Digitalizace

úvod do problematiky

Martin Krčál

VIKBB42 Knihovnické procesy a služby **Brno, 27. března 2013**

Otázka na úvod

- Jak získáme elektronický dokument?

Digitalizace

- převod info z analogové do **digitální** (elektronické) podoby
- formy informace
  - textové
  - obrazové
  - zvukové
  - jejich kombinacích

Proč digitalizujeme

- dostupnost informací
- úspora místa
- ochrana a archivace
- vyhledávání

Základní pojmy

Rozlišení

- rozdělení obrazu na síť pixelů
- **pixel** = jedna barva
- větší hustota (rozlišení) = větší kvalita = větší velikost souboru
- základní jednotka **dpi** (dots per inch)
- tisková kvalita od 300 dpi
- na web od 75 dpi

Barevná hloubka

- počet barev použitých při skenu
- černobílé skeny: čb nebo stupně šedi
- barevné skeny: 24-bitů+
- zdravé oko vnímá okolo 4 mld. odstínů barev

Barevná hloubka - počty barev

Druh obrazu	Počet bitů	Počet barev
černobílý (bitonální, monochromatické)	1	$2^1 = 2$
stupně šedi (grayscale)	8	$2^8 = 256$ odstínů šedi
8-bitový barevný (color)	8	$2^8 = 256$
16-bitový (high color)	16	$2^{16} = 65\,536$
24-bitový (true color)	24	$2^{24} = 16\,777\,216$
32-bitový (super true color)	32	$2^{32} = 4\,294\,967\,296$
48-bitový (deep color)	48	$2^{48} = 281\,474\,976\,710\,656$

Komprese

- zmenšení velikosti souboru
- druhy komprese
  - ztrátová – vypuštění některých pixelů (např. podprahové), větší komprese zmenšuje soubor, ale snižuje kvalitu, trvalá a nevratná (JPG, MP3, MPEG, AAC)
  - bezztrátová – převod na matematický algoritmus, okolní barvy se dopočítávají, není tak účinná jako ztrátová, ale je vratná (GIF, PNG, TIFF, WMA Lossless, RealAudio Lossless, některé video kodeky – HuffyUV, Lagarith)

OCR

- **O**ptical **C**haracter **R**ecognition
- automatické rozpoznávání textu
  - obrazová předloha
  - analýza znaků
  - porovnání s DB (znaky, slova)
- kvalita OCR
  - přesnost rozpoznání
  - kvalita předlohy
- OCR pro národní jazyky

Nástroje - funkce

- profi i free nástroje, home verze
- ručně psané písmo – problémy
- podpora národních jazyků
- zachování layoutu a formátování
  - ❖ písmo, velikost, odstavce, obrázky
- označení bloků k rozpoznání
- ukládání jako PDF s txt vrstvou
- dávkové zpracování
- serverové verze

