

"Introduction to digitisation"

Adam Dudczak Poznań Supercomputing and Networking Center maneo@man.poznan.pl







"Digitisation is the conversion of analogue materials into a digital format for use by software, and decisions made at the time of digitisation have a fundamental impact on the manageability, accessibility and viability of the resources created." MINERVA Technical Guidelines for Digital Cultural Content Creation Programmes





Agenda

- Why digitise?
 - Examples of digitisation projects
- Introduction to digital images
 - Digital image anatomy
 - File formats
 - Software used in graphical post-processing
- Digital text
 - Optical Character Recognition
 - File formats



Agenda (2)

- A few words about digitisation hardware and software
 - Including a quick tour through the e-learning course
- Case study: "OCR in Poland"
- Discussion



Why digitise?



Digitisation of Codex Gigas, picture by Jens Östman (National Library of Sweden) http://www.flickr.com/photos/25300312@N08/2960776263/

europeana

emix



Why digitise?

Europeana Remix

An interactive experience around the story of an unlikely friendship during the First World War.



http://remix.europeana.eu



Henry III Fine Rolls Project



http://www.finerollshenry3.org.uk/



Benefits?

- Increased visibility!
- Rolls were translated into modern English,
- Searching facility was set up to allow users to search for people, places and given subjects,
- Scanned images were released to facilitate a study on the original Latin content,
- Translations with suitable indexes were published as a set of books



Discover Domesday

DOMESDAY BOOK - THE GAME

It is 1086. Last year William the Conqueror ordered a vast survey of land in England to find out who owns the land and how much it is worth to him as King!

There is now a dispute over the numbers of farm animals recorded at this Domesday holding. To give accurate information at a county court you need to count the animals...

COUNT ALL OF THE ANIMALS BY CLICKING THEM - TRY NOT TO MISS ANY



http://www.nationalarchives.gov.uk/domesday/



Benefits?

- Popularity growth
- Base for interesting teaching material
 - Domesday book THE GAME
- Better understading of history





Australian Newspapers Digitisation

http://trove.nla.gov.au/newspaper



Benefits?

- Did you know?
 - "Convicts could leave the colonies after their sentences were completed or after being granted an Absolute Pardon. Departures were announced in the Sydney Gazette's 'Notice of Intent' column."
- In general... increased visibility! ;-)
- Great source of knowledge about genealogy



The Great War Archive

NOTHING is to be written on this side except the date and signature of the sender. Sentences not required may be erased. If , anything also is added the post card will be destroyed. I am quite well. I have been admitted into hampital (rick) and an going on avil. I wounded | and hope to be discharged soon. Lambeing and Jon to the burn Letter daled I have received your detelopment .. -Letters follows at first opportunity. -I-have needed on letter from you Signature only. Date [Postage must be prepaid on any letter or post addressed to the sender of this rard.) 69464) W4. W1002-1219 L000m. 1214 F. T. S.Co., Ltd.



http://www.oucs.ox.ac.uk/ww1lit/gwa/



Benefits?

- Mobilization of local community
- Chance to preserve stories and unique memorabilia of particular people
- Great educational material
- Not mentioning... increased visibility

POZNAŃ SUPERCOMPUTING AND NETWORKING CENTER CONTACT CUltural heritage and technology





Cultural heritage and technology







Florence Englebach has used thick, creamy paint to capture the flamboyant pinks and reds of the flowers in this picture. The background is painted in the same vigorous style, using varied colours. This approach is characteristic of the style of many artists in the 1930s. Florence Englebach was an accomplished artist who was based in Newcastle from 1902 to 1933. She specialised in flower paintings in the 1930s and 1940s.

Link: http://www.imagine.org.uk/details/index. php?id=TWCMS:F3486



Cultural heritage and technology





Summary of benefits

- Provides better access to unknown or little used collections,
- Offers better search and retrieval facilities for an image collection,
- Provides a better understanding of original works through improved indexing or some form of digital image enhancement,
- Creates resources that are suitable for use in learning and teaching,
- Enhances the public knowledge, recognition and understanding of cultural heritage,
- Facilitates preservation of collections for the future in a digital format.



