

# Jak pracuje automatický překlad

Ondřej Bojar

[bojar@ufal.mff.cuni.cz](mailto:bojar@ufal.mff.cuni.cz)

Ústav formální a aplikované lingvistiky  
MFF UK

ELRC Workshop, 14. duben 2016

# Osnova

- ▶ Úloha strojového překladu.
- ▶ Obtížnost překladu.
- ▶ Přístupy ke strojovému překladu.
  - ▶  Hloubkový překlad.
  - ▶  Frázový překlad
  - ▶  Automatické opravy chyb.
- ▶ Shrnutí.

# Úloha strojového překladu

布拉格城市公共交通包括：城市火车、地铁、有轨电车、  
公共汽车。地铁一共有A、B、C三条线，纵横交错贯穿整  
个布拉格，三条地铁线在市中心都可以互相交错转换。

# Úloha strojového překladu

布拉格城市公共交通包括：城市火车、地铁、有轨电车、  
公共汽车。地铁一共有A、B、C三条线，纵横交错贯穿整  
个布拉格，三条地铁线在市中心都可以互相交错转换。

Prague city public transport, including: City train, subway,  
rail trams, buses. Metro, a total of A, B, C three lines,  
criss-cross throughout Prague, three subway lines cross each  
other in the city center can be converted.

# Úloha strojového překladu

布拉格城市公共交通包括：城市火车、地铁、有轨电车、  
公共汽车。地铁一共有A、B、C三条线，纵横交错贯穿整  
个布拉格，三条地铁线在市中心都可以互相交错转换。

Prague city public transport, including: City train, subway,  
rail trams, buses. Metro, a total of A, B, C three lines,  
criss-cross throughout Prague, three subway lines cross each  
other in the city center can be converted.

Praha městská hromadná doprava, včetně: městský vlak,  
metro, tramvaj, autobus. Metro, celkem A, B, C tři řádky,  
křížem krážem po celé Praze, tři linky metra kříží v centru  
města může být převeden.

# Úloha strojového překladu



French Czech English

Patient operated Somel doctor.

Dr. Koutsky patient operated.

Dr. Smith operated on the patient.

# Úloha strojového překladu

File Edit View History Bookmarks Tools Help

translate.google.com/#auto/en/Uvidíme se v Plzni%3F%0AUvidíme se v Plzni.

+You Search Images Maps Play YouTube News Gmail Drive Calendar More ▾

Google ondrej.bojar@gmail.com

Translate From: Czech - detected To: English Translate

English French Spanish Czech - detected Czech English French

Uvidíme se v Plzni?  
Uvidíme se v Plzni. X

See you in Pilsen?  
See you in London. (dropdown menu) ✓

Turn off instant translation About Google Translate Mobile Privacy Help Send feedback

# Jakou kvalitu lze očekávat

- ▶ Srozumitelné, s hrubými chybami.
- ▶ Vhodné k úpravám (posteditaci).
- ▶ Vhodné k vydání.

# Jakou kvalitu lze očekávat

- ▶ Srozumitelné, s hrubými chybami.
  - ▶ Google Translate, Microsoft Bing, ...
  - ▶ ÚFAL Moses:  
<http://lindat.mff.cuni.cz/services/moses/>
- ▶ Vhodné k úpravám (posteditaci).
- ▶ Vhodné k vydání.

# Jakou kvalitu lze očekávat

- ▶ Srozumitelné, s hrubými chybami.
  - ▶ Google Translate, Microsoft Bing, ...
  - ▶ ÚFAL Moses:  
<http://lindat.mff.cuni.cz/services/moses/>
- ▶ Vhodné k úpravám (posteditaci).
  - ▶ Množství nástrojů pro podporu překladu (CAT).
  - ▶ Strojový překlad výrazně obohacuje překladovou paměť.
- ▶ Vhodné k vydání.

# Jakou kvalitu lze očekávat

- ▶ Srozumitelné, s hrubými chybami.
  - ▶ Google Translate, Microsoft Bing, ...
  - ▶ ÚFAL Moses:  
<http://lindat.mff.cuni.cz/services/moses/>
- ▶ Vhodné k úpravám (posteditaci).
  - ▶ Množství nástrojů pro podporu překladu (CAT).
  - ▶ Strojový překlad výrazně obohacuje překladovou paměť.
- ▶ Vhodné k vydání.
  - ▶ I dnes jen velmi úzké oblasti (předpověď počasí).

# Chyby dělají i lidští překladatelé

Základem tohoto loga je Nebojsa, postava Alsasana získaná Thomasem Fentimanem dvakrát při profesionálních zkouškách Crufts Obedience Test.

# Chyby dělají i lidští překladatelé

Základem tohoto loga je Nebojsa, **postava Alsasana** získaná Thomasem Fentimanem dvakrát při profesionálních zkouškách Crufts Obedience Test.