OmniPage


OmniPage 17
OmniPage 17

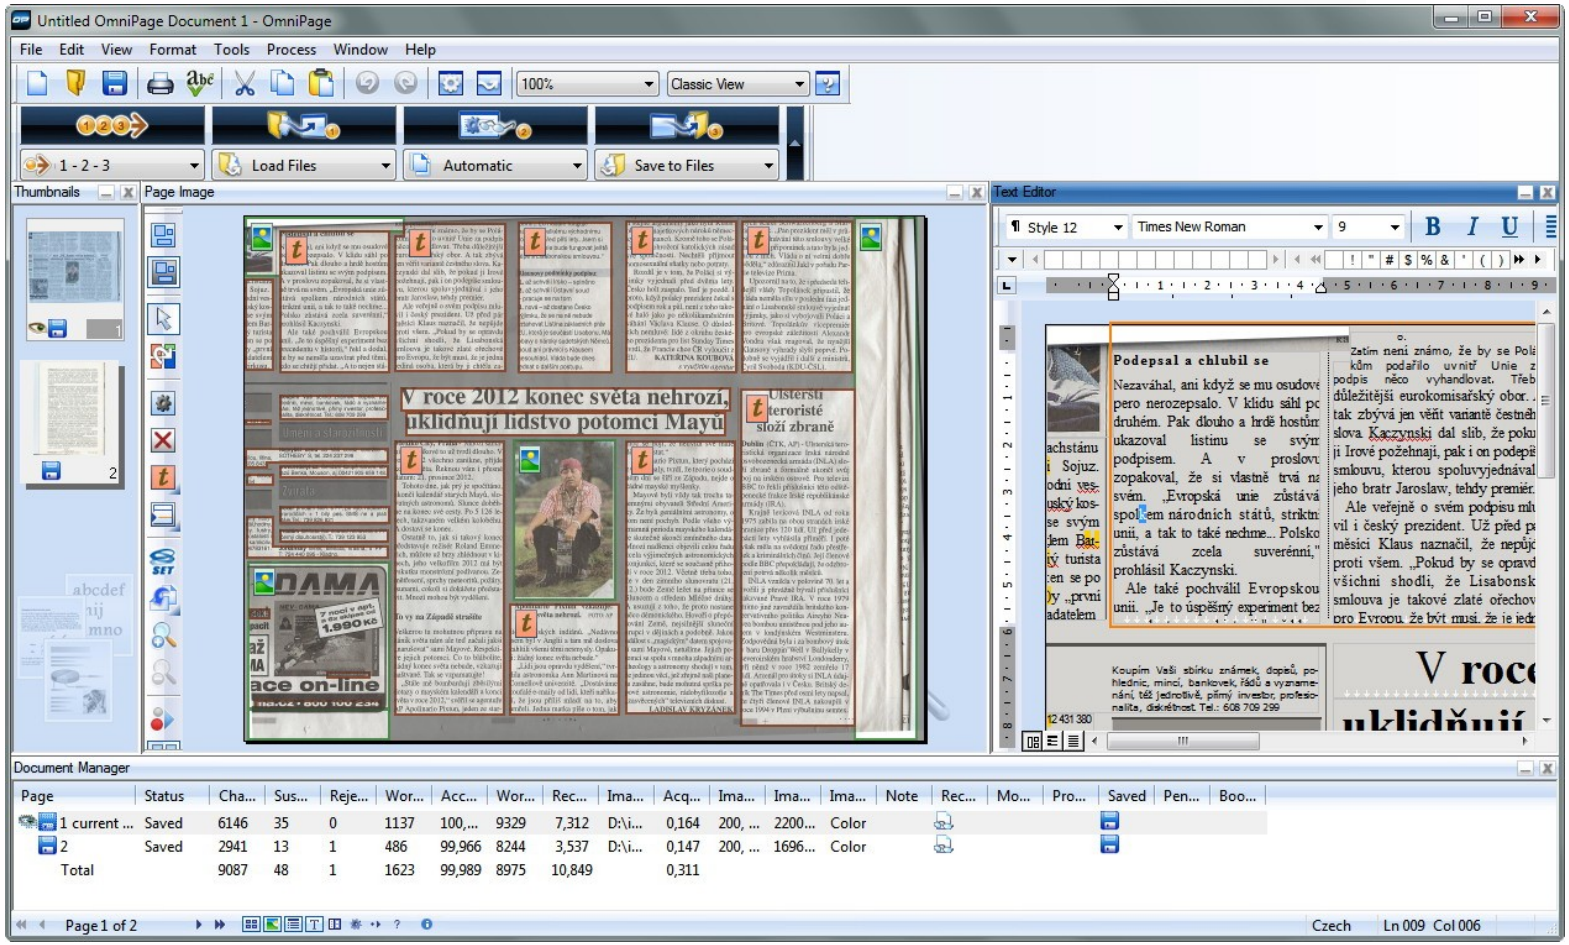
Untitled OmniPage Document 1 - OmniPage
File Edit View Format Tools Process Window Help
100%
Classic View
1 - 2 - 3
Load Files
Automatic
Save to Files
Thumbnails
Page Image
Text Editor
Style 12
Times New Roman
9
V roce 2012 konec světa nehrozí, uklidňují lidstvo potomci Mayů
Podepsal a chlubil se
Document Manager
Page Status Cha... Sus... Reje... Wor... Acc... Wor... Rec... Ima... Acq... Ima... Ima... Ima... Note Rec... Mo... Pro... Saved Pen... Boo...
1 current ... Saved 6146 35 0 1137 100,... 9329 7,312 D:\i... 0,164 200, ... 2200... Color
2 Saved 2941 13 1 486 99,966 8244 3,537 D:\i... 0,147 200, ... 1696... Color
Total 9087 48 1 1623 99,989 8975 10,849 0,311
Page 1 of 2
Czech
Ln 009 Col 006

Omnipage

- nyní verze 18
- různé licence
  - Standard, Professional, Enterprise
- 123 jazyků
  - vč. češtiny, nemá český interface
- přesnost 99%
- propojení se zařízeními a SW
  - Kindle, MS Office
- propojení na cloud úložiště
  - Evernote a Dropbox