Agenda

- Why digitise?
 - Examples of digitisation projects
- Introduction to digital images
 - Digital image anatomy
 - File formats
 - Software used in graphical post-processing
- Digital text
 - Optical Character Recognition
 - File formats



Digital image anatomy

"Digital image is a numeric representation (built out of 0s an 1s) of a two-dimensional image" Wikipedia

- Raster images
- Pixels?





Digital image anatomy (2)



- Each pixel:
 - holds information about color
 - has certain position in the image
- Higher number of pixels means better quality of image



Image resolution

- Resolution is a term that describes image ability to hold information
- Higher resolution means that image will be more detailed
- Resolution can be expressed in three ways



Source: http://en.wikipedia.org/wiki/File:Resolution_illustration.png



Number of pixels

- Width and height of an image expressed in pixels
 - e.g. 640 x 480
- Sum of all pixels expressed in megapixels
 - e.g. 0.3 megapixel means that image consist of 307200 pixels, it is the same 640 * 480 image



Color depth

- Each pixel holds information about its color
 - This information can be less or more detailed
- Color depth denotes accuracy of color representation
- It is expressed in bits per pixel (Bits per pixel, BPP)



Color depth (2)

- 1 BPP only two possible colors
- 24 BPP 16,7 milion of colors







PPI

- Image resolution can be expressed using pixel density per inch of [screen, print-out]
- PPI = Pixel Per Inch
- Higher number means more detailed scan/print out





DPI vs PPI

 Dots and pixels are terms from two different worlds



Source: http://en.wikipedia.org/wiki/File:DPI_and_PPI.png



DPI vs PPI (2)

- Digital image quality should be expressed using PPI
- During scanning you need to use Dot Per Inch (?!?)
- In practice this units of measure are used interchangeably



Image compression

- We would like to have very detailed representation of original image, but:
 - we don't like long download times,
 - we don't have money to buy numerous DVDs, required to archive our digital copies
- Image compression can reduce size of graphical files



Image compression (2)

- Lossless compresion
- Lossy compression





Lossy compression

- It is a compromise between information loss and file size reduction
- Usually there is a way to adjust compression ratio
 - Higher compression ratio means that more information is lost but the file is smaller
- Lossy compression is irreversible process
 - Lost information can't be recovered even after decompression
 - This is crucial while working with images!!
- This way of compression is usually more efficient than lossless compression
- Examples of pictures compressed using lossy compression:
 - http://www.bbproject.net/2010/05/jak-wyglada-jpeg-po-100-000-rekompresji/



File formats – what is important?

- Does it impose compression type/method?
- Does it allow to embed metadata in an image?
- Can one file consist of multiple images?
- Is specification of file format publicaly available?
- During this training we will focus on three most widely used gfx file formats: TIFF, JPG, PNG



TIFF

- Tagged Image File Format
- Available since 1986
- Specification is available for everyone
- It allows to:
 - Embed metadata,
 - One file can contain multiple images
 - It can be used without any compression as well as with lossy and lossless compression
- TIFF (+ lossless LZW compression) is considered as an de facto standard in digital archiving



RAW

- RAW is a file format containing unprocessed data from camera image sensors
- Each vendor has its own, so it require dedicated software
- It allows for advanced adjustements of an image
- Sometimes called digital negative



JPEG

- Joint Photography Experts Group
- File format created especially for storing photography
- Very widely used
- It uses lossy compression!



PNG

- Portable Network Graphics
- General purpose file format was suppose to replace GIF files
- It employs lossless compression
- PNGs are usually bigger than JPEGs



Interactive formats

- Allows to dynamically adjust the quality of presented image
- Especially useful for large images which had to be delivered in high level of details e.g. maps
- Three major formats Zoomify, Deep Zoom and Google Maps
 - e.g. http://sbc.wbp.kielce.pl/publication/8855



Software

- Gimp (http://gimp.org)
- IrfanView (http://www.irfanview.com)
- ImageMagick (http://www.imagemagick.org)
- OptiPNG (http://optipng.sourceforge.net)
- ZoomifyExpress (http://www.zoomify.com)
- More to come...





Agenda

- Why digitise?
 - Examples of digitisation projects
- Introduction to digital images
 - Digital image anatomy
 - File formats
 - Scanning resolution
 - Software used in graphical post-processing

Digital text

- Optical Character Recognition
- File formats



Digital text

What is the difference between scanned text and digital text?