The Fentimans Logo is based on Fearless,  
Thomas Fentiman's prize Alsatian,  
double winner of the Crufts Obedience Test.

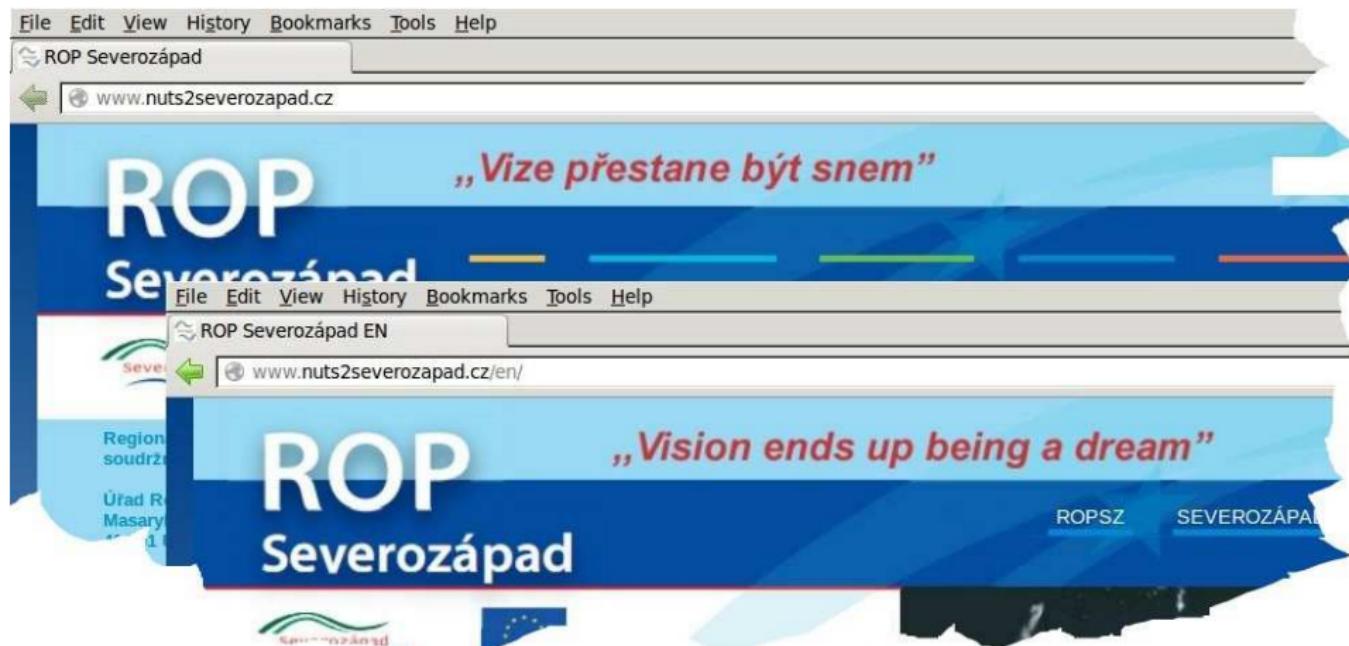
# Chyby dělají i lidští překladatelé

Základem tohoto loga je Nebojsa, **postava Alsasana** získaná Thomasem Fentimanem dvakrát při profesionálních zkouškách Crufts Obedience Test.

The Fentimans Logo is based on Fearless,  
Thomas Fentiman's prize Alsatian,  
double winner of the Crufts Obedience Test.



# Chyby dělají i lidští překladatelé



... nuts2severozapad.cz ... Vize skončí jako sen.

# Proč je překlad těžký

Na vstupu víceznačnost všeho druhu:

The plant is next to the bank.

# Proč je překlad těžký

Na vstupu víceznačnost všeho druhu:

The **plant** is next to the **bank**.  
*rostlina? továrna?*                    *banka? břeh?*

# Proč je překlad těžký

Na vstupu víceznačnost všeho druhu:

The **plant** is next to the **bank**.  
*rostlina? továrna?*                    *banka? břeh?*

Put it on the **rusty coat rack**.

... *rezavá police na kabáty?*  
... *police na rezavé kabáty?*

# Proč je překlad těžký

Na vstupu víceznačnost všeho druhu:

The **plant** is next to the **bank**.  
*rostlina? továrna?*                    *banka? břeh?*

Put it on the **velvety coat rack**.

... *sametová police na kabáty?*  
... *police na sametové kabáty?*

# Proč je překlad těžký

Na vstupu víceznačnost všeho druhu:

The **plant** is next to the **bank**.  
*rostlina? továrna?*                    *banka? břeh?*

Put it on the **velvety coat rack**.  
... *sametová police na kabáty?*  
... *police na sametové kabáty?*

Z češtiny to není lepší:

Spal celou Petkevičovu přednášku.  
Ženu holí stroj.

