



解説動画作成ツールをScalaで作成している話 / Creating an explainer video maker in Scala

@windymelt at ScalaMatsuri (2023-04-15, 2023-04-16)

You can get this slide via...



- <https://www.3qe.us/2023/04-scalamatsuri-zmm-movie-generator> (my site)
 - Scan QR Code
- Subject to be changed.

上記のURLからこのスライドをダウンロードできます

About me

- Windymelt
 - www.3qe.us
 - @windymelt@plrm.capslock.dev
 - @windymelt (at almost everywhere in the world)
- Scala, at work and private
- Web engineer at <https://hatena.co.jp>
 - Mainly developing backend server
- Developing Hatena Bookmark (social bookmark service)
- We're hiring!!



株式会社はてなで働いています 採用強化中

About me (2)



- Currently interested in...
 - Scala (of course!)
 - Fediverse (Mastodon, Misskey, ActivityPub...)
 - Cloudflare Worker
 - ffmpeg
 - APEX Legends

Fediverseやffmpegなどに興味があります



<AD>

[AD] Hatena Bookmark

- Social Bookmark Service
- You can comment, share, discover bookmarks
- <https://b.hatena.ne.jp>

The screenshot shows the homepage of Hatena Bookmark. At the top, there's a search bar and navigation links for 'My Page', 'Bookmark', 'Read Later', 'Add', 'Tools', and 'Settings'. Below the header, the main content area displays several bookmark entries:

- ChatGPTの精度を上げる、あらゆる質問の最後に置く「命令」** - 1524 users. Description: クリエイターに出会ったり、もっとファンになったり、noteで創作をつづけたくなるようなイベントを開催する「noteイベント」。今回は「チャットAI使いこなし最前線」をテーマに、黎明期からチャットAIを活用している内容 CXOの深津貴之氏が登壇しました。こちらの記事では、ChatGPTユーザーの悩みを解決する...
Published by: テクノロジー on 2023/03/15 21:01
Tags: ChatGPT, AI, あとで読む, 人工知能, アイデア, 仕事, これはすごい, 技術, チャット, GPT
- ChatGPT4 本格RPG「チャット転生～死んだはずの幼馴染が異世界で勇者になっていた件」** - 330 users. Description: 書籍「ゲームの歴史」にツッコミ相次ぐ「内容が大事と異なる」との声...講談社は「確認中」
Published by: テクノロジー on 2023/03/16 00:56
Tags: note.com/fladdict
- 書籍「ゲームの歴史」にツッコミ相次ぐ「内容が大事と異なる」との声...講談社は「確認中」** - 125 users. Description: ゲームの歴史
Published by: テクノロジー on 2023/03/16 12:21
Tags: www.itmedia.co.jp
- セキュリティ研修で「w6lj38?pa7J」と「CanYouCelebrate?」ではど...** - 138 users. Description: ゲームの歴史
Published by: テクノロジー on 2023/03/15 18:39
Tags: together.com

はてなブックマークというサービスを展開しています

DISCLAIMER!



- Product introduced in this talk has no business with my employer
- That's my own hobby products

今回の話は勤務先とはぜんぜん関係ない趣味の話です



</AD>

Prerequisites – Explainer video



- Do you know *Explainer video* (解説動画) ?
- Popular videos genre in Japan
- type CTM = (
 Synthetic speech,
 Character,
 Video explaining something,
)

解説動画は合成音声とキャラクター、解説内容から成る

動画 静画 生放送 チャンネル プロマガ アツマール アプリ その他 ▾

ニコニコ動画

動画(542,900) マイリスト(6,634) 静画(5,187) 生放送(37,358)

