

ПРОМТ

Ты монтируешь видео. В текущей папке лежит сырая запись говорящей головы (один спикер, одна камера, много неудачных дублей и пауз) и, возможно, музыкальный трек. Найди их сам: видеофайл — самый большой `.mp4/.mov/.mkv`, музыка — `.mp3/.wav/.m4a`. Если файлов несколько и непонятно, какой брать — спроси один раз и дальше не переспрашивай.

Сделай из этого готовый ролик и проект для правок.

Настройки

```
...
ЯЗЫК РЕЧИ:   ru      # код для whisper: ru, en, es, de...
СТИЛЬ:       светлый минимал
АКЦЕНТ:      #c8623c  # один акцентный цвет на всю графику
ПЛОТНОСТЬ:   максимальная # максимальная | естественная
СУБТИТРЫ:    точно    # нигде | точно | везде
СЛОВА-ПАРАЗИТЫ: оставить # оставить | убрать
РАЗРЕШЕНИЕ:  как в исходнике
МУЗЫКА:      разнос 15 дБ под голосом
...
```

Шаг 0. Окружение

Проверь одной командой и доставь недостающее:

```
```bash
npx --yes hyperframes@latest doctor
```
```

Она разом показывает Node, ffmpeg, ffprobe, whisper-cpp, память и диск.

Чего может не хватать:

```
```bash
ffmpeg (macOS / Debian-Ubuntu)
brew install ffmpeg || sudo apt install -y ffmpeg

Node 22+ — нужен для HyperFrames
brew install node || sudo apt install -y nodejs npm

whisper.cpp
brew install whisper-cpp # даёт бинарь whisper-cli

модель распознавания — формула её НЕ тянет, ~1.6 ГБ
mkdir -p .tmp/models && curl -L --progress-bar \
 -o .tmp/models/ggml-large-v3-turbo.bin \
 https://huggingface.co/ggerganov/whisper.cpp/resolve/main/ggml-large-v3-turbo.bin

проект HyperFrames
npx --yes hyperframes@latest init project --example blank --non-interactive --skip-transcribe
npx --yes hyperframes@latest skills update talking-head-recut embedded-captions
```
```

Windows: ffmpeg и Node ставятся через `winget`, whisper.cpp — готовым релизом с GitHub `ggml-org/whisper.cpp`; остальное работает как есть.

Разложи работу так:

```
tools/    скрипты (пишешь на шаге 1)
project/  HyperFrames-проект
.tmp/     промежуточные файлы, одноразовые
out/      то, что отдаёшь
---
```

Скрипты пиши как отдельные файлы в `tools/`, а не инлайн в командах: их придётся запускать много раз с разными параметрами.

Шаг 1. Разбор материала

```
```bash
ffmpeg -i ИСХОДНИК -vn -ac 1 -ar 16000 -c:a pcm_s16le .tmp/audio16k.wav
M=.tmp/models/ggml-large-v3-turbo.bin

читаемая расшифровка — чтобы понять содержание
whisper-cli -m $M -f .tmp/audio16k.wav -l ЯЗЫК -t 8 -ojf -osrt -of .tmp/transcript

словные тайминги — для синхрона графики
whisper-cli -m $M -f .tmp/audio16k.wav -l ЯЗЫК -t 8 \
-dtw large.v3.turbo -ml 1 -sow -oj -of .tmp/words
```
```

Два обязательных знания про эти тайминги:

- **Без `-dtw` они мусорные** (`-dtw: -1`), слова разъезжаются на секунды.
- **При `-ml 1` конец слова = начало следующего.** Сегменты идут сплошняком. Осмысленны только **стартовые** тайминги.

Дальше построй **оггибающую громкости**: RMS по окнам 10 мс, в dBFS, в JSON. Она будет основой всех решений о резе.

Точки реза берутся из звука, а не из ASR. Тайминги whisper плывут на $\pm 100\text{--}200$ мс; уровни — измеренный факт. Whisper отвечает «что сказано», оггибающая — «где именно».

Шаг 2. Отбор дублей → ГЕЙТ

Прочитай расшифровку и выбери **лучший дубль** каждой смысловой фразы. Это твоя работа, а не скрипта. Признаки:

- спикер сам себя отменяет вслух («не, не пойдёт», «нет», «стоп») — в мусор;
- сам себя одобряет («вот это хорошо», «этот вариант») — бери **предыдущий** дубль;
- слитная целая фраза почти всегда лучше рваной, даже если в рваной формулировка точнее;
- если все дубли рваные — бери самый полный и прикрой стыки графикой (шаг 4).