# Proč je překlad těžký

Na vstupu víceznačnost všeho druhu:

The **plant** is next to the **bank**.  
*rostlina? továrna?*                    *banka? břeh?*

Put it on the **velvety coat rack**.

... *sametová police na kabáty?*  
... *police na sametové kabáty?*

Z češtiny to není lepší:

Spal celou Petkevičovu přednášku.

Ženu holí stroj.



# Proč je překlad těžký

Na vstupu víceznačnost všeho druhu:

The **plant** is next to the **bank**.  
*rostlina? továrna?*                    *banka? břeh?*

Put it on the **velvety coat rack**.

... *sametová police na kabáty?*  
... *police na sametové kabáty?*

Reálné věty jsou stejně těžké:

SRC	One tap and the machine issues a slip with a number.
REF	Jedno čuknutí a ze stroje vyjede papírek s číslem.

---

Moses 1 Z jednoho **kohoutku** a stroj vydá složenky s číslem.

Moses 2 Jeden **úder** a stroj vydá složenky s číslem.

Google Jedním klepnutím a stroj **problémy skluzu** s číslem.

# Při překladu se možnosti násobí

I	saw	two	green	striped	cats	.
já	pila	dva	zelený	pruhovaný	kočky	.
	pily	dvě	zelená	pruhovaná	koček	
	...	dvou	zelené	pruhované	kočkám	
	viděl	dvěma	zelení	pruhovaní	kočkách	
	viděla	dvěmi	zeleného	pruhovaného	kočkami	
			zelených	pruhovaných		
	uviděl		zelenému	pruhovanému		
	uviděla		zeleným	pruhovaným		
			zelenou	pruhovanou		
	viděl jsem		zelenými	pruhovanými		
	viděla jsem		...	...		

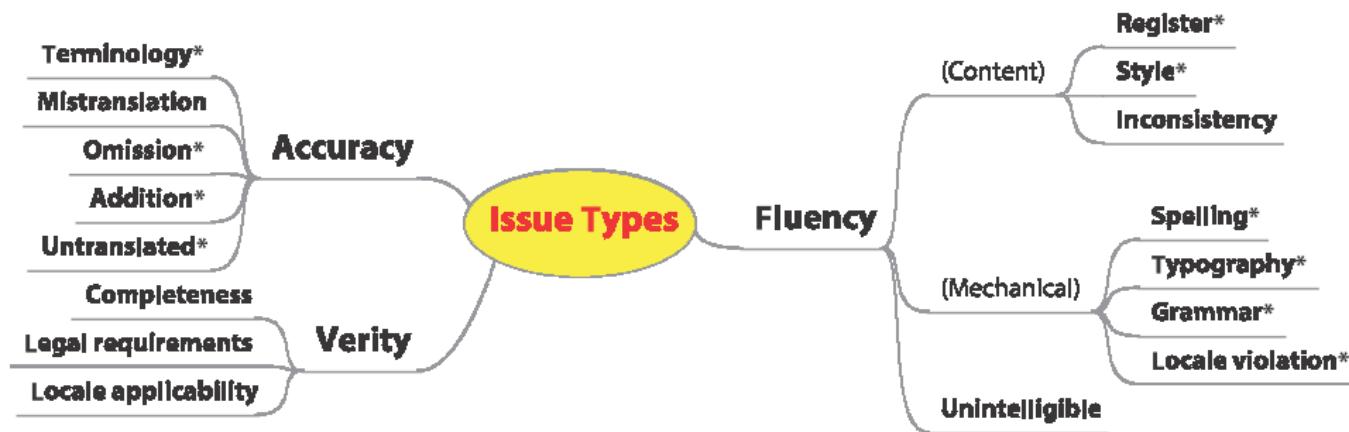
# Do češtiny navíc musíme trefit tvar

I	saw	two	green	striped	cats	.
já	pila	dva	zelený	pruhovaný	<b>kočky</b>	.
	pily	<b>dvě</b>	zelená	pruhovaná	koček	
	...	dvou	<b>zelené</b>	<b>pruhované</b>	kočkám	
	viděl	dvěma	zelení	pruhovaní	kočkách	
	viděla	dvěmi	zeleného	pruhovaného	kočkami	
	...		zelených	pruhovaných		
	uviděl		zelenému	pruhovanému		
	uviděla		zeleným	pruhovaným		
	...		zelenou	pruhovanou		
<b>viděl jsem</b>			zelenými	pruhovanými		
viděla jsem			...	...		

