

Towards General Document Understanding through QA


Šárka Ščavnická, Michal Štefánik, Marek Kadlčík,
Martin Geletka, Petr Sojka
527352@mail.muni.cz, sojka@fi.muni.cz

Math Information Retrieval Research Group,
Faculty of Informatics, Masaryk University

December 9th, 2022

Motivation

Model Description




Competitive system for the English language

1. Select a file

Gallery

INVOICE
Clear



2. Ask a question

Question

What is the invoice number?

Model



Clear

Submit

Top Answer

US-001

Thank you

TERMS & CONDITIONS

Payment is due within 15 days

Please make checks payable to: East Repair Inc.

Textual Representation of the Invoice

- FAKTURA - DAŇOVÝ DOKLAD © číslo: (25 Dodavatel | IČO 42993865 DIČ |CZ6804111963| Variabilní symbol 25 Josef Sedlář Konstantní symbol [0308 Josef Sedlář Specifický symbol , Podolí 88 Částka 78438.00 Kč 789 85 Mohelnice Peněžní ústav KB Mohelnice Objednávka Číslo účtu (100 Číslo fixmy 00024 Příjemce Odběratel IČO Drč Kamil Sedlář Kamil Sedlář Staškova 55 Staškova 55 789 85 MOHELNICE 789 85. MOHELNICE Platební Den splatnosti 24.10.2009
 - Who is the supplier, and what is his address?

Textual Representation of the Invoice

- FAKTURA - DAŇOVÝ DOKLAD © číslo: (25 **Dodavatel** | IČO 42993865 DIČ
| CZ6804111963| Variabilní symbol 25 Josef Sedlář Konstantní symbol [0308 Josef
Sedlář Specifický symbol , Podolí 88 Částka 78438.00 Kč 789 85 Mohelnice Peněžní
ústav KB Mohelnice Objednávka Číslo účtu (100 Číslo fixmy 00024 Příjemce
Odběratel IČO Drč Kamil Sedlář Kamil Sedlář Staškova 55 Staškova 55 789 85
MOHELNICE 789 85. MOHELNICE Platební Den splatnosti 24.10.2009
 - Who is the supplier, and what is his address?
 - We need more context

Visual Representation of the Invoice

FAKTURA - DAŇOVÝ DOKLAD		číslo: 25	(9)		
Dodavatel IČO 42993865 DIČ CZ6804111963 Josef Sedlář Josef Sedlář Podolí 88 789 85 Mohelnice Pendžní ústav Kč Mohelnice Číslo doku 43-3975450267/0100	Variabilní symbol 25 Konsantní symbol 0308 Specifický symbol Částka =78438.00 Kč				
Příjemce Kamil Sedlář Staňkova 55 789 85 MOHELNICE	Objednávka Číslo firmy 00024	Odberatel IČO Kamil Sedlář Staňkova 55 789 85 MOHELNICE	DIČ		
	Platební podmínky Den splatnosti 24.10.2009	Způsob úhrady v hotovosti Datum vystavení dokladu 14.10.2009 Datum uskutečnění zdanitelného plnění 14.10.2009			
Položka	(ceny v Kč bez daně)	JednCena	Množství	CelkCena	DPH
Fakturujeme Vám stavební práce					
stavební práce	150.00	24.000	hod	3600.00	9%
materiál f. 2913000010	61374.00	1.000	Kč	61374.00	9%
materiál f. 3001537373	6987.39	1.000	Kč	6987.39	9%
celkem				71961.39	Kč
	seznam snižená	bez daně	DPH	s daní	
		71961.39	6476.53	78437.92	9%
k úhradě	(zaokrouhlení +0.08)	78438.00	Kč		
*Záv. list 11.12.2008, č.j.: ZJ/642/2008/U/11					
Počet stran 1 Vlastník: Karelina Balánska	Josef SEDLÁŘ 789 85 Mohelnice, Podolí 88 ...na 1. patra, U Mýta 97				

Text Representation of the Invoice with the Visual Knowledge

- Who is the supplier, and what is his address?
- FAKTURA - DAŇOVÝ DOKLAD © číslo: (25 **Dodavatel** | IČO 42993865 DIČ
| CZ6804111963| Variabilní symbol 25 **Josef Sedlář** Konstantní symbol [0308 **Josef
Sedlář** Specifický symbol , **Podolí 88** Částka 78438.00 Kč **789 85 Mohelnice** Peněžní
ústav KB Mohelnice Objednávka Číslo účtu (100 Číslo fixmy 00024 Příjemce
Odběratel IČO Drč Kamil Sedlář Kamil Sedlář Staškova 55 Staškova 55 789 85
MOHELNICE 789 85. MOHELNICE Platební Den splatnosti 24.10.2009
- Better results if we use the visual layout of the document