解説

解説を含む動画が542,900件見つかりました

タグで検索

ゆっくり解説 VOICEROID解説 解説動画 解説・講座 SCP解説 解説 ゆっくり解説動画 結月ゆかり解説 解説実況 voicevox解説

▼人気が高い順 連続再生 ▶ 1 2 3 次へ

2023/03/15 17:00 投稿 **【登録者10万人記念】「銀の盾」、開封レビュー。**
今日はYouTubeから送られてきた「銀の盾」を開封します。○ご質問やリクエストなどはこちらへ: https://peing.net/ja/saltyo_zunda ○音声読み上げ: VOICEVOX <https://vo...>
怪しい日本語は? 塩ビ管と並べようおてて民歌書えよん 分解しよう 怪しい日本語は? 割と早い テ
再生 27,069 コメ 2,487 いいね! 2,536 マイ 66

2023/03/15 14:00 投稿 **【ふにんがす】【Among us】綾星あかり、英語禁止 #139【VOICEROID実況】**
本日3/15は、うぶ主の誕生日です。そしてその記念すべき今日で、2021年11月29日から続けていた毎日投稿を終了します。472日間も毎日投稿することができたのは見てください...
誕生日おめでとう 光線男だとレーマンになっちゃうのよ。あーDLのとこ見ない絶妙なガバ探しし
再生 22,170 コメ 983 いいね! 2,943 マイ 104

2023/03/15 17:00 投稿 **ブルガリア - 結月ゆかりのひとくち全世界解説【39/197ヶ国】**
ブルブル前:sm41907662(ラン)次:sm(ペラルーン)マイリスト:mylist/73789037シリーズのガイドは[こちら!sm41157779](#)()ガイドンス)使わせていただいてい...
投稿お疲れ様です。マケドニア人にブルガリア語とほぼ一緒に話してはいけないゾ やるじやん ここ
再生 10,615 コメ 768 いいね! 1,512 マイ 69

ニコニ広告

【ゆっくり紹介】SCP-5205【パラノーマル・アクティビティ】

提供:DlSa 広告 81,600pt

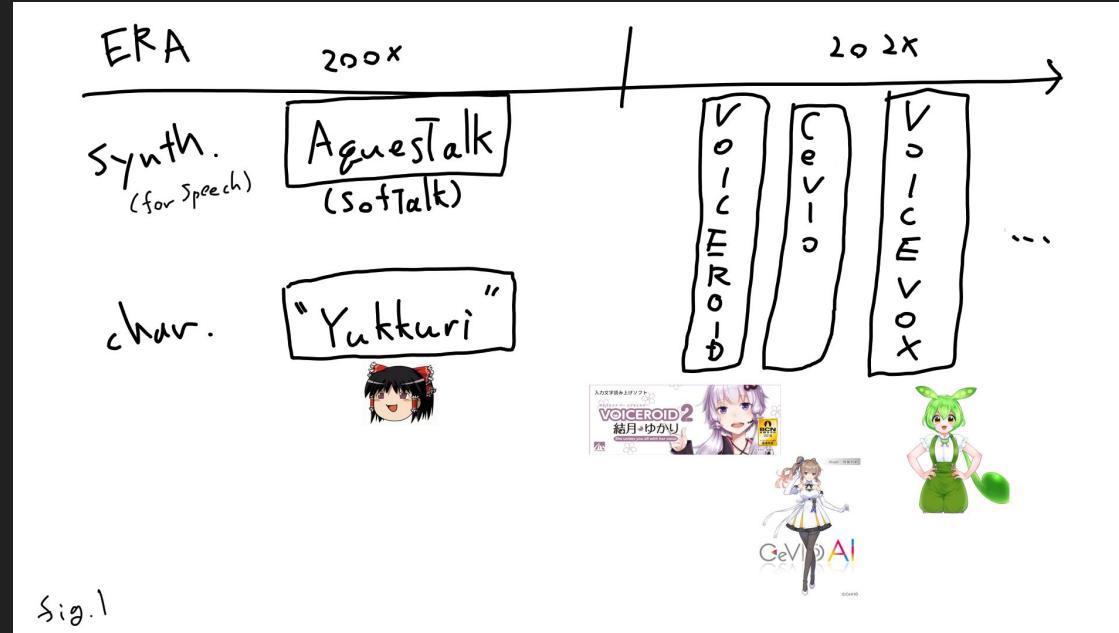
2023/03/15 18:00 投稿

関連チャンネル

活発な解説動画文化が日本に存在する



Synthetic Speech Technology (in ja_JP)