Source: http://www.flickr.com/photos/shokai/3255725751/



Why digital text?

- Full text search
 - Even most detailed metadata cannot replace described object
 - Full text search allows to access to full content of the object
 - Crucial for regular and address books
- Reuse
 - Creation of translation, digital editions, monographies is simpler if you can just copy and paste the text
- Research material
 - e.g. Linguistic analysis on how language was changing



Creation of digital text

- Manual keying
 - Manual rewriting of text from scans done by human
 - Expensive (very time-consuming)
 - It may require some domain knowledge
 - Crowdsourcing
 - Trove http://trove.nla.gov.au/newspaper
 - PG DP http://www.pgdp.net/c/
 - Transcrine Bentham http://www.ucl.ac.uk/transcribe-bentham/
 - Wikisource http://wikisource.org
 - Flaws of crowdsourcing



Creation of digital text

- Optical Character Recognition (OCR)
- Computer program converts scanned text into machine-readable digital text
- Quality of results depends on multiple factors



How does OCR works?

- Pre-processing
 - Depending on input image type conversion might be required
 - Binarization, deskewing
- Layout analysis and identification of text components on the page
 - It is not always supported by OCR, crucial for complex layouts like newspapers
- Segmenetation of text into lines, words and characters

CKIE, *)

dzisiski, pulkownik wojsk "Alzyrę" (Warsz. 1780) li, był redaktorem kilku

ya Jana III. Niez. 01 i Katarayny Gerwanieo ayeka, 2do toto Maryanne ofrka Maryanna poślubiła

galie r. 1809, to samo - 'Do tego domu zlaje

dzie z przemyskim 1782. miał za sobą Zofią księżne komisarz do granie pruskiej go, z Zifii Pałezowskiej uro Nicz – Niewiadomo ury

Nicz. — Niewiademo er a Augusta. Erzz. wichojski nazwany, z Polsk vicz w karaniu Wyproscieni lotkuw, tam był ociadł; syr tego zaś syn Iwan, który Lituw się urzeniedł za Zy.

Polubinska splodnit ce zegorza i Teodora, oba

m ialem ludz Włoszech parenteli, cór yna Jana Alfonsa starce OO. Dominikanów w W

tseijanskim, 2do voto Teodor, Samuel i Pic



SZLACHECKIE.") AMILIE

L.