Readiris

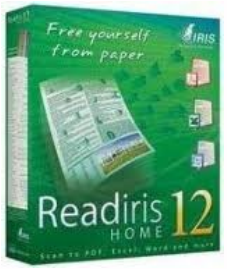
Free yourself from paper
IRIS
Readiris 12
HOME

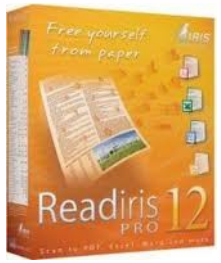
Free yourself from paper
IRIS
Readiris 12
PRO

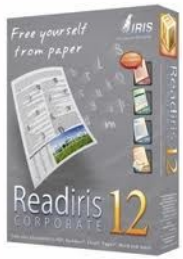
Free yourself from paper
IRIS
Readiris 12
CORPORATE

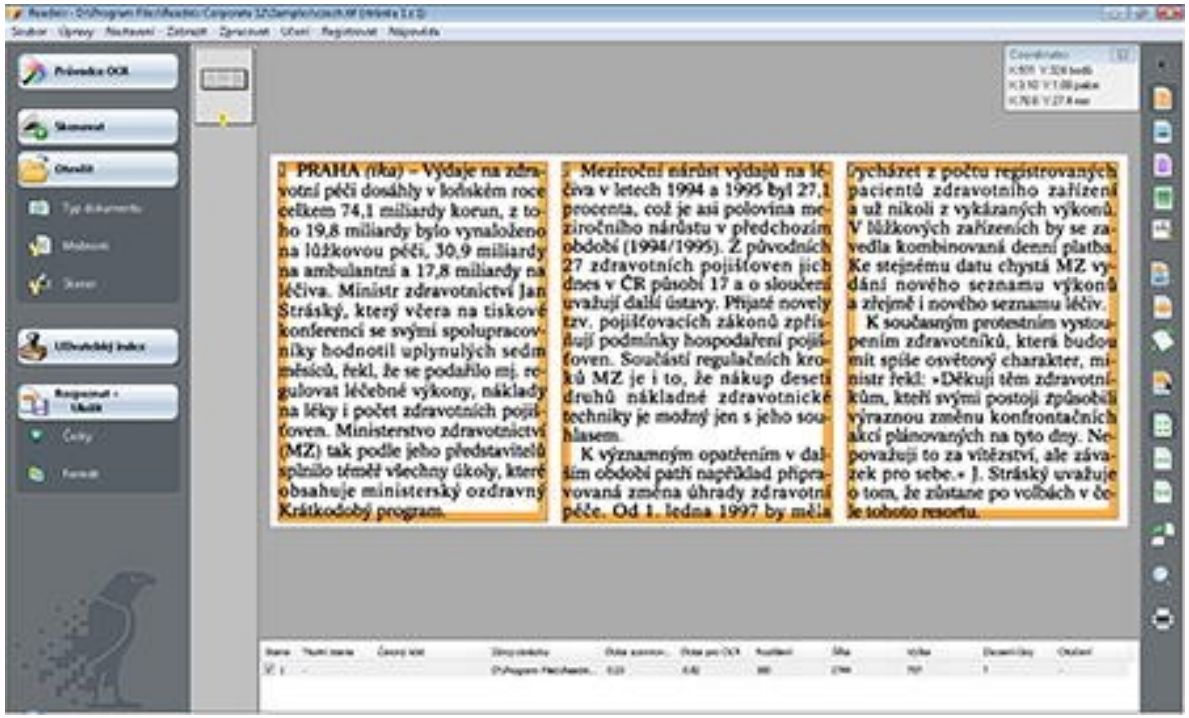
Průvodce OCR
PRAHA (ika) – Výdaje na zdravotní péči dosáhly v loňském roce celkem 74,1 miliardy korun, z toho 19,8 miliardy bylo vynaloženo na lůžkovou péči, 30,9 miliardy na ambulantní a 17,8 miliardy na léčiva. Ministr zdravotnictví Jan Stráský, který včera na tiskové konferenci se svými spolupracovníky hodnotil uplynulých sedm měsíců, řekl, že se podařilo mj. regulovat léčebné výkony, náklady na léky i počet zdravotních pojišťoven. Ministerstvo zdravotnictví (MZ) tak podle jeho představitelů splnilo téměř všechny úkoly, které obsahuje ministerský ozdravný Krátkodobý program.
Meziroční nárůst výdajů na léčiva v letech 1994 a 1995 byl 27,1 procenta, což je asi polovina meziročního nárůstu v předchozím období (1994/1995). Z původních 27 zdravotních pojišťoven jich dnes v ČR působí 17 a o sloučení uvažují další ústavy. Přijaté novely tzv. pojišťovacích zákonů zpřísňují podmínky hospodaření pojišťoven. Součástí regulačních kroků MZ je i to, že nákup deseti druhů nákladné zdravotnické techniky je možný jen s jeho souhlasem.
K významným opatřením v dalším období patří například připravovaná změna úhrady zdravotní péče. Od 1. ledna 1997 by měla vycházet z počtu registrovaných pacientů zdravotního zařízení a už nikoli z vykázaných výkonů. V lůžkových zařízeních by se zavedla kombinovaná denní platba. Ke stejnému datu chystá MZ vydání nového seznamu výkonů a zřejmě i nového seznamu léčiv.
K současným protestním vystoupením zdravotníků, která budou mít spíše osvětový charakter, ministr řekl: »Děkuji těm zdravotníkům, kteří svými postoji způsobili výraznou změnu konfrontačních akcí plánovaných na tyto dny. Nepovažuji to za vítězství, ale závazek pro sebe.« J. Stráský uvažuje o tom, že zůstane po volbách v čele tohoto resortu.