最近は合成技術がキャラクターとセットで提供されがち

What is talked in their videos



- Everything
 - Cooking recipe
 - History
 - Technology review
 - Gaming (RTA, etc.)
 - Politics, Economy, etc.
 - Just a talk
- Each Synthesize engine / Character have their guideline
 - e.g. "Cannot be used for political activity."

内容は様々だが、キャラクターにはガイドラインがある



Two problems

動画文化が抱えている2つの問題

Knowledge and Video editing skill is not equal



- Knowledge
 - Skill / Experience with specific domain
 - Have Ph.D
 - Talk skill
 - etc.
- Video editing
 - Video editor skill
 - Encoding skill
 - ffmpeg hell
 - Creating screen format
 - etc.



優れた知識があっても動画作成が上手とは限らない

Disadvantage for video



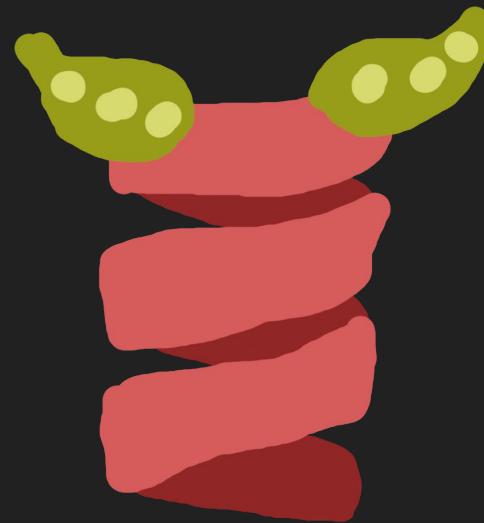
- Insufficient searchability
 - You can never search YouTube contents using its spoken words (now)
- Influencer gains more power
 - If you cannot search it, You have to rely on influencer
 - Influencer dominancy
- We have to watch all through a video to confirm whether we want it

検索しにくくインフルエンサーが力を持つ状況



So I made ZMM

<https://github.com/windymelt/zmm>



問題解決のためにZMMを作った

ZMM



- XML => MP4 CLI application
- Docker image available
- Stands for “Zunda movie maker”
 - came from a character name
 - respecting existing (but complex) movie maker
- Demo?
 - Caveat: VOICEVOX does speak only Japanese
 - <https://www.nicovideo.jp/watch/sm41810130>
 - <https://github.com/windymelt/zmm/blob/main/docs/sm41810130.xml>

原稿XMLからMP4を生成するアプリケーションです



Example input

```
<?xml version="1.0" encoding="utf-8" ?>
<content version="0.0">
  <meta>
    <voiceconfig id="metan" backend="voicevox">
      <voicevoxconfig id="2" />
    </voiceconfig>
    <voiceconfig id="zundamon" backend="voicevox">
      <voicevoxconfig id="3" />
    </voiceconfig>
    <characterconfig name="metan" voice-id="metan" serif-color="#E14D2A" tachie-url="../../assets/metan.png" />
    <characterconfig name="zundamon" voice-id="zundamon" serif-color="#379237" tachie-url="../../assets/zundamon.png" />
  </meta>
  <dialogue backgroundImage="../../assets/background.jpeg" bgm="assets/bgm.mp3">
    <say by="zundamon">こんにちはなのだ</say>
    <say by="metan">ずんだもん、こんにちは</say>
    <say by="zundamon">難しい操作は不要なのだ</say>
  </dialogue>
</content>
```

ZMM – Features



- Automatic subtitle and voice from XML
- Background image
- Code highlighting
- Mathjax support
- Modularized synthesis engine
 - Currently only VOICEVOX supported
- Who need ZMM?
 - Who have academic background
 - Who doesn't have video editing skills
- Aiming Plain and Easy

字幕生成やコードハイライト、数式表示などを搭載

Why XML?



