



Ай-ТИ Фреш

ТЕХНИЧЕСКИЙ РАЗБОР

Self-hosted runners GitHub Actions: CI/CD на своём железе

Как мы строим парк раннеров: агенты под systemd, метки, ARC-автоскейлинг и изоляция контура

Июль 2026

itfresh.ru · ИТ-аутсорсинг для юридических лиц

Суть проблемы

Команда разработки упирается в лимиты и очереди облачных раннеров GitHub Actions: минуты тарифа сгорают, сборки ждут агентов десятками минут, а CI не достаёт до внутренних ресурсов — registry, тестовых БД, стендов за VPN. Мы переносим сборки на собственные раннеры: убираем плату за минуты, даём CI доступ во внутренний контур и контролируем скорость железом.

Почему это важно бизнесу

- Плата за минуты растёт с командой: Linux \$0.008/мин, Windows x2, macOS x10 — при активном CI это сотни долларов в месяц
- Очередь на раннеры — это простой разработчиков: PR, собирающийся 20 минут вместо 5, тормозит каждый релиз
- Облачный раннер не попадает во внутренний контур: закрытый registry, тестовые базы и стенды за VPN ему недоступны
- Небрежно подключённый self-hosted раннер — исполнение чужого кода внутри сети компании
- Свой раннер снимает лимит длительности job — долгие интеграционные прогоны перестают падать по таймауту



Ключевые параметры реализации

2.329.0+

минимальная версия агента для регистрации; дальше — обновление в 30 дней с релиза, держим в мо...

по докам actions/runner

0.14.0

ARC: чарт gha-runner-scale-set — автоскейлинг эфемерных подов-раннеров в Kubernetes, с 0.14 —...

по докам ARC

443 исх.

только исходящий HTTPS к github.com, api.github.com и *.actions.githubusercontent.com, входящи...

по докам GitHub Actions

1 job

один агент = одна job; параллелизм — N экземпляров, 250-500 МБ RAM на каждый

наш стандарт

60 мин

срок жизни registration-токена — регистрацию автоматизируем через REST API и JIT-конфиг

по докам GitHub Actions

2/20

minRunners/maxRunners — стартовый профиль: два тёплых раннера против холодного старта

наш стандарт



Базовый парк: агенты под systemd на выделенном хосте

Что настраиваем

Linux-хост (Ubuntu 24.04 LTS) в серверной клиента; раннеры уровня организации, маршрутизация job метками

Как мы это делаем

- 1 Отдельный пользователь без sudo: `useradd github-runner`; агент из tarball `actions/runner`, регистрация `./config.sh --unattended` на URL организации
- 2 Метки под роли хостов: `self-hosted,linux,x64,docker,high-cpu` — `runs-on` в workflow сам выбирает раннер, lint уводим на слабый хост меткой `lightweight`
- 3 Служба через `svc.sh install`: юнит `actions.runner.<org>.<имя>`, автозапуск после ребута, логи в `_diag/`, статус юнита заводим в Zabbix
- 4 На фаерволе — только исходящий 443 к `github.com`, `api.github.com` и `*.actions.githubusercontent.com`; входящих правил и белого IP не требуется
- 5 Очистку `_work/` и `docker system prune --filter until=72h` вешаем в cron; порог свободного места 15% — триггер в мониторинге

РЕЗУЛЬТАТ

Плата за минуты уходит, сборки получают локальный кэш зависимостей и внутренние registry напрямую; отказ раннера виден в мониторинге раньше, чем разработчики упрутся в очередь.

КЛЮЧЕВОЙ НЮАНС

Registration-токен живёт 60 минут — в Ansible-роль закладываем получение токена через REST API непосредственно перед `config.sh`, а не хранение его в переменных.



Автоскейлинг: ARC и runner scale sets в Kubernetes

Что настраиваем

Kubernetes-кластер клиента (k3s/managed); эфемерные поды-раннеры на пиковые 10-20 параллельных job

Как мы это делаем

- 1 Ставим helm-чарт gha-runner-scale-set-controller в namespace arc-systems, затем gha-runner-scale-set на каждый профиль раннеров
- 2 Аутентификация через GitHub App (app ID + private key в secret), а не PAT — токен переживает смену сотрудников и ротацию
- 3 githubConfigUrl на организацию, minRunners=2 / maxRunners=20; имя scale set становится меткой для runs-on
- 4 Сборка образов — containerMode: kubernetes или dind в values; docker.sock хоста в поды не пробрасываем
- 5 Каждый job получает свежий эфемерный под, после завершения под удаляется — состояние между сборками не протекает

РЕЗУЛЬТАТ

Пиковые 15 параллельных PR разъезжаются по подам за секунды, ночью кластер держит только два тёплых раннера; узлы не заняты простаивающими агентами, стоимость масштабируется вместе с нагрузкой.

КЛЮЧЕВОЙ НЮАНС

Multilabel для scale sets появился только в ARC 0.14 — на старых версиях runs-on принимает лишь имя scale set, и привычные наборы меток ломаются при миграции со статичных раннеров.



Контур безопасности раннеров

Что настраиваем

Все self-hosted раннеры клиента: сеть, права токенов, политика репозиториев

Как мы это делаем

- 1 Self-hosted никогда не подключаем к публичным репозиториям; для приватных включаем Require approval for first-time contributors
- 2 В workflow задаём permissions: contents: read по умолчанию; write-права GITHUB_TOKEN выдаём точно на уровне job
- 3 Раннеры выносим в отдельный VLAN: доступ только к нужным registry и стендам, продовый сегмент закрыт ACL
- 4 Разовые и чувствительные задачи — эфемерные раннеры: ./config.sh --ephemeral, агент снимается с учёта после одной job
- 5 Runner groups (план Team/Enterprise) ограничивают, какие репозитории видят какие группы раннеров

РЕЗУЛЬТАТ

Компрометация workflow не даёт закрепиться: эфемерный раннер умирает вместе с job, сеть не пускает дальше своего сегмента, а токен без write не может подменить код или релизы.