Readiris

- nyní verze 14
- 120 jazyků (vč. češtiny)
- spolupracuje s MS Office
- konverze do PDF
- info o verzi 12 na Grafika.cz

Abby Fine Reader

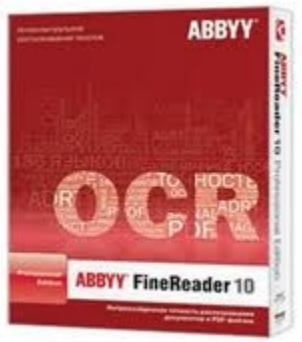

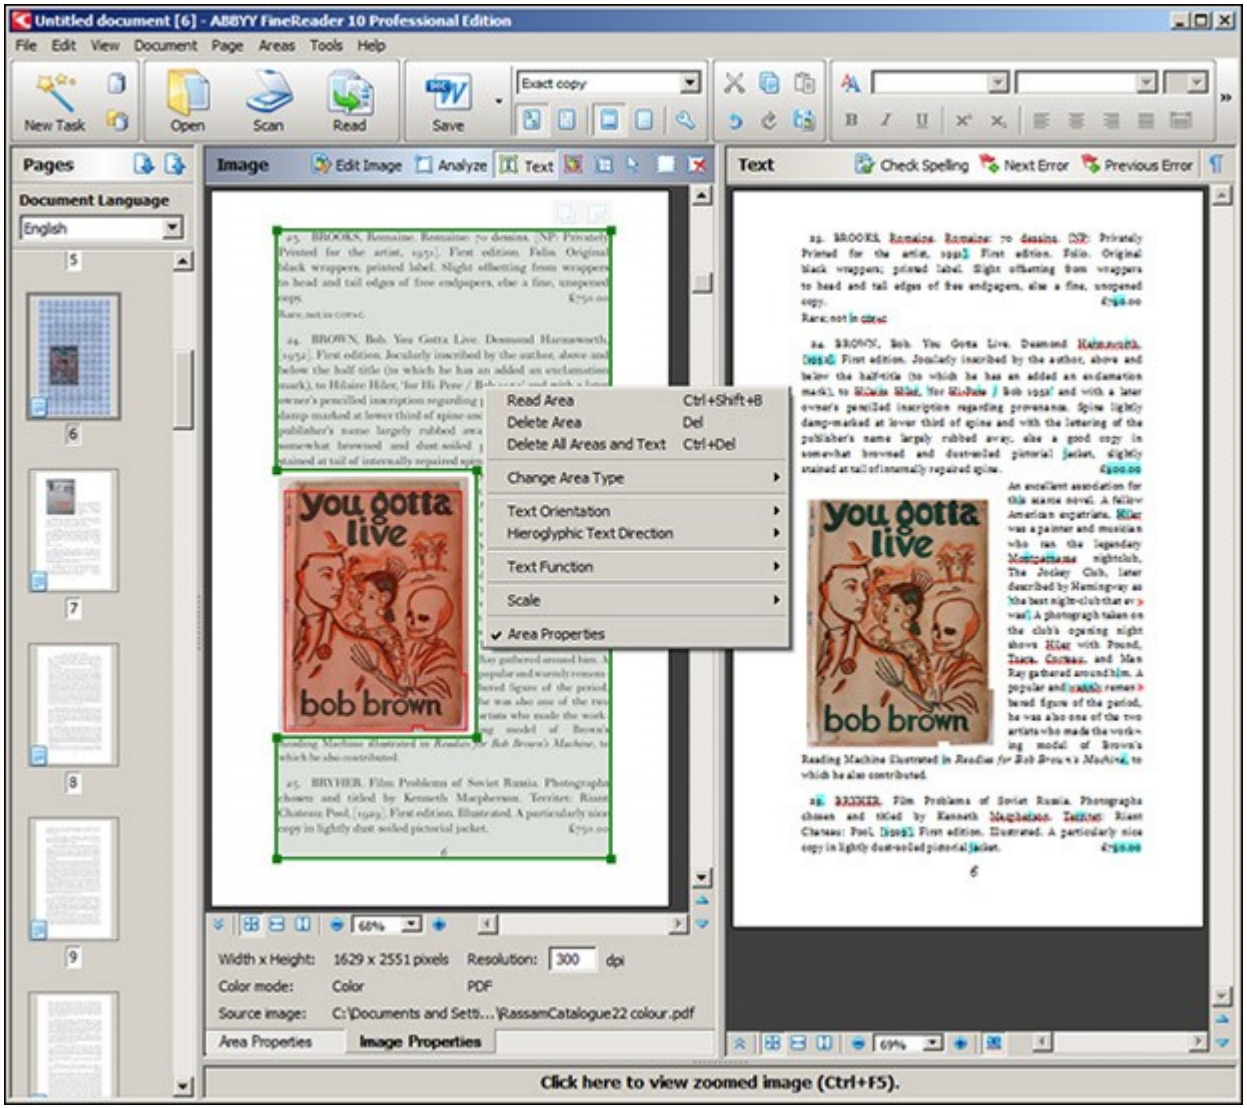

Abby Fine Reader

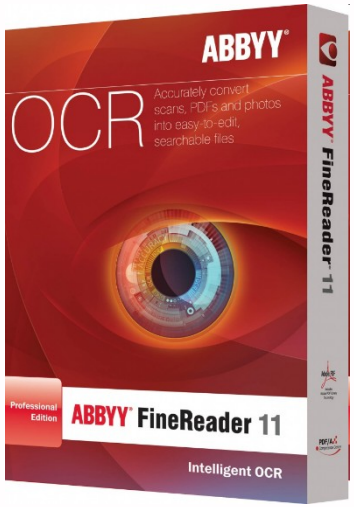

- verze 11
- 189 jazyků (včetně češtiny)
- stejné funkce jako konkurence
- serverová verze
- více info na Grafika.cz
- PDF Transformer 3.0
  - ❖převod PDF do editovatelné podoby