- Scenario contains tree structure
 - e.g. Different character talks, but same background image and BGM
- XML is eXtensible Markup Language
 - Other tool can insert own tags
 - ZMM just ignores unsupported tags
- XML can insert code snippet
 - CDATA section is useful for code snippet

```
<code id="voice" lang="sh">
| <![CDATA[
$ java -jar zmm-0.2.0.2.jar show voicevox
| ]]>
</code>
```

XMLは動画原稿に適切なフォーマット



ZMM – Architecture

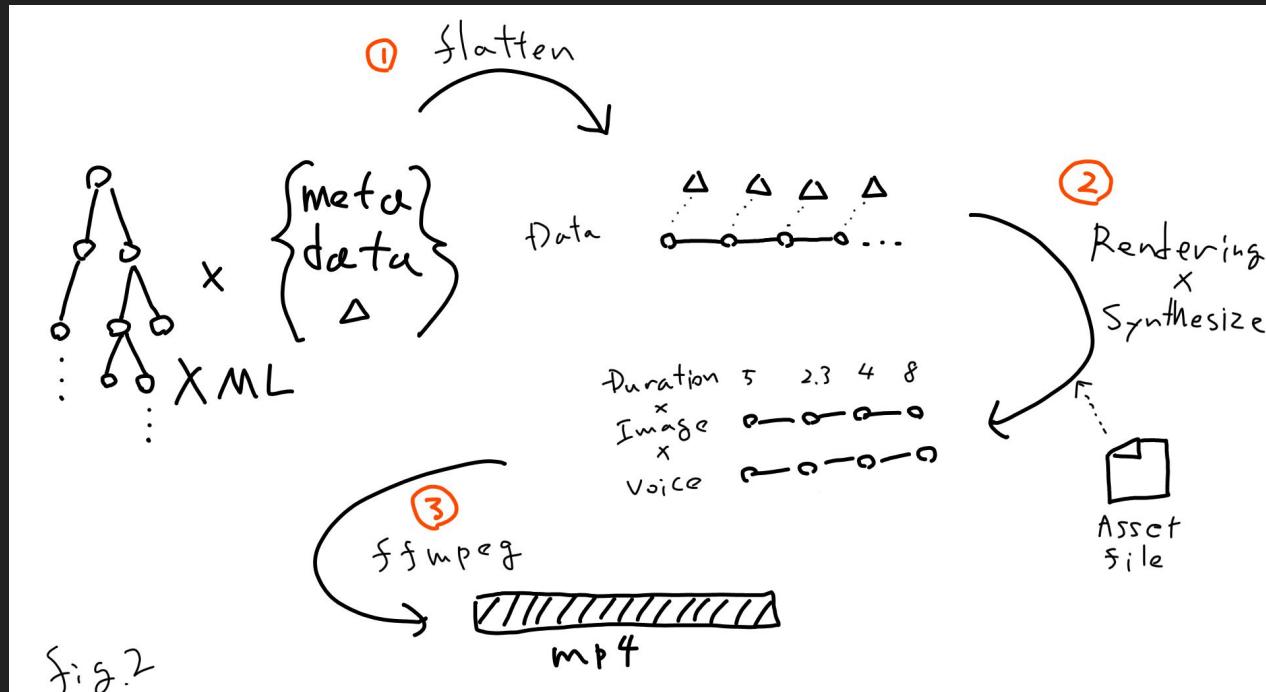
ZMMのアーキテクチャ



ZMM: XML \Rightarrow MP4

ZMMはXMLをMP4に変換するアプリケーション

ZMM – Architecture



全体像で見るとこんな感じ

Three Part of ZMM (Simplified)



