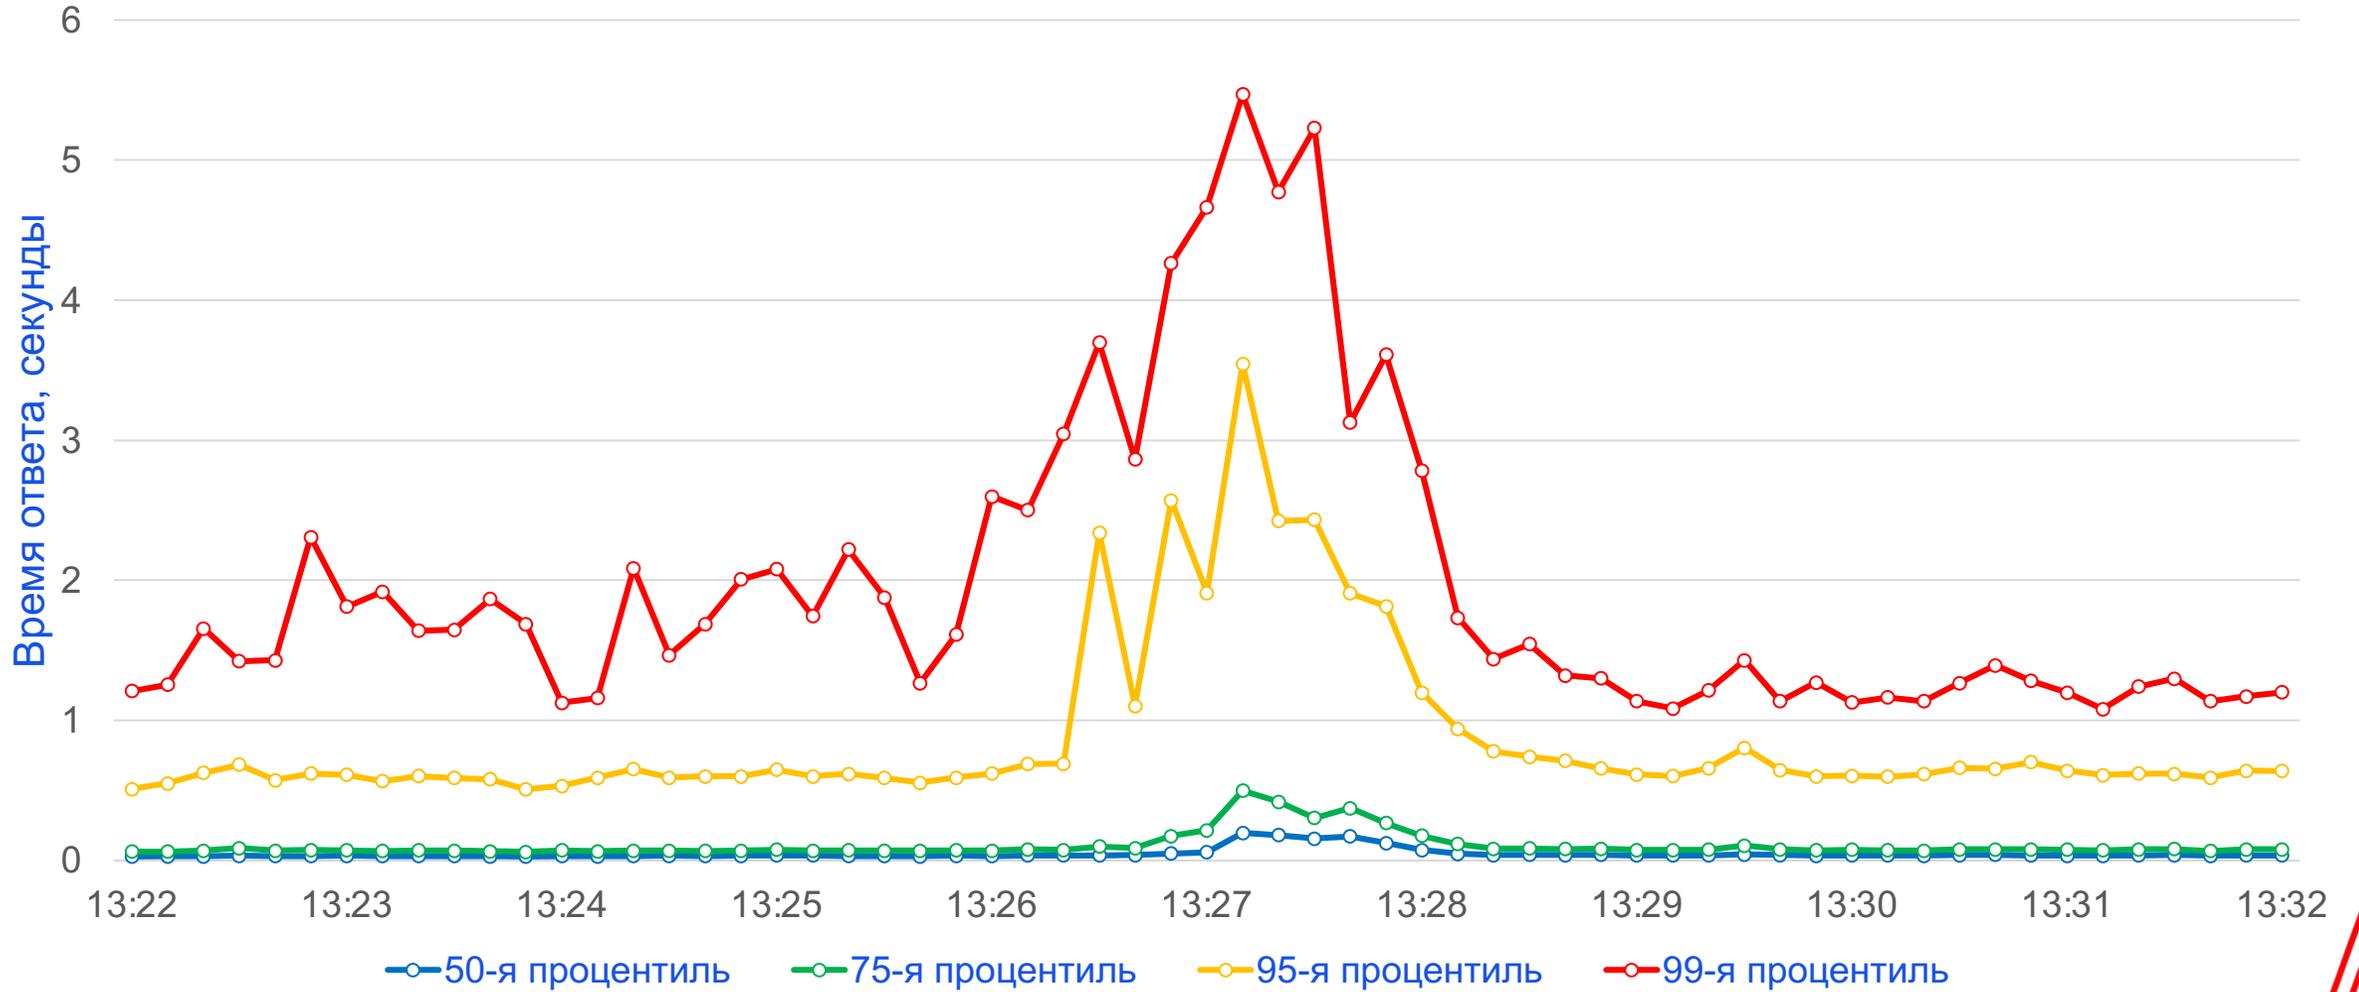
# Синтетический тест



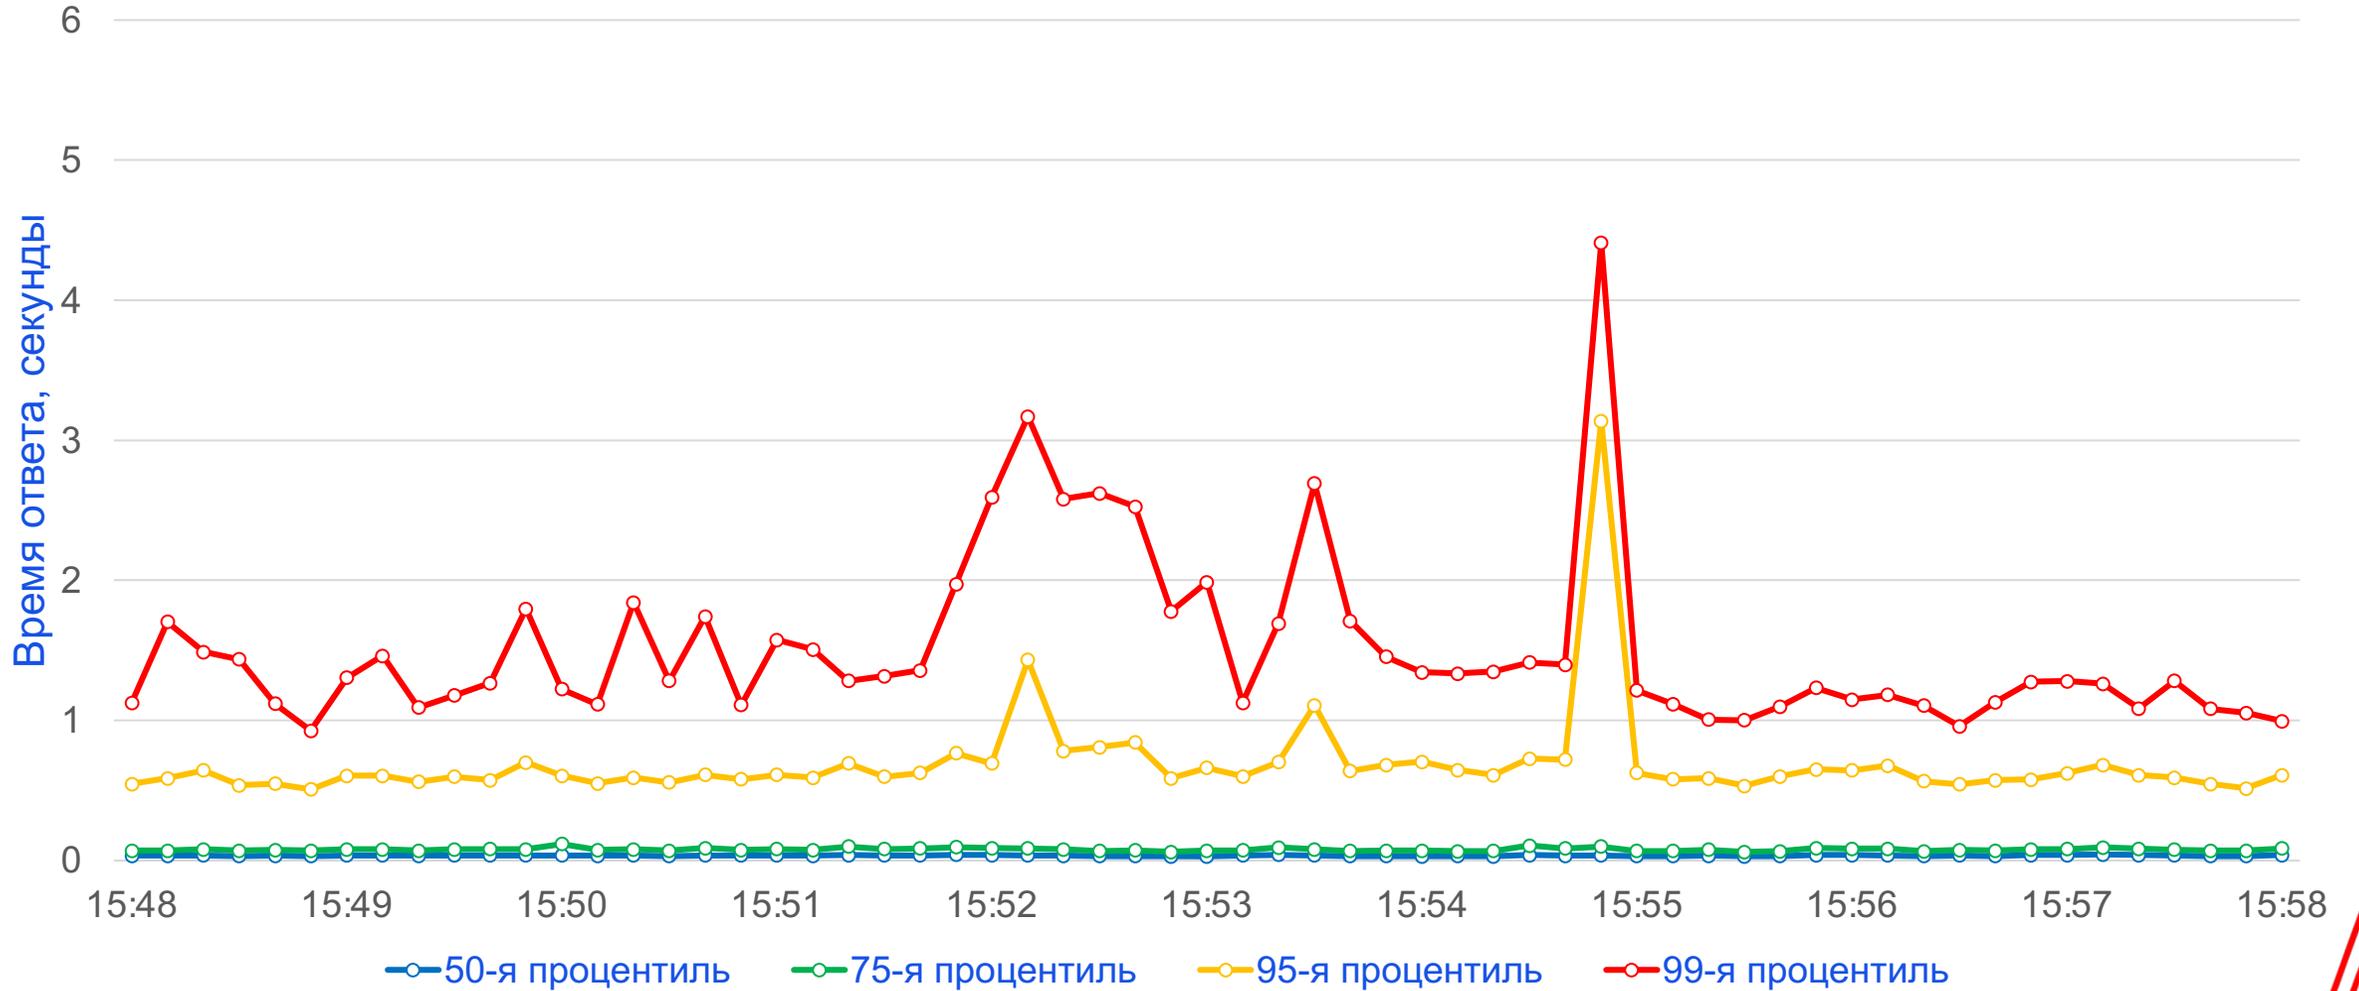
# Деплой + Round Robin



# Деплой + EWMA



# Деплой + EWMA + прогрев







# Технические детали

```
apiVersion: apps/v1
  kind: Deployment
spec:
  strategy:
    type: RollingUpdate
    rollingUpdate:
      maxUnavailable: 0
      maxSurge: 1
  minReadySeconds: 60
  readinessProbe:
    ...
```

# Технические детали

```
apiVersion: networking.k8s.io/v1
kind: Ingress
metadata:
  annotations:
    nginx.ingress.kubernetes.io/load-balance: ewma
```

**Вопросы?**



**Спасибо!**