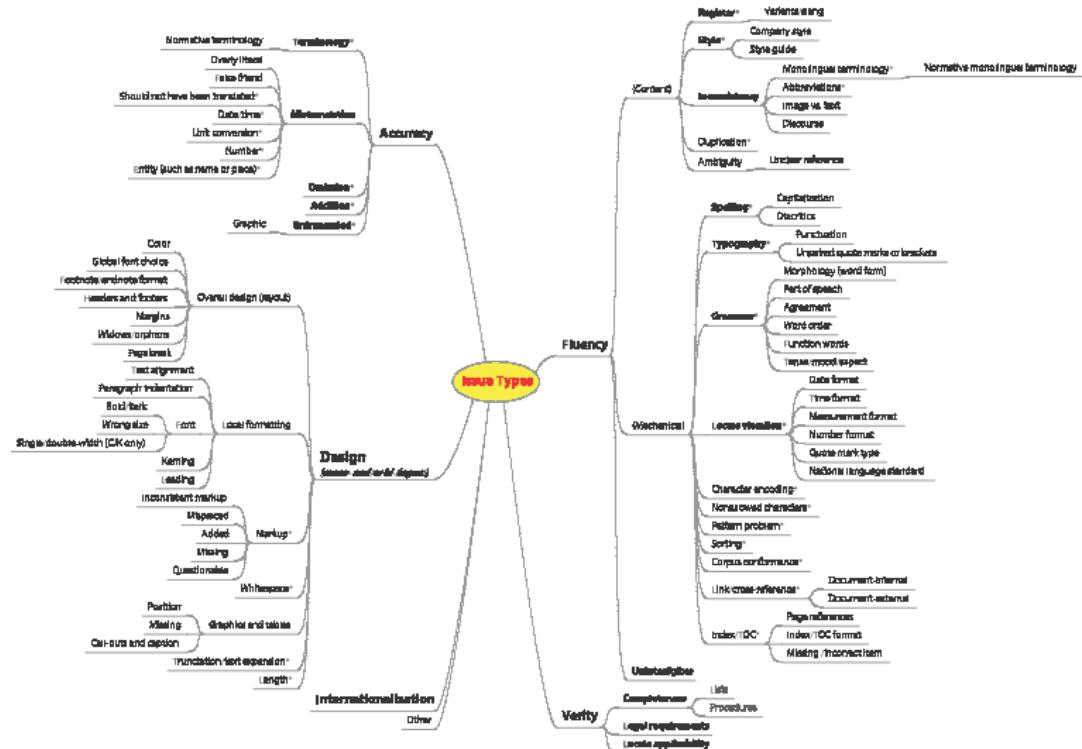
... ale tvar závisí na kontextu...

I	saw	two	green	striped	cats	.
já	pila	dva	zelený	pruhovaný	<b>kočky</b>	.
	pily	<b>dvě</b>	zelená	pruhovaná	koček	
	...	<b>dvou</b>	<b>zelené</b>	<b>pruhované</b>	kočkám	
	viděl	dvěma	zelení	pruhovaní	<b>kočkách</b>	
	viděla	dvěmi	zeleného	pruhovaného	kočkami	
	...		<b>zelených</b>	<b>pruhovaných</b>		
<b>zrak mi utkvěl na</b>			zelenému	pruhovanému		
...			zeleným	pruhovaným		
<b>viděl jsem</b>			zelenou	pruhovanou		
viděla jsem			zelenými	pruhovanými		
			...	...		

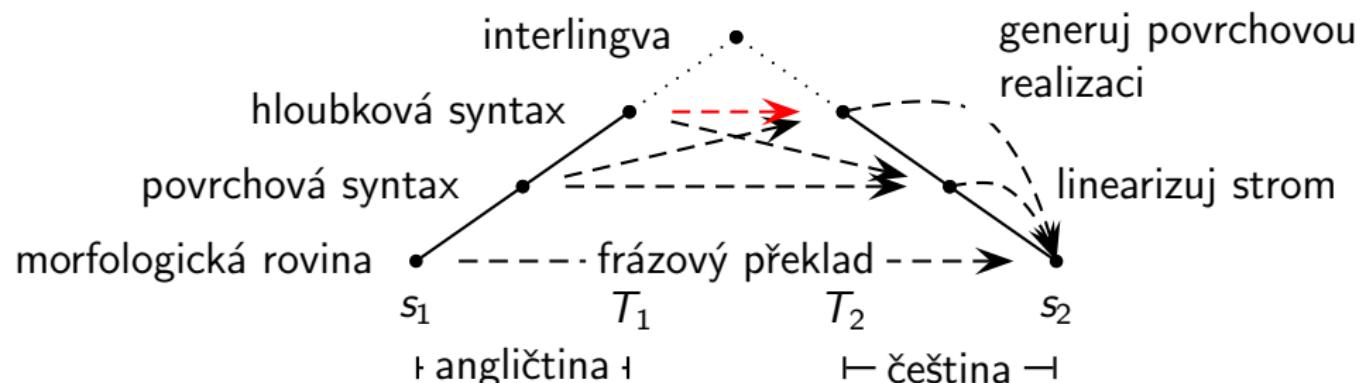
# Co všechno může být špatně



# Co všechno může být špatně



# Přístupy ke strojovému překladu



- ▶ Čím víc vstup rozeberu, tím snazší by měl být transfer.
  - ▶ Rozbor ovšem také není snadný.
  - ▶ Navíc čelím kumulaci chyb.
- ▶ Pravidlový vs. statistický přístup:
  - ▶ Pravidlové systémy píší lingvisté-programátoři.
  - ▶ Statistické systémy se naučí samy podle dat.