India w konst. r. 1790 fol. 227. Malach. neh Segresa h. Ludies 2 odmiana. Patra Szyrma. achnicki, w wilkomirskim itd. Malach. – Ignacy siemani, gub. grodzieński, pułkownik wojsk polikici, w róla Biograda udariowania i prati umatryl trogedrą Woltera "Alsyru" (Warz. 1780). Ignacy Emannel (ur. 1793 + 1825) synowice poprzedniego, dr. filozofi, był reduktorem kilku wasopism w Wilnie Inchiwicki Cradenicz, Kurpp. J. Mačach, Obacz Czechewicz, Lachawicki h. Zedzini, w crzaniskim pow. Z tych Fioty podpiał letekcya Jana III. Niez-Lachawicki h. Stepitate. Jan syn. Alexandra stebnika wielamkiego 1701 i Katarzyny Gerwanjec horodnitzy krzemieniecki, miał za sola Imo soto Maryanze Recerycka, 240 roto Maryanne owska, z pierwszej był syn Felir, którego z Klary Robezińskiej córka Maryanna poślubila Eachowiez h. Zodia. Leon udowidnił szlachectwo w wydz ile Stanów galie. r. 1809, to samo Wojewch (ale herb jego nie wyrażony) w sotzie z twowakim r. 1788. – Do tego domu zdaje sie nahriy Stanisław August, współczesny autor w Petersburgs achanics h. Radiean. Kurep. i Malach. Lachowski h. Nolecs. Tadeur i Mikolaj udowodnih szlachectwo w sądzie z. przemyskim 1782. Lachowski h. Pilojen, w sandomiorskiem i insvjeh województwach. N. mist za sobą Zafia księżne Waroniecky obołu r. 1520. Wojciech wojski z. wiskiej, z sejma 1591 komisarz do granic proskich od Marowsza. N pojął Łukowska, tórke Jana pisarza z krakowskiego, z Zofii Palczowskiej urodzona. Jan w saadomierskiem 1632. Jędrkej komernik czerski 1674. Nice – Niewiadomo czy do tych należał Schwetym jezuita, sławny kaznodzieja króla Stanisława Augusta. Kroze lacki h. ud. Antorowie naši pisze, że dawniejszy przedek tego domu Zawichojski nazwany, s Polski wynieślszy, w Moskwie byż osiadł, gdzie nazwony był Lackim, a Dolowier w kazaniu Woprawienie Okoy przydaje, że ten Zawichofski Zacharjasz peśluje z Polski do Moskwy, tam był osiadł; syn jego wodług niektórych. Jan Wasil Lacki sa cara Wasila Iwanowicza, tego zaż syn Iwan, który ulinarato zniešć tyranii Owczyny opiekuna mlodogo cara Iwana, do Litwy się przeniósł za Zy-gwana I króla polskiego, od którego wzisł dobra Zoludek i Wyzoki Dwór, sył praz leśniczym Podlaskių, mits wojenos i w sprawach rycorskich biegiy, z Bogdam Polubinską spiedził córke Torciesz za Eliaziem Pielprzymowskim pisorzem lit. i synów owich: Grzegosza i Torciera, obadwa byla dzielach, kowalerakiemi ustawieni, otobliwie jednak Torcier, którego krwawe i przewaine dzielu z poch wajominają Konzyc 1011 fol. 45 i 1013; umart z wielkim iniem ludzi rycer-tweb w Wilnie, zustawiwszy z Izabeji Bonarelli de Rovere, zmeznej we Wieszech perenteli, odrkę Ewareyne za Teodorem Tyszkiewiezem wojewodą nowogrofizkim i syna Jana Alforia stariete amudzk., raduńsk. i zoslański, również wojennego meża, ten fundował OO. Dominikanów w Wyzokim Dworze, żona jego Jeanna Talwoszówna, jedynatzka dirka Adama kasztelana żmudzkiego, 2 której opricz odrki luzbelli inio soto za Taofilem Teyrne skojowoda hrecácijańskim. 2do soto za Bierozimem Chodkiewiczem starosta mozyrakim, zostało syniw trzech: Teodor, Samnel i Piotr; minszezone w tomie



FAMILIE SZLACHECKIE.")

L.

Fahady. Josig, w komt. r. 1190 fol. 227. Molach.
Fach Syrras L. Lakier z edminar. Patra Sayras.
Fach Syrras L. Saker Z. Sayras.
Fach Syrras L. Sayras L. Sayras.
Fach Syrras L. Sayras L. Sayras L. Sayras.
Fach Syrras L. Sayras L.

*) Horby rodzin szlacheckich są umieszczone w tomie I.



FAMILIE SZLACHECKIE

Indig w konst. r. 1700 fol. 227. Malach

and menny whence for 1000 me. 2-47 Sections. Segress 2. Laborator a detainin. Tata Segrena in the section of the section of

L.

Applied, wrahl. *Mispredi substantia*, i grantitamateji impedje Wolfers, "Akrya" (Was giney Tasawigi (m. Th3 y History synonice paymotike), dr. Blakan, by Trediki Lacharieki (Azkanez, Korpa, i Malaki. Okaz Cerchertirz. Lacharieki (Azkanez, Korpa, i Malaki. Jaka (Korpa, Korpa, Ko

Deskew nieszczone w tomie Auto Manual -1.56°

Labady. Indig. w konst. r. 1790 fol. 227. Malach.

Lach Szyna h. Lubics z odmioso. Patrz Szyrma. Lachnicki, w wilkomirskim itd. Malash. — Ignacy ziemianin gub. grodzisiski, pułkownik wojak polskich, wydał Biogropie włościonina i przetiomaczył tragedyn Woltera, Alszyrę" (Warz, 1780). guary Emanuel (ur. 1793 + 1826) synowiec poprzedniego, dr. filozofii, był redaktorem kilku m w Wilnie.

L.

AMILIE SZLACHECKIE.")