Free OCR

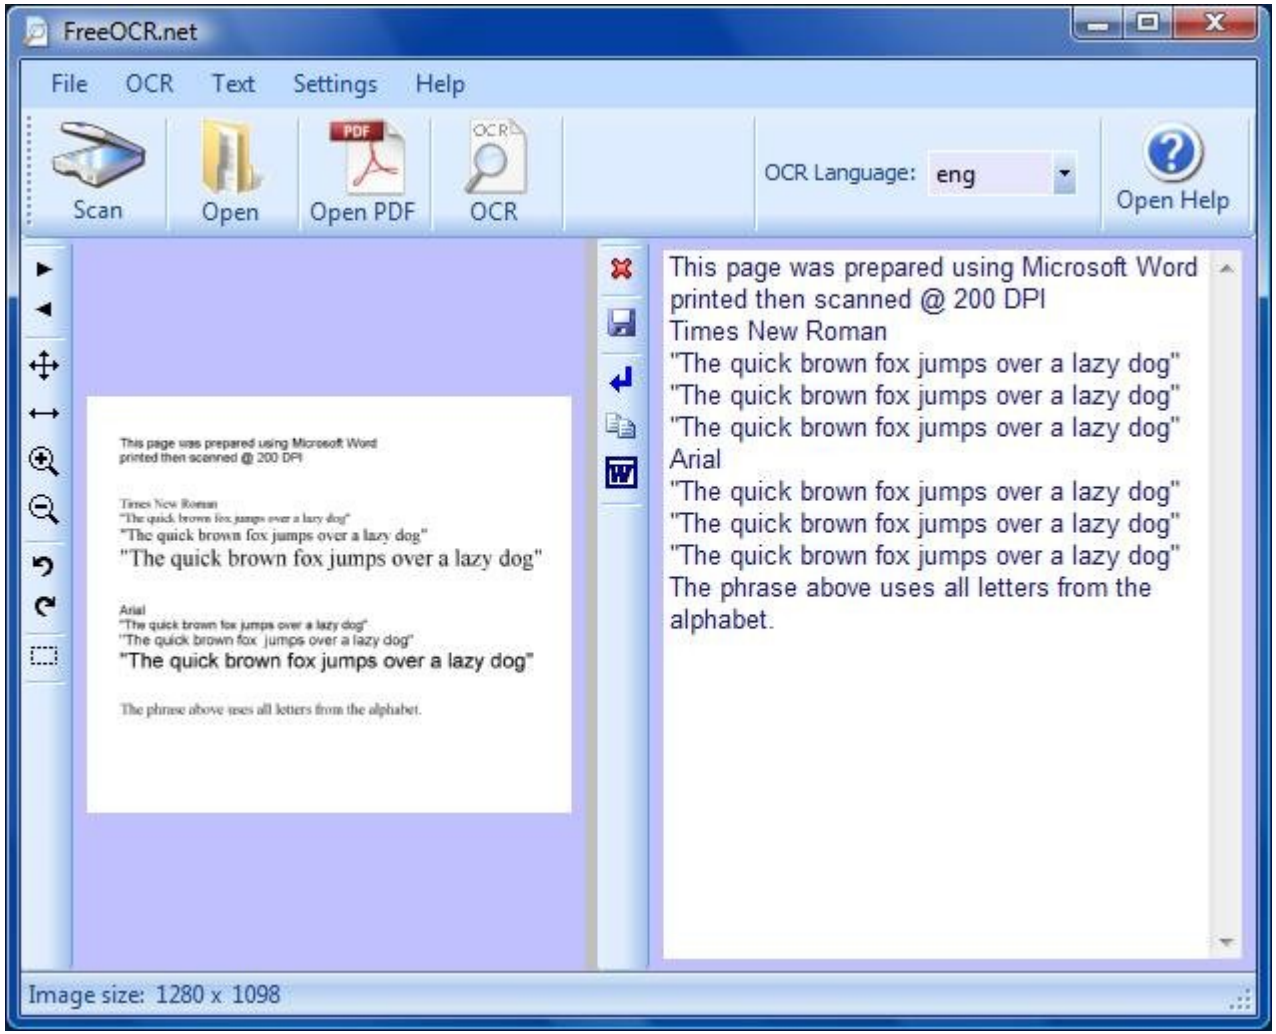
FreeOCR.net
File
OCR
Text
Settings
Help
Scan
Open
Open PDF
OCR
OCR Language:
eng
Open Help
This page was prepared using Microsoft Word
printed then scanned @ 200 DPI
Times New Roman
"The quick brown fox jumps over a lazy dog"
"The quick brown fox jumps over a lazy dog"
"The quick brown fox jumps over a lazy dog"
Arial
"The quick brown fox jumps over a lazy dog"
"The quick brown fox jumps over a lazy dog"
"The quick brown fox jumps over a lazy dog"
The phrase above uses all letters from the alphabet.
Image size: 1280 x 1098

FreeOCR

- OCR zdarma pro Windows
- verze 4.2
- vychází z Tesseract OCR Engine
- nemá české podklady
- horší kvalita výstupu
- solidní výsledky na podporované jazyky
  - ENG, GER, SPA, POR, NDL, ITA

Online služby

- **OnlineOCR**
  - 32 jazyků včetně češtiny
  - dobrá kvalita, zachování v layoutu, výstupy do DOC, XLS, TXT
  - omezení (odpadnou po registraci)
- **NewOCR**
  - 58 jazyků včetně češtiny
  - posloupnost odkazů, ale nezachová layout, dobrá kvalita
  - propojení s Google Docs a Translate + Bing Translate
  - bez registrace, bez omezení

Online služby

- **Free OCR**
  - 29 jazyků včetně češtiny
  - dobrá kvalita, dobré výsledky
  - max. 2MB, 10 stran za hodinu
  - capcha

ScanTaylor

- opensource
- komplexní nástroj pro úpravu dokumentů
- otáčení, spojování, odstraňování částí stránek, OCR
- nepodporuje PDF – PDF-TO-TIFF