- Flattener
 - XML => Seq[(Sentence, Context)]
 - *In ZMM, we call Metadata as Context*
- Materializer
 - Seq[(Sentence, Context)] => Seq[(Image, Wav)]
- Concatenator
 - Seq[Image, Wav] => MP4

ZMMの3要素: 平らにする・変換する・結合する

Three Part of ZMM (Much More Simplified)



- Flatten
- Map
- Combine

Scala風に言うとflatten, map, combine



“OK I love them”

Scalaが得意とする分野ですね



1. Flatten

まず平らにする所から見ていきましょう

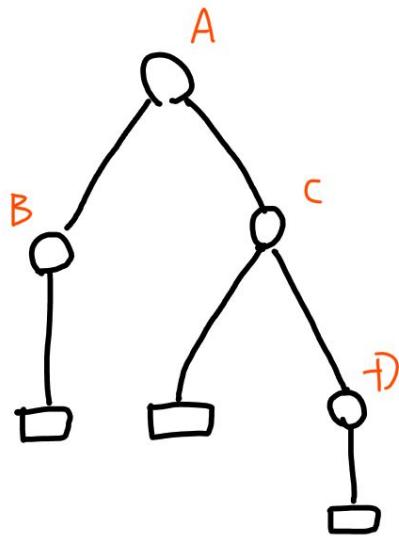


Context inside tree

```
<dialogue backgroundImage="A">
  <scene backgroundImage="B">
    <say by="char1">こんにちは</say>
  </scene>
  <scene backgroundImage="C">
    <say by="char1">こんにちは</say>
    <scene backgroundImage="D">
      <say by="char1">こんにちは</say>
    </scene>
  </scene>
</dialogue>
```

原稿XMLの各場所にはコンテキストがある
コンテキストは画像や速度などの設定のこと

m = background
Image



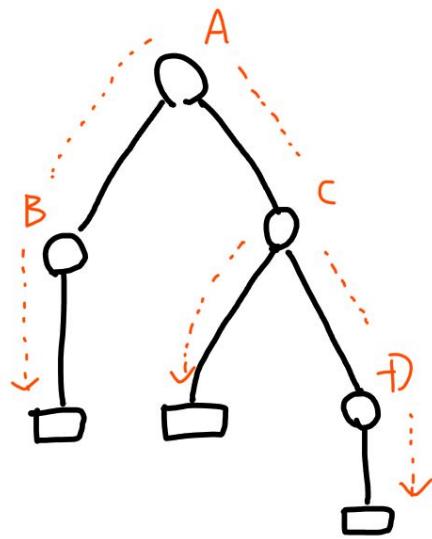
図にすると、背景情報がノードに乗っている感じ



Flatten it

これを平らにする

m = background
Image



平らにすることで、動画にする準備ができる

How XML should be flatten?



- Principle: Child context overrides parental context
- Complecation: context is not only `backgroundImage`
 - Actually context is a big case class →
 - Talking speed, character, BGM, etc.
- We have to merge two contexts safely
- Merged context is also a context
 - 😕 Merge...? Binary operation...?

```
final case class Context(  
    voiceConfigMap: Map[String, VoiceBackendConfig] = Map.empty,  
    characterConfigMap: Map[String, CharacterConfig] = Map.empty,  
    backgroundImageUrl: Option[String] = None,  
    spokenByCharacterId: Option[String] = None,  
    speed: Option[String] = Some("1.0"),  
    serifColor: Option[String] = None, // どう使うかはテンプレート依存  
    tachieUrl: Option[String] = None,  
    dict: Seq[(String, String, Int)] = Seq.empty,  
    additionalTemplateVariables: Map[String, String] = Map.empty,  
    bgm: Option[String] = None,  
    codes: Map[String, (String, Option[String])] = Map.empty, // id →  
    maths: Map[String, String] = Map.empty, // id → LaTeX string  
    sic: Option[String] = None, // 代替読みを設定できる(数式などで使う)  
    // TODO: BGM, fontColor, etc.  
) {
```

CSSのように、子のコンテキストが親の属性を上書きする
しかも、安全に行う必要がある



Context is a Monoid !!!