Lacharicki Creckowaz, Kurop, i Madach, Obacz Czechowicz, Lacharicki L. Zedzka, w orzaniskim pow. Z tych Piotr podpiał elekcya Jana III. Niez. Lacharicki h. Szenisto. Jan zym Alexandra stolnika wielniskiego 1700 i Katorzyny Gorwanieokiej, borodulczy krzemieniecki, miał za sobą Joso soto Maryannę Rzeczycką, 2do toto Maryanną Bakowską; z pierwszej był syn Feliz, którego z Klary Rohozińskiej córka Maryanna poślubiła Adolfa Jolowickiego. Gen. Jelowickich.

achowicz h. Lodzia Leon udowodnił szlachostwo w wydziale Stanów galie r. 1809, to samo Wsjelech (ale herb jego nie wyrażony) w sądzie z lwowskim r. 1783. – Do tego domu zdaje

Wegicen (sie herb jego sie wyracowy) w sądzie z. twowskim 7. 1785. — Do tego domu zdaje ito należy Stanisław August, wysiołczeny zator w Petersburgu. Lachowski b. Radneas. Korop. i Małach. Lachowski b. Piłonow, w sandemierskiem i izszych wojewidztwach. N. misł za zobą Zofa kiejźne Waronieską około r. 1520. Wojciech wojski z. wiskiej, z sejam 1581. konisarz do grande prasideh od Maronieską około r. 1520. Wojciech wojski z. wiskiej, z sejam 1581. konisarz do grande prasideh od Maronieską około r. 1520. Wojciech wojski z. wiskiej, z sejam 1581. konisarz do grande prasideh od Maronieską około r. 1520. Wojciech wojski z. wiskiej, z sejam 1581. konisarz do grande prasideh od Mazawsza. N. pojął Łakowska, obrkę Jane pisarza z. krakowskiego, z Zefii Palezowskiej uro-dzony. Jan w sandomierskiem 1632. Jędzzej komornik ezerski 1674. Nies. – Niewiadamo czy do tych naledał Schastyan jezuita, sławny kaznodzieja króla Stanislawa Augusta. Kraz-

Larki h. to?. Autorowie nasi pisza, że dawniejszy przodek tego domu Zawichojski nazwany, z Polski wymedlezy, w Moskwie był osiadł, gdzie nazwany był Lackim, a Dudowier w kazaniu Wyprawienie Gody przydaje, że ten Zawichojski Zacharyasz posłując z Polski do Moskwy, tam był esiadł; syn Jeros przydaje, ze ten Zawiednjak Zacharyska postując z Polski do Moskwy, kam był cesadi jem jego według niektórych. Jan Waali Lacki za cura Wasila Ireanowien, tego zaś spi Iwan, który ubuogąc znieść tyranił Owczyny opiekuna młodego cara Iwana, do Litwy się przeniósł za Zy-gununa I króla polskiegy, od którego wzlął dobra Zołudek i Wysoki Dwór, był oraz leśniezym poślakim, maje wojenny i w sprawach rycerskich biegyr, z Bogtane Połsbińska spislakil córte Teodore za Eliszere Pielgrzymowskim pisarzem Ist, i synów dwóch. Grzegerza i Teodora, obadwa teli dobra barolicze i postowie za stary za spisarze i Teodora, obadwa yli dzielami kawalarskiemi wstawieni, osobliwie jednak Teodor, którego krwawe i przeważne drieła z pochwalą wspominają Konstyt 1611 fol. 45 i 1613; umarł z wielkim jałem ludzi rycer-thich w Wilnie, zostawiwszy z Izabeli Bonarelli de Rovere, znacznej we Wioszech parenteli, obrkę R starayne va Todořenu Tytalikow zeom wojewodą nowogredzkim i syma Jaza Alfonsa istarotne imučta, raduńsk, i zesłeńsk, również wojennego moża, ten fundował OO. Dominikanów w Wy-wkim Dworze; żona jego Janna Talwaszówna, jedynazska córka Adanek kazetelana źminiskiego, z której oprocz córki Istałelli Ano todo za Teolikem Togran, wojewodą birzskejańakim, 260 esto za Bioronimsem Chedkiewiczem starosta mosytakim, zostało synów trzech: Toodor, Samuel i Piotr

*) Horby ridzin salacheekich są umieszczone w tomie I.