## Překlad přes hloubkovou rovinu TectoMT

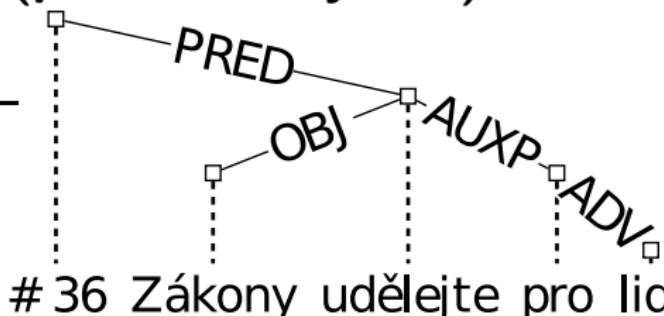


# Formální popis češtiny

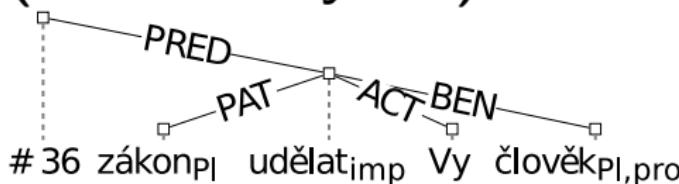
## Analytická rovina (povrchová syntax):

### Morfologická rovina:

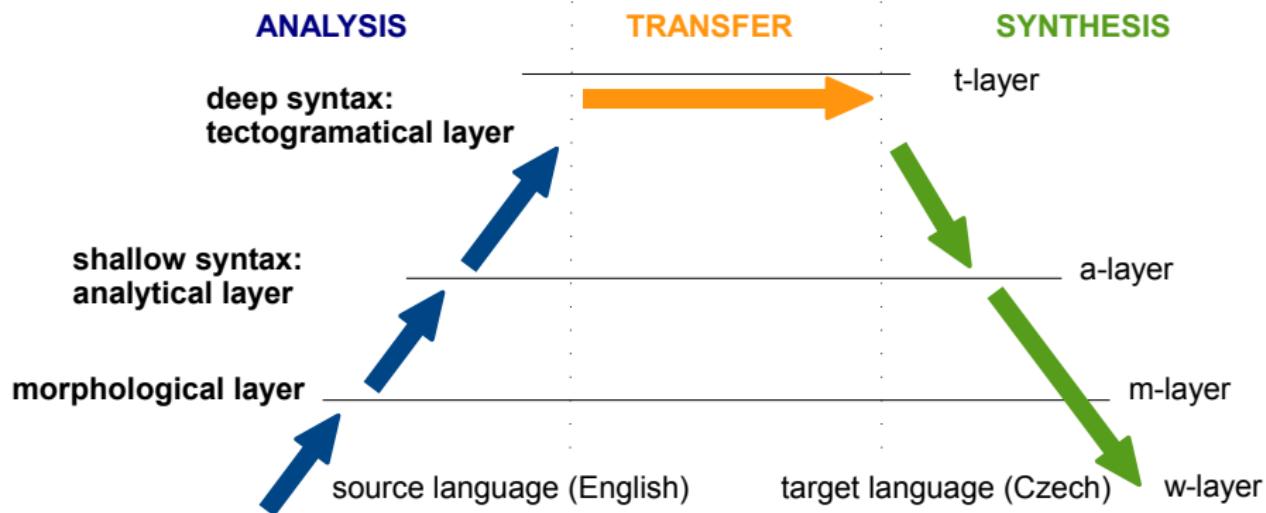
Slovo	Lema	Morfologická značka
zákony	zákon	NNIP1----A----
zákony	zákon	NNIP4----A----
zákony	zákon	NNIP5----A----
zákony	zákon	NNIP7----A----
udělejte	udělat	Vi-P---2-A----
udělejte	udělat	Vi-P---3-A---4
pro	pro-1	RR--4-----
lidi	člověk	NNMP1----A----
lidi	člověk	NNMP4----A----
lidi	člověk	NNMP5----A----