コンテキストはモノイドになることに注目

Monoid for beginners



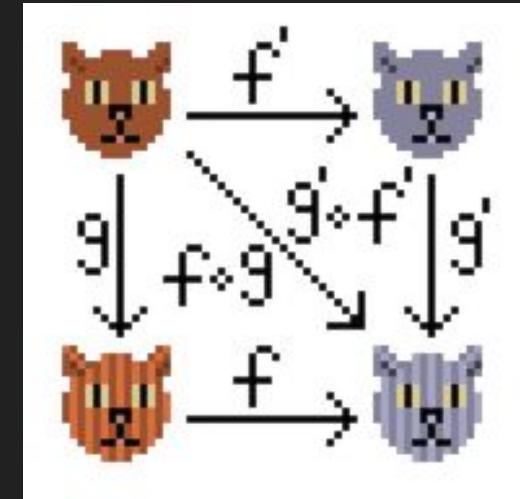
- A mathematical structure
 - There should be binary operation `|+|` (combine) for the Monoid
 - Monoid should have empty value \emptyset
 - $\emptyset |+| m1 = m1 = m1 |+| \emptyset$
 - $(m1 |+| m2) |+| m3$ shouldBe $m1 |+| (m2 |+| m3)$
- An useful and common structure
 - There're good libraries to handle these common structure
 - e.g. Cats, Scalaz, etc...
- Many things in the world is a Monoid
 - List
 - Option
 - ...

モノイドとは空要素と結合操作と結合則を持つ型のこと

Handling Context using Cats



- Cats: Functional programming library for Scala
- Implementing Monoid instance for Context



Catsライブラリを使ってモノイドとしての
コンテキストを扱う



```
implicit val monoidForContext = new Monoid[Context] {
  def combine(x: Context, y: Context): Context = {
    val spokenByCharacterId = y.spokenByCharacterId |+| x.spokenByCharacterId
    val characterConfigMap = x.characterConfigMap ++ y.characterConfigMap
    val serifColor = y.serifColororElse x.serifColororElse spokenByCharacterId
    val tachieUrl = y.tachieUrlorElse x.tachieUrlorElse spokenByCharacterId
    Context(
      voiceConfigMap = x.voiceConfigMap ++ y.voiceConfigMap,
      characterConfigMap = characterConfigMap,
      backgroundImageUrl =
        | y.backgroundImageUrlorElse x.backgroundImageUrl, // 後勝ち
        spokenByCharacterId = spokenByCharacterId,
        speed = y.speedorElse x.speed, // 後勝ち
        serifColor = serifColor,
        tachieUrl = tachieUrl,
        dict = y.dict |+| x.dict,
        additionalTemplateVariables = x.additionalTemplateVariables ++ y.additionalTemplateVariables,
        bgm = y.bgmorElse x.bgm,
        codes = x.codes |+| y.codes, // Map の Monoid 性を応用すると、同一 id で書かれた二つの値が合算される
        maths = x.maths |+| y.maths,
        sic = y.sicorElse x.sic,
    ) ← #61-76 Context
  } ← #56-77 def combine(x: Context, y: Context): Context =
  def empty: Context = Context.empty
} ← #55-79 implicit val monoidForContext = new Monoid[Context]
```



