

## Cassandra Crossing/ Archivismi: archiviamo Cassandra, parte seconda

(565)—Dopo aver preparato i pdf non ci sono più scuse, dobbiamo archiviare il nostro primo articolo di Cassandra Crossing.

---

### Cassandra Crossing/ Archivismi: archiviamo Cassandra, parte seconda



(565)—Dopo aver preparato i pdf non ci sono più scuse, dobbiamo archiviare il nostro primo articolo di Cassandra Crossing.

**1 gennaio 2024**—Nelle precedenti puntate di *Archivismi* abbiamo raccontato le caratteristiche principali di Internet Archive, e caricato un semplice documento di esempio. Successivamente ci siamo dati l'ambizioso obiettivo di uploadare l'*opera omnia* di Cassandra, ed abbiamo faticosamente preparato il materiale necessario nei formati e struttura più opportuni.

Non ci sono più scuse; è il momento di iniziare a caricare il primo documento di Cassandra Crossing, con tutte le cosette ed i metadati al posto giusto!

Dobbiamo quindi cimentarci davvero con *ia* e, visto che dovremo caricare centinaia di documenti, non farlo direttamente con la linea comandi, caricando un file per volta e scrivendo tutti i parametri ed i metadati su una lunghissima linea comandi.

Molto meglio impratichirsi fin da subito con i *bulk upload*, che si realizzano fornendo ad *ia* un unico parametro, cioè il nome di un foglio elettronico in

formato CSV, in cui inseriremo i dati necessari (e li modificheremo tantissime volte per rimediare ad inevitabili errori).

Il comando per fare ciò è semplicemente

```
ia upload—spreadsheet=metadata.csv
```

Il lavoro vero sarà riempire il foglio elettronico finale con migliaia di righe di dati, ma facciamo un passo alla volta e carichiamo un solo oggetto, per cui un file di tre righe basterà.

Il nostro primo documento conterrà due file tra quelli generati per l'archiviazione, il *pdf* come documento principale e l'*html entrocontenuto* come secondo file; aggiungeremo anche un *minimo sindacale* di metadati, e l'identificativo verrà scelto uguale al nome dei file, tolta l'estensione.

Insomma, dopo molti, molti tentativi ecco il foglio ...

	A	B	C	D	E	F	G	H	I	J	K
1	identifier	file	description	subject[0]	subject[1]	subject[2]	title	creator	date	collection	mediatype
2	Test4_562_Cassandra-Crossing-Archivismi-I-organizzazione-dei-documenti-in-Internet-Archive	/html/562_Cassandra-Crossing-Archivismi-I-organizzazione-dei-documenti-in-Internet-Archive.html	Come archiviare gli articoli su Internet Archive	Soggetto 1	Soggetto 3	Soggetto 3	Archivismi: l'organizzazione e dei documenti in Internet Archive	Marco A.L. Calaman		2023 test_collection	texts
3	Test4_562_Cassandra-Crossing-Archivismi-I-organizzazione-dei-documenti-in-Internet-Archive	/pdf/562_Cassandra-Crossing-Archivismi-I-organizzazione-dei-documenti-in-Internet-Archive.pdf								test_collection	texts
4											

Sembra facile, ma c'è voluta mezza giornata di lavoro, per avere il primo inserimento soddisfacente. Minuzie apparentemente insignificanti ma in realtà diaboliche hanno richiesto un sacco di tempo per prove e controprove. Ve ne racconto qualcuna qui, sperando così di farvi risparmiare tempo prezioso.

**uno**—quando salvate un foglio elettronico in formato CSV, che vuol dire “*valori separati da virgole*” non fidatevi della vostra applicazione. In certi casi, qui in Italia, l'applicazione potrebbe decidere di usare non la virgola ma il punto e virgola, e voi non ve ne accorgete subito. Giuro, è successo!

**due**—disabilitate, nell'applicazione con cui state gestendo il foglio elettronico, tutti gli strumenti di autocorrezione; altrimenti il programma deciderà certamente di sostituire qualcosa per *il vostro bene*. Nel mio caso ha deciso di sostituire due segni meno consecutivi, presenti nei nomi di file, con un “*trattino lungo*”, una modifica praticamente invisibile, anche da linea comandi. Questo ha portato all'inspiegabile messaggio di errore di *file non trovato*, ed ha reso necessarie alcune dozzine di prove, con relativi arrampicamenti sugli specchi. Non riferisco qui le parole che sono state pronunciate quando il problema è stato finalmente localizzato!