Запиши решения в `edl\_spans.json`: по интервалу на фразу, с текстом,

и обязательно ****с пометкой, что отвергнуто и почему**** — это читает человек.

```
'''json
{
  "source": "raw.mp4",
  "spans": [
    { "id": "S1", "in": 18.40, "out": 23.20,
      "text": "...",
      "note": "4-й дубль, после него автор говорит «хороший вариант»",
      "rejected": ["0.0-8.6 медленно", "9.2-12.4 обрыв"] }
  ]
}
'''
```

****Прежде чем зафиксировать интервал — проверь две вещи:****

1. Нет ли ****внутри**** него паузы длиннее секунды. Почти наверняка это шов между двумя заходами на одну фразу, и сжатие пауз склеит их в слышимый повтор.
2. Не начинается ли он речью, за которой идёт длинная пауза. Это хвост предыдущего дубля.

 ****СТОП. Покажи человеку `edl\_spans.json` и расшифровку. Дальше не иди, пока не подтвердит.**** Смысловые акценты вслепую не угадываются.

Шаг 3. Рез

Один проход ffmpeg: по сегменту `trim`/`atrim` + `setpts`/`asetpts`, затем `concat` ****фильстром****.

Не concat-демуksером и не сборкой из кусочков: фильтр даёт рез в точный кадр, а не в ближайший ключевой, и режет видео с аудио одним графом — рассинхрон невозможен. На каждом стыке фейд аудио 15 мс, иначе щёлкает.

Выход: `.tmp/cut.mp4`, H.264 CRF 16, разрешение и fps как в исходнике.

Проверка реза — обязательная

```
'''bash
ffmpeg -i .tmp/cut.mp4 -vn -ac 1 -ar 16000 -c:a pcm_s16le .tmp/cut16k.wav
whisper-cli -m $M -f .tmp/cut16k.wav -l ЯЗЫК -osrt -of .tmp/cut_check
'''
```

Расшифровка смонтированного должна читаться как связный сценарий. Но помни ловушку №1 ниже: ****эта проверка не видит повторов****. Дополнительно вырежи каждый интервал отдельно и расшифруй коротким фрагментом.

Отдельно измерь остаток тишины и покажи числом. Норма при ПЛОТНОСТЬ=максимальная — не больше ~150 мс в любом месте.

Шаг 4. Графика

Собирай ****весь ролик одним HyperFrames-проектом****, включая исходное видео как ``<video>``. Не гибрид из альфа-оверлеев с композитом в ffmpeg: рендер 2560×1440 идёт около 11 кадр/с, полторы-две минуты на 35-секундный ролик — гибрид не

нужен и хуже правится.

Словные тайминги сними ****заново, со смонтированной дорожки**** — иначе всё разъедется.

Тайминги не вбивай руками

Заведи `cues.json`, где каждая метка привязана к произнесённому слову, и генератор, который подставляет числа в композицию — и в блок констант, и в `data-start`/`data-duration` каждого клипа:

```
```json
{ "cues": {
 "chk1": { "word": "склейки," },
 "hit2": { "word": "Claude", "n": 2 },
 "mgln": { "word": "добавляет", "offset": -0.10 } },
 "clips": {
 "checks": { "from": "chk1", "pre": 0.35, "to": "chkOut", "post": 0.50 } } }
...
```
```

После любой перерезки — один запуск генератора, и вся графика едет за речью. Иначе после каждой правки монтажа руками переставлять три десятка чисел, и что-нибудь обязательно разъедется.

Сопоставление слов делай ****без краевой пунктуации и без учёта регистра****:
whisper между прогонами пишет то «эти», то «эти.», то «Let's», то «let's».

Правила сцен

1. ****Самодемонстрация.**** Спикер говорит «добавляет анимацию» — ровно там играет анимация. Говорит «делает субтитры» — ровно там субтитры. Сильнейший приём в таком ролике.
2. ****Графика прикрывает джамп-каты.**** Где речь рваная и сжатие пауз оставляет заметные склейки — ставь слайд-сцену: спикер уезжает вбок и уменьшается (`scale: 0.42`, сдвиг вправо), с другой стороны выезжает панель. Стыки перестают читаться.
3. ****Сторона по свободному месту.**** Смотри, где в кадре пусто, туда и ставь.
4. ****Не прижимай к низу.**** Нижние чипы — примерно на 20% высоты кадра от низа.
5. ****Ключевую фразу — на полный экран.**** Один-два раза за ролик: цветное поле шторкой, рисуется иконка, слова выходят снизу. Работает как удар.
6. ****Hard cut там, где молчание.**** Если плавный переход приходится на паузу — заменяй резом по кадру (`tl.set` вместо `tl.to`). Плавность по тишине читается вяло.
7. ****Каждый элемент выходит на своём слове****, а не пачкой.