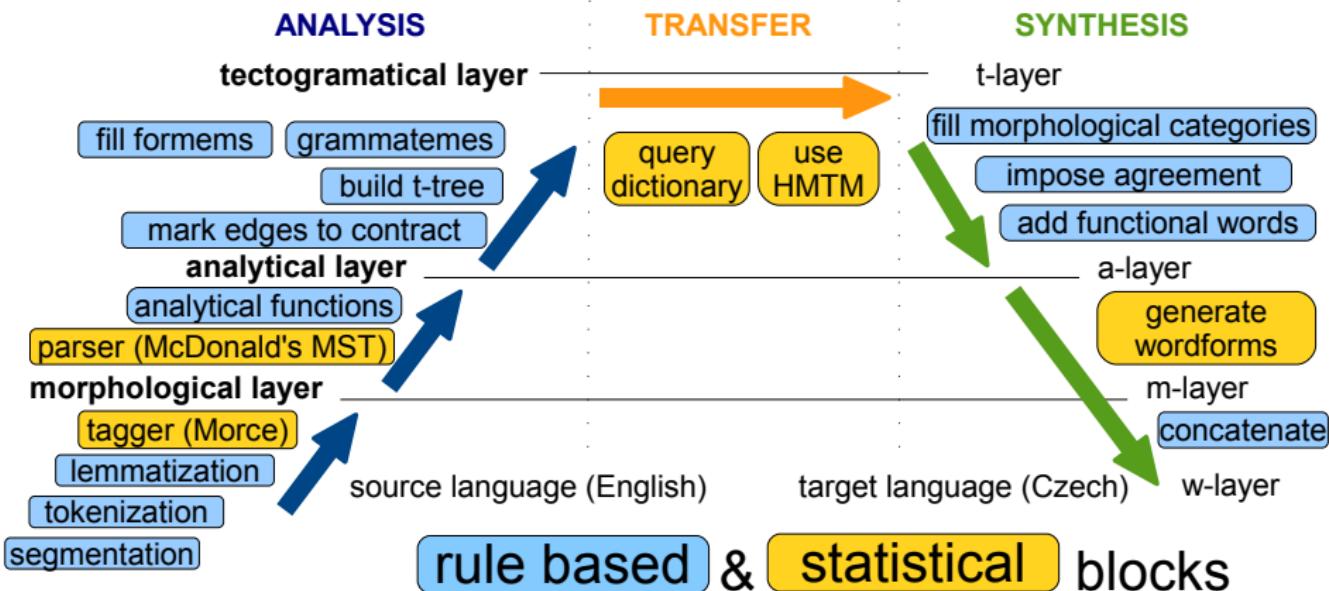
## Tektogramatická rovina (hloubková syntax):



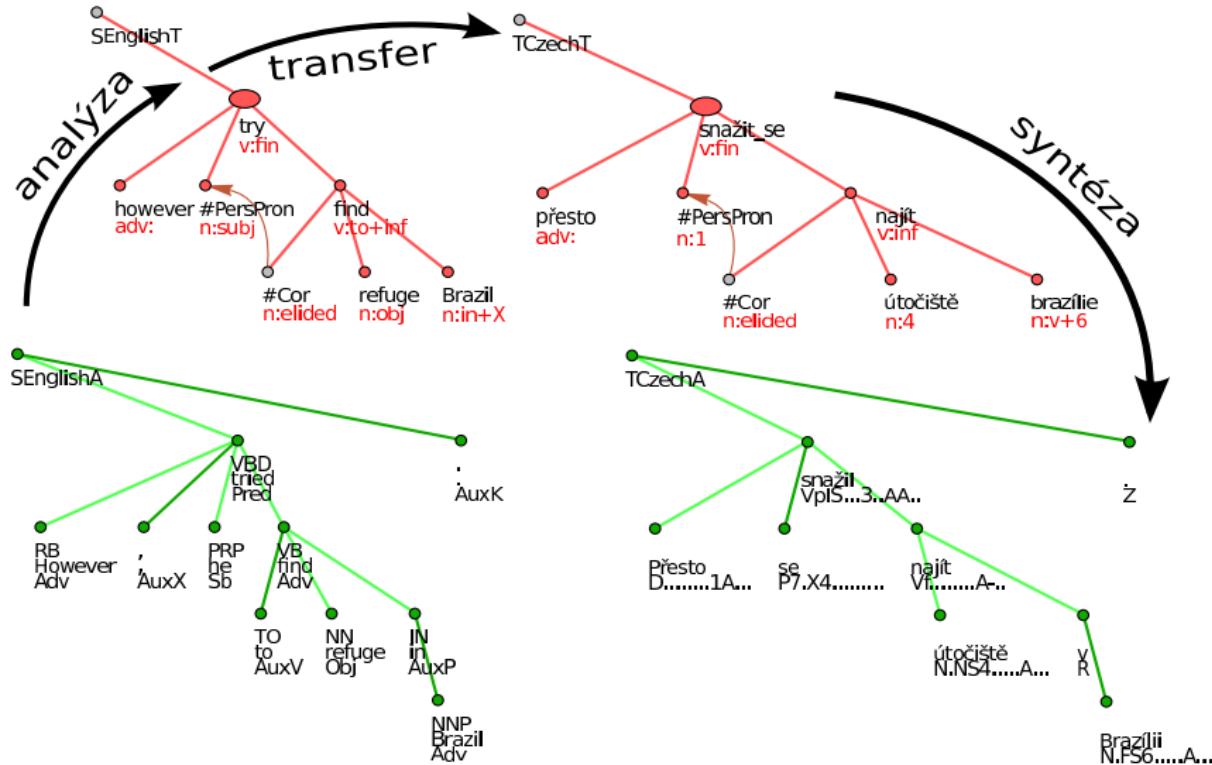
# TectoMT: Hloubkový překlad



# TectoMT: Hloubkový překlad



# Jádro: Překlad stromu na strom



- Díky t-rovině lze tvar stromu přenést beze změn.