がんばってコンテキストがモノイドであることを示す



(2)

```
class ContextSpec extends AnyFlatSpec with Matchers {
    // Verify that Context is a Monoid
    "Context" should "satisfy associative law" in {
        val x = Context(
            Map("zundamon" → VoiceVoxBackendConfig("3")),
            Map("z" → CharacterConfig("z", "zundamon")),
            Some("https://example.com/bg1.png")
        ) ← #9-13 val x = Context
        val y = Context(
            Map("metan" → VoiceVoxBackendConfig("2")),
            Map("m" → CharacterConfig("m", "metan")),
            Some("https://example.com/bg2.png")
        ) ← #14-18 val y = Context
        val z = Context(
            Map("tsumugi" → VoiceVoxBackendConfig("8")),
            Map("t" → CharacterConfig("t", "tsumugi")),
            None
        ) ← #19-23 val z = Context

        import cats.implicits._
        { (x |+| y) |+| z } shouldEqual { x |+| (y |+| z) }
    } ← #8-27 "Context" should "satisfy associative law" in
        windymelt, 4 か月前 · Contextの仮実装
    it should "have identity element" in {
        val x = Context(
            Map("zundamon" → VoiceVoxBackendConfig("3")),
            Map("z" → CharacterConfig("z", "zundamon"))
        )

        val e = Context.empty

        import cats.implicits._
        (x |+| e) shouldEqual (e |+| x)
    } ← #29-39 it should "have identity element" in
```



モノイド則を満たすことのテストも書く



```
def fromNode(  
    dialogueElem: scala.xml.Node,  
    currentContext: Context = Context.empty  
) : Seq[(Say, Context)] = dialogueElem match {  
  case Comment(_) ⇒ Seq.empty // コメントは無視する  
  case Text(t) if t.forall(_.isWhitespace) ⇒ Seq.empty // 空行やただの  
  case Text(t) ⇒ Seq(Say(t)) → currentContext  
  case e: Elem ⇒  
    | e.child.flatMap(c ⇒ fromNode(c, currentContext |+| extract(e)))  
} ← #84-90 : Seq[(Say, Context)] = dialogueElem match
```

😊 We can serialize XML tree using `|+|`

モノイドの`|+|`を使って木を平らに潰す操作が書けた



Done: flatten

XML原稿を平らに潰してメタデータを各要素に配った



2. Map

原稿を画像と音声に変換する

Materialize (Sentence, Context)



- Image
 - Generate HTML using Twirl
 - Currently template is fixed
 - Render HTML using Chromium
 - Use screenshot option
 - Screenshot will be generated into filesystem
 - Use **os-lib** to spawn process
- Voice
 - Call API for VOICEVOX Engine
 - API returns `audio/wav` byte array
 - Use **http4s** to make HTTP requests

TwirlでHTMLを生成し、Chromiumでレンダーする
音声はVOICEVOXをhttp4sで叩く

Asynchronous



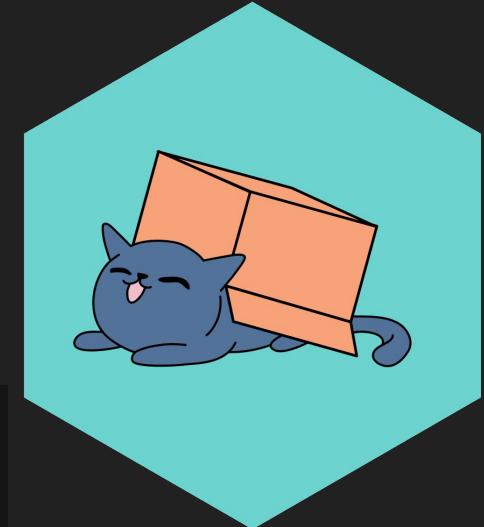
- (Sentence, Context) makes two operation (side effect)
 - Calling voice synthesizer
 - Calling HTML Renderer / Chromium
- Each is independent
 - ⇒ We can call them concurrently

生成処理は独立しているので非同期・並行して呼び出せる

Handling asynchronous operation using Cats Effect



- Handle side effect as `IO[?]` type
- Separate definition and execution of side effect
- Programmer: Prepare and Compose `IO` type
- Cats Effect: Execute and schedule `IO` type
 - Fiber (managed thin thread)
 - Parallel execution



```
private def generateSay(  
    sayElem: domain.model.Say,  
    voiceVox: VoiceVox,  
    ctx: Context  
): IO[(fs2.io.file.Path, scala.concurrent.duration.FiniteDuration)] = for {
```