MILIE SZLACHECKIE.*)

L.

konst. r. 1790 fol. 227. Malach.

2008. F. 1709 101. 2011. Autoen. bier z odniane, Patz Szyrma. mirakim id. Malach. — Ignacy ziemianiu gub. gredzieński, pułkownik wojak liografie udościanie i przedziomacył trzgadys Woltera "Alszyę" (Warz. 1780). (ar. 1733 † 1826) synowiec poprzedniego, dr. filozofii, był redaktorem kilku

hogrady włościowani i przeklawany i trządyt Woltra "Atywy" (Warz. 1780). (zr. 1736 + 1986) synowie z poprzekniny, d. Eksoni, byt redskown klika-cie. Krony, i Molech. Okarz Czrchowitz. (int. wtrastki mow. Z tych Jorb redpisał debry Jana III. Nie. Isto. Jaz yn Akzadira stelałka wkiatkiego 1701 i Karzyny Gerwale-meniesieki, mi za ska, Anov ok Mayrang Exeryck, 26 et ok. Mayrang wan juj ny Tel. Isto. Jaz yn Akzadira stelałka wkiatkiego 1701 i Karzyny Gerwale-mi stelawa stelawa stelawa stelawa stelawa stelawa stelawa wan juj ny Tel. Isto. Losa udwodni stelaciewa w wydale Stanow galic. 1 1800, i o zmo-jego nie wyrzieczy w udkie s. Iwwakie r. 1783. — Do tego dam z dalu w Argut, wzgołaczany asite y Peterkurgu. m. Krop. 1 Moled. n. wandeniemiemi innych ujereditarzak. N. miał za oka Zak kujeże r. 1820. Wojsceł wojali z wkieja z sojno 1301 komian do granie przak w okarcze i sojna kranka stelawa z krawka stelawa stelawa stelawa nie naj stelawa stelawa stelawa stelawa stelawa stelawa stelawa naj w stelawa stelawa stelawa stelawa stelawa stelawa stelawa naj w stelawa stelawa stelawa stelawa stelawa stelawa stelawa stelawa naj w stelawa na stelawa stelaw

izin szlacheckich sa umieszczone w tomie I.



FAMILIE SZLACHECKIE.")



FAMILIE SZLA L. dy. Jodig, wknyst r. 1790 fal, 227. Molach, Szyrana h. Lubácz s cómiase. Patra Szyrma, nicki, w wilszmirálim id. Molach. – Iguary tá Mich, wydał Biografie wcócionimie i przetkomacyji tá try Ezanutel (ur. 1723 † 1826) synowiec poprzedm mjórn w Wilde.

any Danaed (ar. 1703 + 1980) synwhite paradial angel w Wilds, and Edi Koraya J Mahoh. Obser Chells and Edi Korahamiza. Koraya J Mahoh. Obser Chells and Santa La ya Alamana ta toka a sense a second secon the product and without Ministry of the second seco

*) Herby ridzin salacheekich są umieszczone w

L.

Labady. Indig. v konst. r. 1790 fol. 227. Malach. Lach Szyrma h. Lubics z odmianą. Patrz Szyrma.

Lachnicki, w wilkowirskim itd. Malach. — Ignacy ziemianiu gub. gredzieński, pułkownik wojak półskich, wydał Biografią włościanimi i przetiomaczył tragedyą Woltera "Alzyrę" (Warsz. 1780). Ignacy Emanuel (ur. 1793 † 1826) synowiec poprzedniego, dr. filozofii, był redaktorem kilku Satopism w Wilnie.

Lachowicki Czechowicz. Kurop. i Małach. Obacz Czechowicz. Lachowicki h. Zodsia, w orzzańskim pow. Z tych Piotr podpiał elekorą Jana III. Nies. Lachowicki h. Sizsietka. Jan syn Alexandra stolnika wjelinskiego 1701 i Katarzyny Gorwaniec-Jachmer Perk I. Streinburg, Jan syn Astrangta stoinita wiedinistigo 1101 I Estistryny Gorwander-kiej, horodniczy krzemieniecki, mieł ta sobą Jno oto Maryanne Reczycka, 2do oto Maryanne Bakowska; z pierwszej był syn Felix, którego z Klary Rohosińskiej ofrka Maryanna poślubila Adolfa Jołowickiego. Gen. Jełowichich. Jackowich k. Kodris. Lesn udowodnił szlachertwo w wydziale Stanów galie. r. 1809, to samo Wyljotch (ale herb jego nie wyrażony) w sudzie z Iwowskim r. 1783. – Do tego demu zdaje tik naloże Stanisław Acarat wrachowych w Połacharow.