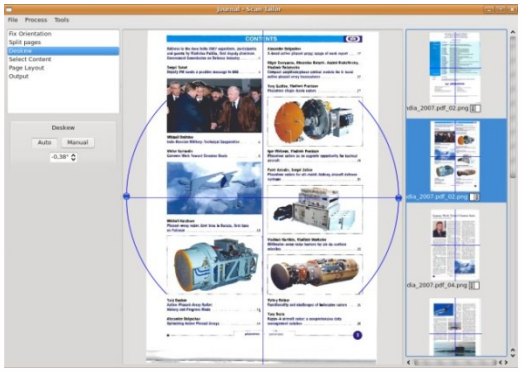

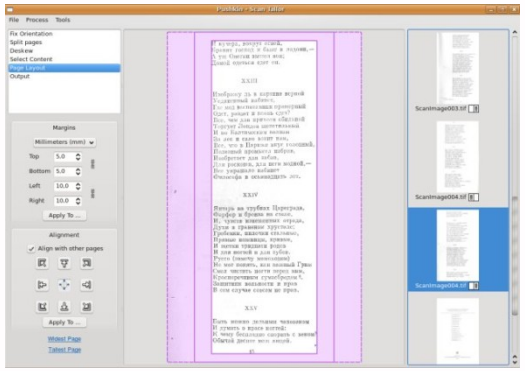

Články k nástrojům

- http://extrawindows.cnews.cz/prehled-softwaru-rozpoznavani-textu-ocr-jak-na
- http://extrawindows.cnews.cz/prehled-softwaru-rozpoznavani-textu-ocr-jak-na?page=0,1

Výstupní formáty

Výstupní formáty

- grafické
  - JPG, TIFF, PNG, GIF, BMP
- textové
  - TXT, RTF, PDF, DjVu

JPG (JPEG)

- **J**oint **P**hotographic (**E**xpert) **G**roup
- nejrozšířenější formát
- ztrátová komprese (0-100%)
- malé soubory
- vhodné na web

TIFF

- **T**agged **I**nterchange **F**ile **F**ormat
- podobný BMP
- ztrátová komprese

PNG

- **P**ortable **N**etwork **G**raphics
- bezztrátová komprese
- náhrada formátu GIF
- podpora 24-bitové grafiky
- průhlednost
- na rozdíl od GIF nepodporuje animace

BMP

- bitová mapa (**b**it **m**a**p**)
- složen z bodů
- neumožňuje kompresi

GIF

- **G**raphics **I**nterchange **F**ormat
- v minulosti velmi populární
- využití u animovaných obrázků
- uchová max. 256 barev
- bezztrátová komprese

TXT

- Plain Text
- text bez formátování
  - pouze odstavce
- zpracuje jakýkoliv program pracující s textem

RTF

- **R**ich **T**ext **F**ormat
- prostý text se základním formátováním
- Microsoft

PDF

- **P**ortable **D**ocument **F**ormat
- Adobe
- komerční Adobe Acrobat
- prohlížení Reader
- volně dostupné programy
  - PDFCreator, PDFill PDF Tools a další
  - kancelářské balíky: Open Office, MS Office 2007+,…

DjVu

- konkurence PDF
- otevřený formát
- vhodný pro text, obrázky, kresby
- rozdělení do vrstev
  - výběr vhodné komprese = efektivnější komprese = malé soubory
- více info: http://djvu.org

Hardware pro digitalizaci

Skenery

- kvalita skenování
- zvolit vhodný skener pro konkrétní druh dokumentu!!!

Ruční a tužkové skenery

Ruční a tužkové skenery

- problémy s kvalitou a přesností
- chyby při OCR (nejen) českých textů
- výhoda - přenosnost zařízení
- novější integrovaný disk

Plochý skener

Plochý skener

- stolní skener
- relativně kvalitní
- nízká cena
  - v multifunkcích již okolo 1000Kč
- formát A4
- velkoformátové skenery
- odrážení světla na CCD snímač
  - čím tmavší, tím menší odraz světla = určení barvy

Rotační skener

Rotační skener

- bubnový skener
- profesionální využití
- kvalitní výstup
- nelze použít na knihy
  - upínání na válec
- extrémně drahé
  - stovky tisíc až mil. Kč