Cats Effectで非同期処理をこなしてもらうことにした



Handling asynchronous operation using Cats Effect

- saySeq:
Seq[IO[(Path, FiniteDuration)]]
- saySeq.parSequence
IO[Seq[(Path, FiniteDuration)]]
 - Cats Effect does parallel execution

```
for [|
  -> showLogo
  -> IO.println(s"""\${path} ${System.getProperty("user.dir")}"")
  -> IO.println(s"""${configuration} voicevox api: ${voiceVoxUri}""")
  -> IO.println(s"""${configuration} chromium command: ${chromiumCommand}""")
  -> IO.println(s"""${configuration} ffmpeg command: ${config.getString("ffmpeg.com...})
  -> IO.println("Invoking audio api...")
  x <- content
  -> contentSanityCheck(x)
  defaultCtx <- prepareDefaultContext(x)
  -> applyDictionary(defaultCtx)
  // <- IO.println(ctx)
sayCtxPairs <- IO.pure(Context.fromNode((x \ "dialogue").head, defaultCtx))
pathAndDurations <- {
  import cats.syntax.parallel._
  val saySeq = sayCtxPairs map { case (s, ctx) => generateSay(s, voiceVox, ctx) }
  saySeq.parSequence
}
// <- IO.println(pathAndDurations -->
```

parSequenceメソッドで並列実行を指示できる



3. Combining

結合する

Combining – call ffmpeg



- ffmpeg can create video from still image and sound
 - First, overlay all sounds with ffmpeg
 - Voice
 - BGM
 - Next, combine all rendered images into one MP4 file
 - Finally, zip sound and video
- Use `os-lib` to spawn ffmpeg process
- We've got MP4 file

最後に画像と音声をffmpegを呼び出して結合する

Review: What we did



- **Flattened** XML tree, and made sequence of (speech text, context)
 - Context is merged by making it Monoid
- **Mapped** sequence of (speech text, context) into sequence of (image, voice)
 - Efficient parallel execution by using Cats Effect
- **Combined** sequence of (image, voice) into single MP4
 - FFmpeg does this

おさらい: XMLを潰して直線構造にし、画像と音声へ変換を行い、結合してMP4ファイルに変換した



ZMM – philosophy

ZMMが目指す哲学

Why I made this application? – License!



- Soft / Open license made VOICEVOX popular
 - MIT license for core library, soft license for each character
- Artists contribute their illustration on soft license
 - e.g. “*You can use it for anything as long as it is within the official terms and conditions.*”

音声合成・キャラクター・立ち絵は比較的オープンなライセンスで提供されていて、だからこそ広まった

Why I made this application? – License!



- Famous video editing tools known among folks are on **proprietary license**
 - Free for using, but closed source
 - Once author dead, that's end
 - ZMM is provided on **MIT license**
- Open ecosystem is getting grow **except for video editor**
 - Why don't we?

動画作成ツールもオープンなライセンスで作ることで、
より動画コミュニティの世界を広げたい

ZMM – Future



- Aiming at middle quality application
 - Not perfect, nor very powerful, but good for general use
- Main contributor: @windymelt
 - An user gave me `ci.yaml` (unique contributor now 😂)
- Documentation: WIP at <https://www.3qe.us/zmm/doc/>
- Web Frontend for folks: WIP at <https://github.com/windymelt/zmf> (private yet)
 - React + Typescript
 - Help me...

今のところ僕だけが開発しています。一緒にフロントエンドなども作りませんか

“Connecting Dots”



- Connecting specialist and movie culture = ∞
- We can invent nice tool to connect them!

専門家と動画文化を接続することで、より良い文化へ



Let's make video community
Bigger, Better, More Opened!



動画コミュニティをより大きく、良く、オープンに

COPYING



- 「ゆっくり」の素材
- ずんだもん立ち絵素材
- VOICEROID2 結月ゆかり
- CeVIO AI
- VOICEVOX ずんだもん