КЛЮЧЕВОЙ НЮАНС

Раннер исполняет код любого, у кого есть write в репозиторий, — считаем его недоверенным узлом сети и проектируем сегментацию до подключения, а не после первого инцидента.



Подводные камни

✗ **docker.sock внутри контейнера раннера**

Проброс /var/run/docker.sock равен root на хосте — вместо него DinD с отдельным daemon, rootless Docker или containerMode: kubernetes в ARC

✗ **Раннер на публичном репозитории**

PR из форка исполнит произвольный код на вашем железе; self-hosted оставляем только приватным репо плюс approval для новых контрибьюторов

✗ **Протухший registration-токен**

Токен живёт 60 минут — скрипты деплоя падают; берём его REST-запросом registration-token прямо перед config.sh или используем JIT-конфиг

✗ **Очередь при живом раннере**

Один агент обслуживает одну job; для параллелизма ставим N экземпляров в отдельных каталогах с уникальными именами

✗ **Автообновление за прокси**

Агент старше минимума 2.329.0 не регистрируется, а за прокси автообновление молча ломается — ставим --disableupdate и обновляем сами не реже чем ра...

✗ **PAT в values Helm-чарта**

Личный токен умирает вместе с сотрудником и светится в values; для ARC регистрируем GitHub App с правами на self-hosted runners организации

✗ **Диск, съеденный _work и образами**

Каждый checkout и docker build копят гигабайты; cron-очистка _work/, docker system prune по расписанию и алерт на 15% свободного места

✗ **Секреты в окружении хоста**

Переменные хоста читает любой job; секреты держим только в Settings → Secrets и передаём через контекст secrets, а не через профиль пользователя



Как правильно

МИНИМУМ

- Раннер от отдельного пользователя без sudo, служба через svc.sh, логи в _diag/
- Только приватные репозитории + approval для первых контрибьюторов
- Исходящий 443 к github.com, api.github.com и *.actions.githubusercontent.com, входящ...

НОРМАЛЬНО

- Раннеры уровня организации, маршрутизация метками по ролям хостов
- Мониторинг: юнит службы, диск, версия агента не ниже минимальной
- Cron-очистка _work/ и docker prune, порог диска 15% в алертинге
- Секреты только в GitHub Secrets, permissions: contents: read по умолчанию

ХОРОШО

- ARC в Kubernetes: эфемерные поды, minRunners/maxRunners под профиль нагрузки
- Аутентификация через GitHub App вместо PAT, ротация ключей
- Отдельный VLAN для раннеров, runner groups по чувствительности репо
- Эфемерные раннеры для всего: одна job — один чистый агент



Чек-лист самопроверки

☐ Подключены ли self-hosted раннеры только к приватным репозиториям?

☐ Работает ли агент от отдельного пользователя без sudo и без docker.sock хоста?

☐ Версия агента не ниже минимальной (2.329.0) и обновляется не реже чем раз в 30 дней?

☐ Есть ли алерт на упавшую службу раннера и на заполнение диска рабочего каталога?

☐ Ограничены ли права GITHUB_TOKEN до contents: read там, где запись не нужна?

☐ Вынесены ли раннеры в отдельный сетевой сегмент без доступа к продовому контуру?

☐ Автоматизирована ли регистрация раннеров (REST API/JIT) вместо ручной вставки токена?

☐ Хватает ли параллелизма: число агентов соответствует пиковым одновременным job?

☐ Настроен ли автоскейлинг (ARC) для пиков вместо закупки простаивающего железа?

Если хотя бы на два вопроса ответ «нет» или «не знаю» — тема требует внимания.



Как поможет ITFresh

ITFresh — ИТ-аутсорсинг для юридических лиц до 50 рабочих мест в Москве и области. 15+ лет практики, собственная инфраструктура в дата-центре МТС (8 серверов Dell Xeon Platinum).

- Разворачиваем парк раннеров под ключ: физика или Kubernetes, метки, runner groups, мониторинг
- Мигрируем workflow с облачных минут на self-hosted без остановки разработки
- Ставим ARC с автоскейлингом и GitHub App-аутентификацией в ваш кластер
- Строим контур безопасности: сегментация сети, эфемерные раннеры, аудит прав токенов
- Подключаем раннеры к внутренним registry (Harbor/GitLab) и кэшу зависимостей

15+

лет в ИТ-поддержке

50

рабочих мест — наш профиль

МТС

дата-центр, Москва



КОНТАКТЫ

Обсудить вашу задачу

Сайт **itfresh.ru**

Телефон **+7 903 729-62-41**

Telegram **@ITfresh_Boss**

Бесплатно посмотрим вашу инфраструктуру по этому чек-листу и скажем, где тонко — без обязательств.



itfresh.ru



Техническая база

- 01** Hosting your own runners — Self-hosted runners (docs.github.com — 2026)
- 02** Deploying runner scale sets with Actions Runner Controller (ARC 0.14.0) (docs.github.com — 2026)
- 03** Security hardening for GitHub Actions (docs.github.com — 2026)
- 04** actions/runner — Releases, минимальная версия агента 2.329.0 (github.com — 2026)
- 05** REST API: Self-hosted runners (registration-token, JIT) (docs.github.com — 2026)
- 06** Шаблон ITfresh: Ansible-роль gha-runner (systemd) (itfresh.ru — 2026)

Основано на официальной документации продуктов и нашей практике внедрения.