3D skener

- tvorba 3D modelů

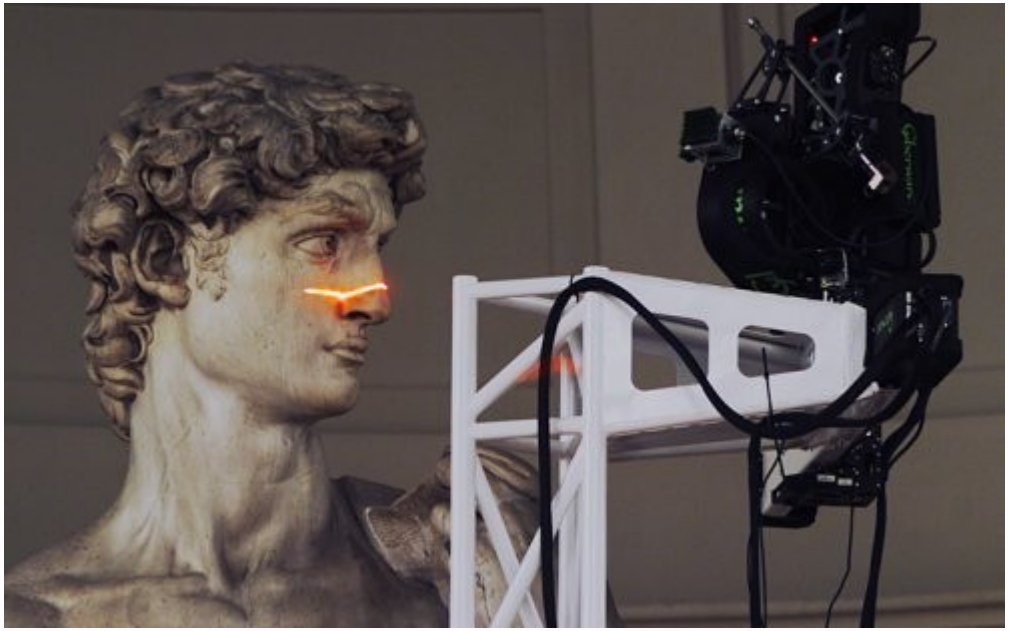

Knižní skener

- http://www.youtube.com/watch?v=-oOXXpxzETA

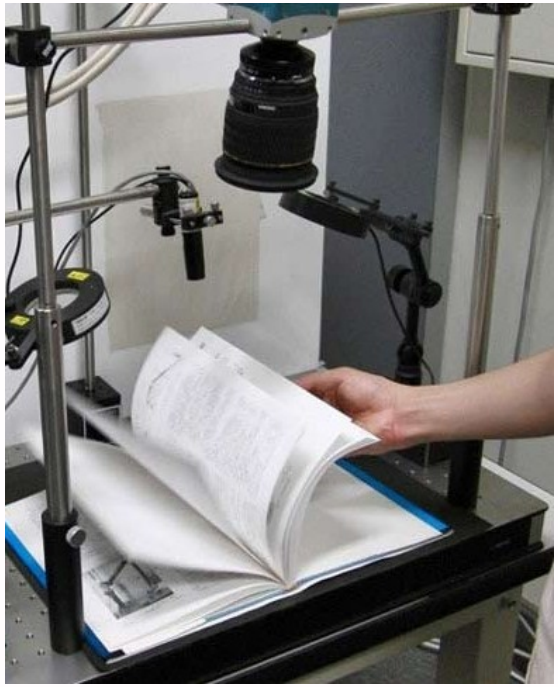

Knižní skener

- fotografické skenery
- komplexní systémy
  - vč. PC a SW
- robotické skenery
  - otáčení stránek
  - extrémně drahé

Postup digitalizace

Výběr a příprava dokumentů

- vytipování dokumentů k digitalizaci
- různá kritéria výběru
- prohlédnutí a volba zařízení pro digitalizaci
  - záleží na typu dokumentu
  - digitalizace VŠKP na MU – rozřezání
  - vyčištění, narovnání listů, svorky,…
  - kvalita předlohy

Stanovení pravidel

- workflow = jednotný postup při digitalizaci, pravidla digitalizace
- uplatnění zejména v projektech a při vícenásobném skenování
- kvalita, rozlišení, komprese, formát,…
- záleží na typu dokumentu

Digitalizace

- provedení převodu
- dle pravidel
- kontrola na výstupu

Uložení do repozitáře

- zvolit vhodný archiv
- metadata
- vhodný formát
- zálohování
- zpřístupnění

Využití digitalizace

- Kde se digitalizace využívá???

Použité zdroje

- Digitální knihovny – teorie a praxe (Bartošek)
- Projekt digitalizace vysokoškolských prací MU (Bartošek)
- Zpracování novinových článků v Digitální knihovně Arna Nováka (Damborská)

Závěr

Děkuji Vám za pozornost

Martin Krčál
krcal@fss.muni.cz