Субтитры

При СУБТИТРЫ=точно ставь их ****только там, где они по смыслу****: если спикер сам о них говорит — там; иначе на одной ключевой фразе как акцент. Караоке на весь ролик — это СУБТИТРЫ=везде, и просить об этом должен человек.

Стиль

«Светлый минимал» = тёплые белые панели поверх кадра, тонкая типографика, много воздуха, мягкие тени, один акцентный цвет:

```
```css
--panel:#fcfbf8; --ink:#14161a; --line:rgba(20,22,26,.10);
```
```

```
--accent:АКЦЕНТ; --shadow:0 28px 90px rgba(0,0,0,.34);  
---
```

Системный шрифт (`-apple-system, "SF Pro Display", system-ui`) — у него хорошая кириллица и он всегда на месте. Скругления 28px. При кадре 2560 панель ≈1090px, отступ от края 150px.

Тексты на панелях придумывай по смыслу реплики — и ****покажи их человеку до рендера****, формулировки почти всегда правят.

Шаг 5. Звук

хайпасс 80 Гц → двухпроходный loudnorm → -14 LUFS, истинный пик -1 dBFS

Двухпроходный обязательно: однопроходный уплывает от цели. Лимитер по истинному пику — без него подъём до -14 клипует.

Деноиз ****не делай****, если пол шума ниже -50 dBFS: на чистой записи он только добавляет артефактов. Сначала измерь.

Музыка

Уровень считай ****не процентом от громкости трека**** (это ни о чём не говорит), а разном с голосом:

- подложку нормализуй к абсолютной цели (-24 LUFS при голосе -14);
- приглуши сайдчейном по голосу: ratio 3, threshold 0.10, attack 20, release 380;
- целевой разнос ****15 дБ**** — музыка отчётливо слышна, голос не вязнет.
Громче — подложка -22 (13 дБ), тише — -26 (17 дБ).

Сайдчейн обязателен: паузы вырезаны, речь идёт сплошняком, и статичная подложка либо давит голос, либо не слышна.

****Режь трек по смыслу, а не с нуля.**** Построй профиль громкости трека, найди друп и посади его на финальную фразу: смещение = время друп минус время фразы. Тогда перед ударом трек истончается под концовку — так это делают руками.

Финальный микс приведи к -14 LUFS.

Шаг 6. Мастер

```
```bash  
npx hyperframes render project -o out/render.mp4 --quality high
звук подставляется в готовый рендер БЕЗ перекодирования видео:
ffmpeg -i out/render.mp4 -i tmp/audio_mixed.wav -map 0:v:0 -map 1:a:0 \\\n -c:v copy -c:a aac -b:a 256k -ar 48000 -shortest -movflags +faststart \\\n out/master.mp4
```
```

Второй прогон по видео только испортил бы картинку — она уже финальная.

Алгоритмы, которые надо реализовать точно

Здесь всё, что отличает хороший результат от посредственного.

Маска речи

...

```
env    = RMS по окнам 10 мс, dBFS
sdb[i] = max(env[i-3 .. i+3])    # скользящий максимум ±30 мс
loud[i] = sdb[i] >= -30 dBFS
речь[i] = loud[i] И длина непрерывного участка loud ≥ 110 мс
...
```

Скользящий максимум нужен дважды: он не даёт провалу внутри слова сойти за паузу и подтягивает короткие слова над порогом длительности.

Добор глухих окончаний

...

```
для каждого участка речи:
  k = конец участка
  пока в пределах 250 мс дальше есть хоп с sdb >= -30:
    расширить участок до него
  ...
```

Обязан жить **в маске**, а не в подрезке краёв интервала: резы бывают и внутренние, от сжатия пауз.

Границы интервала

...

```
вход = первая речь в интервале – 20 мс
выход = последняя речь в интервале + 30 мс
...
```

Сжатие пауз

...

```
пауза = участок без речи длиной ≥ 160 мс
из каждой оставить 50 мс (по 25 мс с каждой стороны, середину выбросить)
все точки резать по сетке кадров
...
```

⚠️ **Порог 160 мс не опускай ниже 150.** Тихий безударный слог короче этого неотличим от паузы, и слово обрубается: «пока вы спите» → «ка вы спите».