## Frázový překlad Moses (a také Google)



# MOSES CORE

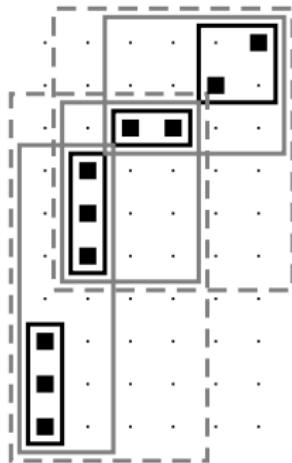


Frázový překlad  
Moses (a také MT@EC)



# Frázový překlad

faster  
even  
moving  
're  
they,  
  
around  
time  
This

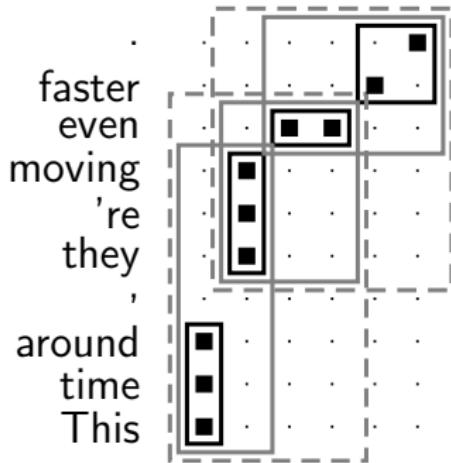


Nyní  
zareagovaly  
dokonce  
jště  
rýchleji

## Trénovací data:

- ▶ paralelní korpus (česká věta = anglická věta)
- ▶ automatické zarovnání slov (české slovo ~ anglické slovo)

# Frázový překlad



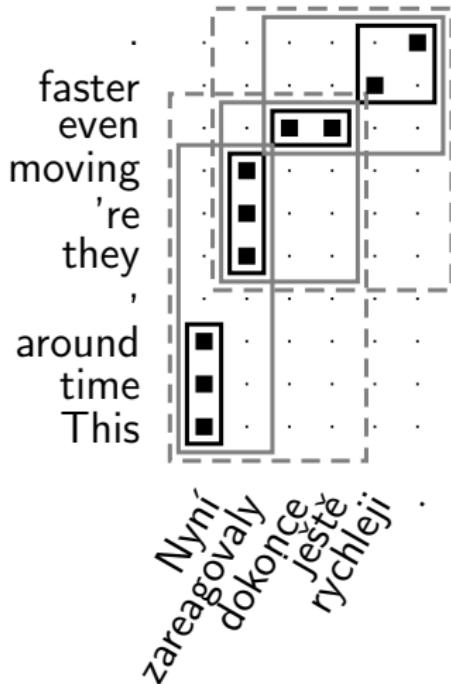
Nyní  
zareagovaly  
dokoncě  
ještě  
rychleji

This time around	=	Nyní
they 're moving	=	zareagovaly
even	=	dokoncě
even faster	=	ještě rychleji
...	=	...

## Trénovací data:

- ▶ paralelní korpus (česká věta = anglická věta)
- ▶ automatické zarovnání slov (české slovo ~ anglické slovo)

# Frázový překlad



This time around	=	Nyní
they 're moving	=	zareagovaly
even	=	dokoncě ještě
even faster	=	dokoncě ještě rychleji
...	=	...

## Trénovací data:

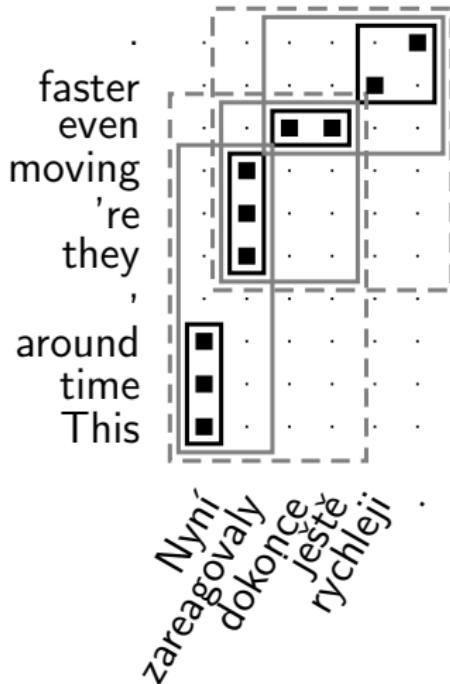
- ▶ paralelní korpus (česká věta = anglická věta)
- ▶ automatické zarovnání slov (české slovo ~ anglické slovo)

## Při samotném překladu hledáme:

- ▶ takovou segmentaci vstupní věty na úseky („fráze“)
- ▶ a takové překlady frází

aby byl výstup co nejpravděpodobnější.