**tre**—state molto attenti quando inserite i valori nei campi. Un singolo spazio bianco prima o dopo il valore può non farlo interpretare, ed avere effetti imprevisti. Uno spazio all'inizio di “*test\_collection*” ha ad esempio impedito

l'assegnazione corretta dell'oggetto alla *collection di test*, destinata, come già sapete, ad abilitare la cancellazione automatica dopo 30 giorni. In più considerate che non è possibile assegnare esplicitamente l'oggetto a collezioni pubbliche come “*opendata*”, ma bisogna accettare la selezione automatica che verrà operata dal sistema.

**quattro**—inserite nel foglio la colonna *mediatype*, quando i documenti sono testuali (txt, html, pdf, etc.), ed usate il valore, “*texts*” altrimenti il sistema assegnerà automaticamente il valore “*data*” e questo avrà effetti collaterali insidiosi. Ad esempio il *browser di oggetti* non vi farà sfogliare le pagine, malgrado tutti i file derivati necessari siano stati creati correttamente. Il *mediatype*, contrariamente alla grande maggioranza dei parametri, non può più essere modificato, ma è necessario cancellare e rigenerare l'oggetto.

**cinque**—cancellare un oggetto non è un'operazione istantanea, ma richiede minuti o decine di minuti prima che l'effetto si propaghi in tutte le parti dell'interfaccia del sito. Non merita cancellare da linea comandi con *ia*; è decisamente più pratico farlo dalla pagina *My Upload*. Ricaricate spesso la pagina, e se notate cose strane, provate anche a svuotare la cache del browser.

**sei**—la comparsa di un oggetto appena creato nella finestra *My Upload* è, stranamente, abbastanza veloce, ma scatena tutte le operazioni “*derivative*”, che a loro volta generano gli altri file in tempi variabili ma abbastanza lunghi. Questo vuol dire, ad esempio, che il *browser di oggetti* non sarà in grado di farvi sfogliare le pagine prima di una mezz'ora, e che la funzionalità di ricerca interna al *browser di oggetti* sarà attiva solo dopo parecchie ore.

**Però, alla fine, che soddisfazione ...**

## Archivismi: l'organizzazione dei documenti in Internet Archive

by Marco A.L. Calamari



Publication date 2023  
Topics Soggetto 1, Soggetto 3, Soggetto 3  
Collection test\_collection

Come archiviare gli articoli su Internet Archive con mediatype texts

Addeddate 2024-01-01 14:20:22  
Identifier Test4\_562\_Cassandra-Crossing--Archivismi--l-organizzazione-dei-documenti-in-Internet-Archive  
Identifier-ark ark:/13960/s2vc5qm14d  
Ocr tesseract 5.3.0-6-g76ae  
Ocr\_autonomous true  
Ocr\_detected\_lang it  
Ocr\_detected\_lang\_conf 1.0000  
Ocr\_detected\_script Latin  
Ocr\_detected\_script\_conf 1.0000  
Ocr\_module\_version 0.0.21  
Ocr\_parameters -l ita-Latin  
Page\_number\_confidence 0

SHOW MORE



### Reviews

Add Review

There are no reviews yet. Be the first one to write a review.

0 Views

#### DOWNLOAD OPTIONS

CHOCR	1 file
EPUB	1 file
FULL TEXT	1 file
HOCR	1 file
HTML	1 file
ITEM TILE	1 file
OCR PAGE INDEX	1 file
OCR SEARCH TEXT	1 file
PAGE NUMBERS JSON	1 file
PDF	1 file
SINGLE PAGE PROCESSED JP2 ZIP	1 file
TORRENT	1 file
SHOW ALL	16 Files 7 Originals

#### IN COLLECTIONS

Collection of Test Items



Community Collections



Uploaded by  
calamarim  
on January 1, 2024

Ed anche per oggi è tutto. *Stay tuned* per la prossima puntata di “Archivismi”.

Scrivere a Cassandra—Twitter—Mastodon  
Videorubrica “Quattro chiacchiere con Cassandra” tempo  
Lo Slog (Static Blog) di Cassandra  
L’archivio di Cassandra: scuola, formazione e pensiero

**Licenza d’utilizzo:** *i contenuti di questo articolo, dove non diversamente indicato, sono sotto licenza Creative Commons Attribuzione—Condividi allo stesso modo 4.0 Internazionale (CC BY-SA 4.0), tutte le informazioni di utilizzo del materiale sono disponibili a questo link.*

By Marco A. L. Calamari on January 3, 2024.

Canonical link

Exported from Medium on January 15, 2024.