Methods and Datasets

Question Answering

- Two types:
 - Extractive QA
 - Generative QA
- Multilingual datasets, primarily in English
- Datasets:
 - Stanford Question Answering Dataset (SQuAD)
 - Wikipedia articles
 - French Question Answering Dataset (FQuAD)
 - Wikipedia articles

Visual Question Answering

- Focusing only on the visual part of an image
- We can use the same images for different languages
- Datasets:
 - Visual Question Answering (VQA) dataset
 - The Image-Set Visual Question Answering (ISVQA)

Named Entity Recognition

- Aims to locate and identify entities in the given text
- Datasets:
 - CoNLL-2003 dataset
 - English and German
 - Newspaper articles
 - Few-NERD
 - Wikipedia articles
 - Dataset of German Legal Documents for NER
 - Non-English
 - Legal documents

Document Visual Question Answering


- Combines the visual and textual sides of a document
- Lacking coverage of non-English models for Document Visual Question Answering
- Datasets:
 - DocVQA
 - From the UCSF Industry Documents Library
 - Contains invoices
 - Documents are from the period between 1960 and 2000
 - Visual Machine Reading Comprehension (VisualMRC)
 - Consisting of screenshots of web pages

Dataset creation

Invoices - 6,849 documents and 15 entities

FAKURA - DAŇOVÝ DOKLAD		číslo: 25 (9)			
Dodavatel IČO 42993865 DIČ CZ6804111963 Josef Sedlář Josef Sedlář Podolí 88 789 85 Mohelnice Peněžní účet Kč Mohelnice Číslo účtu 43-3975450267/0100	Variabilní symbol 25 Konstantní symbol 0308 Specifický symbol Částka = 78438.00 Kč				
Příjemce Kamil Sedlář Staškova 55 789 85 MOHELNICE	Odběratel IČO Kamil Sedlář Staškova 55 789 85 MOHELNICE	Objednávka Číslo firmy 00024			
	Platební podmínky Den splatnosti 24.10.2009	Způsob úhrady Datum vystavení dokladu 14.10.2009 Datum uskutečnění zdanitelného plnění 14.10.2009	v hotovosti 14.10.2009		
Položka	(ceny v Kč bez daně)	JednCena	Množství	CelkCena	DPH
Fakturujeme Vám stavební práce					
stavební práce	150.00	24.000 hod	3600.00	9%	
materiál f. 2913000010	61374.00	1.000 Kč	61374.00	9%	
materiál f. 3001537373	6987.39	1.000 Kč	6987.39	9%	
celkem	71961.39		71961.39	Kč	
	součet snížení	bez daně 71961.39	DPH 6476.53	s daní 78437.92	9%
k úhradě	(zakrkouhlení +0.08)				78438.00 Kč
*Zivn. list 11.12.2008, č.j.:ZJV/642/2008/U/11					
Počet stran 1	Josef SEDLÁŘ 789 85 Mohelnice, Podolí 88 Místa 97				

Dataset Description



Research Proposal

How can Textual QA and Visual QA datasets improve Document Understanding?

First Question

- Our model will be trained on the Czech Document VQA dataset
 - A large number of relevant but narrow questions
- Hypothesis:
 - If we first introduce our model to much more general and comprehensive QA datasets
 - More robust in the unseen evaluation scenarios
 - Perform better

**How well can Document VQA models
generalize beyond training entity types?**

Second Question

- Conventional Named Entity Recognition models
 - A closed set of entity types present in the training set
 - Must be retrained when a new entity needs to be recognized
- Document VQA
 - A closed set of questions
 - Retraining?
 - How well our model can generalize to unseen entities?

How much can Document VQA in non-English languages benefit from English datasets?

Third Question

- Compare the model performance on a target language
- Train on:
 - Only English data
 - A mixture of English and the target-language data
 - Only the target-language data
- The evaluation of the approach will assess the applicability of our models to unseen language

MUNI
FACULTY
OF INFORMATICS