tiš należy Staniaław August, współczesny sutor w Petersburgu. Lauhowsticz h. Rotham. Karop. i Medech. Jaułowski h. Najezz. Taławz i Micolaj udowodnih salachestwo w sądzie z. przemyskim 1782.

- Lachowski b. Pilowa, w zaudomierskiem i inszych województwach. N. miał za sobą Zofią księżne Wereniecka około r. 1529. Wojciech wojski z. wiskiej, z sojmu 1591 komisarz do granic pruskich od Mazowsza. N. pojął Eukowską, córkę Jana pisarza z krakowskiego, z Zofi Palczowskiej uro-dzeną. Jan w sandomierskiem 1632. Jędrzej komornik czerski 1674. Niez. – Niewiadomo czy do tych należał Sebastyan jezuita, slawny kaznodzieja króla Stanislawa Augusta. Kros.
- Lacki h. ud. Autorowie nasi pisro, że dawniejszy przodek tego domu Zawichojski nazwany, z Polski wyszedlszy, w Moskwie był osiadł, gdzie nazwany był Lackim, a Dubowies w kazaniu Wyprawienie Osoby przydaje, że ten Zawichojski Zacharyasz posłując z Polski do Moskwy, tam był osiadł; syn jego wodług niektórych, Jan Wasil Lecki za cara Wasila Iwanowicza, tego zaś syn Iwan, który ulemogac mieść tyranii Owczyny opiekuna młodego cara Iwana, do Litwy się przenidsł za Zy-gwunta I króla polskiego, od którego wział dobra Zołudek i Wysoki Dwór, był craz leśnierzy podlackim, mąż wojenny i w sprawach rycerskich biegły, z Bogdaną Połubińską spłodził córkę Teodorę za Eliaszem Pielgrzymowskim pisarzem lit i synów dwóch: Grzegorza i Teodora, obadwa Periody iz Linkeeni reigrepmowskim prazizim in i synow urodni ofrzegorza i leodora, odalow byli drziejami kuwalerskiemi walawieni, coobliwie jodnak Toodor, którego krwawe i przoważac dziela z pochwalą wspominają Konzyst 1611 fol. 45 i 1613; umark z wielkim ialem ludzi ryzer-skieh w Wilnie, zostawiwszy z Izabeli Bonareli de Rovrez, maznej we Wioszech paronzeli, dorkę Katarzyne za Toodorem Tyszkiewiczem wojewodą nowegrodzkim i syna Jana Alforsa starostę imachi. źmudzk., raduńsk. i zosleńsk., również wojennego mężn, ten fundował OO. Dominikanów w Wysokim Dworze; żona jego Joanna Talwoszówna, jedynaczka córka Adama kasztelana źmudzkiego, z której oprócz córki izabelli Imo voto za Teofilem Toyzną wojewodą brześcijańskim, 2do voto za Bieronimem Chodkiewiczem starostę mozyrskim, zostało synów trzech: Teodor, Samuel i Piotr;

*) Horby rodzin szlacheckich są umieszczone w tomie I.



How does OCR works? (2)

- Character recognition by comparision with pattern database
 - If pattern database does not contain given character, OCR will try to match it to "something" which is similar
- Preparation of final text
 - Combining characters into words and lines according to original order of text
 - Comparing words with a dictionary, spelling correction possible