При ПЛОТНОСТЬ=естественная поставь `оставить 220 мс`, `порог 400 мс`.

Ловушки — не переоткрывать

Каждая стоила отдельной итерации.

1. Whisper схлопывает повторы. При разборе длинного файла два подряд захода на одну фразу выдаются одной строкой. Расшифровка выглядит чистой, а в звуке фраза звучит дважды. Обратная транскрибация целого файла этого **структурно**

не ловит.

→ Ищи в списке тишины паузы длиннее секунды внутри интервала — это шов между дублями. Проверяй фрагментами до 5 секунд с разбегом из тишины: на 10-секундном клипе повтор всё ещё схлопывается.

****2. Дыхание — не тишина.**** Вдох в близкий микрофон живёт на $-36...-42$ dBFS, на стыках доходит до -26 . Порогом тишины не берётся ни при каком значении: либо пропускает, либо спотыкается о собственный шум и рвёт проверку непрерывности.
→ Отсюда критерий «речь — это то, что держится» выше.

****3. Тот же критерий рубит глухие окончания.**** Финальный глухой слог длится 10–20 мс и бракуется наравне с дыханием.
→ Отсюда добор в маске.

****4. Посторонний шум громче порога проходит за речь.**** Шорох ткани, когда спикер поправляет одежду, держится выше -30 dBFS почти секунду. Все проверки по звуку считают это речью, расшифровка там пустая.
→ Ловится только глазами или по пустому промежутку в расшифровке между репликами. Смотри кадры на стыках.

****5. Хвост чужого дубля в начале интервала.**** Подрезка по речи не спасает — хвост тоже речь. Проверяй структуру интервала до фиксации.

****6. `sidechaincompress` отдаёт примерно на секунду меньше, чем получил.****
Хвост пропадает молча — так исчезает финальный удар музыки.
→ Дополняй оба входа тишиной (`apad`), подрезай выход (`atrim`) и ****сверяй длительность результата****.

****7. Слова-якоря нестабильны**** — пунктуация и регистр гуляют между прогонами.
→ Сопоставление без краевой пунктуации и без учёта регистра.

****8. Грабли HyperFrames.****

| Симптом | Решение |

|---|---|

| `video\_missing\_muted` | `data-has-audio="true"` на ``<video>`` — звук несёт само видео |

| `gsap\_exit\_missing\_hard\_kill` | внутренняя обёртка `\*-in` + `tl.set(sel,{autoAlpha:0})` в конце твина; твины

****никогда**** не вешать на сам `.clip` |

| Конфликт CSS-трансформа и твина | начальное состояние задавать в `gsap.fromTo`, а не в CSS |

| Столбики диаграммы не видны | `flex:1` растит по ширине — нужен `height:100%` |

| Контраст падает там, где статика в порядке | аудит смотрит и промежуточные кадры твина; не гонять текст через серый на цветном |

| Панель полупустая после смены содержимого | скрытые через `autoAlpha` блоки держат высоту — анимировать `height:0` при `overflow:hidden` |

| `--resolution 1080p` не уменьшает 2560×1440 | пресет только повышает DPR; уменьшать отдельным проходом ffmpeg |

Чек-лист приёмки

Прогони сам, до того как отдать:

1. `npx hyperframes check` — ноль находок по всем пяти аудитам.
2. `npx hyperframes snapshot --at <середины сцен>` и ****посмотреть глазами****:
не порезан ли текст, нормальные ли переносы, не превратились ли буквы в квадраты, сбалансирован ли кадр.
3. Обратная транскрибация мастера — читается как связный сценарий, без

- повторов и обрубленных слов.
4. Остаток тишины измерен и назван числом.
 5. `ffmpeg -af ebur128` — -14 LUFs, истинный пик не выше -1 dBFS.
 6. `ffprobe` — разрешение и fps как задумано, длительность сходится с суммой сегментов, `moov` перед `mdat`.

Порядок общения

- **Гейт после шага 2** — обязателен. Без утверждения отбора дублей не рендерь.
- После сборки отдай превью, дождись правок, и только потом мастер.
- Показывай **измеримое**: сколько тишины осталось, сколько секунд вышло, что сказал `check`. Не «стало лучше», а числа.
- Нашёл дефект, о котором не просили, — скажи и почини.

Что отдать

- `out/master.mp4` — мастер
- `project/` — композиция для правок
- `edl\_spans.json` и `cues.json` — решения о резе и привязка графики
- `EDIT.md` — раскадровка и где что крутить
- расшифровки исходника и финала