Q.	en Coli VI Free OCK Software
File OCR. Text Settings Holp	
Sean Open ROM OCK OCK Open Hele Ock	
** 4 1 8 8 5 4	Termin szermierka be "trafić, nie będąc trafionym". W ninie w wykonywaniu działań i mistrzostwo we mierzających do d "trafić, nie będąc trafionym". W ninie w wykonywaniu działań i mistrzostwo we mierzających do d "trafić, nie będąc trafionym". W ninie stawy trate, nie bądąc trafionym ". W ninie stawy trate, nie bądąc trafionym". W ninie stawy trate, nie bądąc trafionym ". W ninie stawy trate, nie bądąc trafionym". W ninie trate spłasobje '
	działanie twórcze, walk szybkość postrzegania "traiié, nie będąc trai10nym"_ \V minie ^{Ostrzego} cs11.1_W nasłe antazia, witulizeta i
	intelektów, rozmowa bez słów, "gra w sz estetyka w wś. "1<01"/wa n tu świczemi zmierzajacych d2 dDS1[011&1"05C1- a nawet "1.=agi1tacji"_ W tym rozumetti u szemnerka jest nie tylk0 zwy1 dym=
	Istotę współczesne jest według zasad w wykonywaniu działań i mistrzostwo majwiszych sukesciw Natyle Indice Usco- w w5 *1<0r1* navo11i u dZ18 1`d t:1 i 1:rric 1:rz0 ctw0 s zaldam jego
20.0	Pod względen w w5, T<0TT ywaThTu dz T&T d.t, TT T.MST.120StW0 przełomy w historii naszego kraju (przejś ponrzednimi okresami Zasież tervtorialn * *
Image size 1219 - 5%	



OCR – quality of results

- Quality of print and general state of the document
 - OCRs perform much better on modern printed texts
- Scanning resolution and color depth
 - >300 PPI, color depth 1 BPP
- Language of text, alphabet and font



OCR – quality of results (2)

- Text layout
 - Different in books and in newspapers
 - If layout analysis is done in a wrong way, text flow is broken
- Text formatting
 - Appropriate spacing between letters, lines and page boundaries



File formats

- Digital text can be stored as simple plain text files
 - Choose encoding wisely
 - No information about original features of the text (layout, formatting, illustrations)
- Other solutions: HTML (EPUB), PDF or DjVu
- PDF and DjVu are relatively complex file formats, allowing to:
 - Embed original image as a background for text
 - Add annotations, bookmarks
 - Optimize for web delivery



PDF

- Portable Document Format (PDF) is an open standard
- Created by Adobe Systems in 1993
- Aimed to decouple document representation from application, hardware and operating systems
- Fully featured and widely known



DjVu

- Designed to store scanned documents
 - Especially those containing a combination of text, line drawing and photographs
- Similar features as PDF, but:
 - DjVu document can be splitted into multiple files
 - Ususally smaller files
- Limited adoption in recent year
 - Text is not indexed by Google
 - Requires web browser plugin



Agenda (2)

- A few words about digitisation hardware and software
 - Including a quick tour through the e-learning course
- Case study: "OCR in Poland"
- Discussion



Agenda (2)

- A few words about digitisation hardware and software
 - Including a quick tour through the e-learning course
- Case study: "OCR in Poland"
- Discussion



OCR in Polish digital libraries

- Survey was held in September-October of 2010
- We received responses from 26 major institutions
- Survey covered 70% of resources gathered by Polish Digital Libraries Federation
- We were asking about all sort of things related to creation of full text search
 - Type and number of documents
 - Digitisation practices
 - Usage of OCR software



OCR in Polish digital libraries (2)

- 40% of objects were a subject of OCR
- No one does the correction of OCR results
- Scanning resolution between 300-600 PPI, colour depth depends on type of resource and purpose of digitisation
- FineReader and Document Express are most widely used software packages
- Only 3 institutions use training capabilities of OCR software



OCR in Polish digital libraries (3)

- Used OCR software
 - Document Express
 - ABBYY products
 - Omnipage (1 institution)
- Input formats
 - TIFF (25 institutions), DjVu (17), JPEG (5)
- Output formats
 - DjVu, PDF
 - ABBY Finereader XML (5 institutions)



Agenda (2)

- A few words about digitisation hardware and software
 - Including a quick tour through the e-learning course
- Case study: "OCR in Poland"
- Discussion



Discussion

Any thoughts, questions?



Discussion

- What are scenarios for digitisation in small memory institution?
- What software is used in your library?



References

- Lessons from DRMSI course:
 - "What should I know about digitisation equipment?"
 - "What should I know about software used in digitisation process?"
 - "What is the rationale for digitisation activities in the cultural heritage domain?"