# Frázový překlad



This time around	=	Nyní
they 're moving	=	zareagovaly
even	=	dokoncě ještě
even faster	=	dokoncě ještě rychleji
...	=	...

## Trénovací data:

- ▶ paralelní korpus (česká věta = anglická věta) ... **15 mil. páru vět**
- ▶ automatické zarovnání slov (české slovo ~ anglické slovo) **~ 2×200 M**

## Při samotném překladu hledáme:

- ▶ takovou segmentaci vstupní věty na úseky („fráze“)
- ▶ a takové překlady frází

aby byl výstup co nejpravděpodobnější.

# Výhody a nevýhody frázového překladu

- ⊕ Není třeba žádná znalost jazyka, stačí paralelní data.
- ⊕ Dokáže zachytit i idiomatická spojení, jsou-li v datech.
- ⊖ Nechtí gramatiku, snadno sestaví slovní salát.
- ⊖ Neumí nové tvary slov, a to ani známých.

Natáhnout bačkory.

Kick the bucket.



# Výhody a nevýhody frázového překladu

- ⊕ Není třeba žádná znalost jazyka, stačí paralelní data.
- ⊕ Dokáže zachytit i idiomatičká spojení, jsou-li v datech.
- ⊖ Nechtí gramatiku, snadno sestaví slovní salát.
- ⊖ Neumí nové tvary slov, a to ani známých.

Natáhnout bačkory.

Kick the bucket.



Proč musel natáhnout bačkory?

Why did he kick the bucket?



# Výhody a nevýhody frázového překladu

- ⊕ Není třeba žádná znalost jazyka, stačí paralelní data.
- ⊕ Dokáže zachytit i idiomatičká spojení, jsou-li v datech.
- ⊖ Neguje gramatiku, snadno sestaví slovní salát.
- ⊖ Neumí nové tvary slov, a to ani známých.

Natáhnout bačkory.

Kick the bucket.

✓

Proč musel natáhnout bačkory?

Why did he kick the bucket?

✓

Proč natáhl bačkory?

Why stretched slippers?

✗

# Výhody a nevýhody frázového překladu

- ⊕ Není třeba žádná znalost jazyka, stačí paralelní data.
- ⊕ Dokáže zachytit i idiomatičká spojení, jsou-li v datech.
- ⊖ Nechtí gramatiku, snadno sestaví slovní salát.
- ⊖ Neumí nové tvary slov, a to ani známých.

Natáhnout bačkory.	Kick the bucket.	✓
Proč musel natáhnout bačkory?	Why did he kick the bucket?	✓
Proč natáhl bačkory?	Why stretched slippers?	✗
Proč musel natáhnout bačkory Karel?	Why did <u>he</u> kick the bucket Charles?	✗

# Výhody a nevýhody frázového překladu

- ⊕ Není třeba žádná znalost jazyka, stačí paralelní data.
- ⊕ Dokáže zachytit i idiomatičká spojení, jsou-li v datech.
- ⊖ Nectí gramatiku, snadno sestaví slovní salát.
- ⊖ Neumí nové tvary slov, a to ani známých.

Natáhnout bačkory.	Kick the bucket.	✓
Proč musel natáhnout bačkory?	Why did he kick the bucket?	✓
Proč natáhl bačkory?	Why stretched slippers?	✗
Proč musel natáhnout bačkory Karel?	Why did <u>he</u> kick the bucket Charles?	✗
John se snažil natáhnout bačkory.	John tried to kick the bucket.	✗

# Nachytat překlad na švestkách...

...nemusí jít o idiomy, abyste frázový překlad odhalili:

Jan s Marií se vzali.

John and Mary were married.



# Nachytat překlad na švestkách...

...nemusí jít o idiomy, abyste frázový překlad odhalili:

Jan s Marií se vzali.

John and Mary were married.



Jan s Marií se včera vzali.

John and Mary married yesterday.



# Nachytat překlad na švestkách...

...nemusí jít o idiomy, abyste frázový překlad odhalili:

Jan s Marií se vzali.

John and Mary were married.



Jan s Marií se včera vzali.

John and Mary married yesterday.



Jan s Marií se včera v kostele vzali.

John and Mary are married in church yesterday.



# Nachytat překlad na švestkách...

...nemusí jít o idiomu, abyste frázový překlad odhalili:

Jan s Marií se vzali.

John and Mary were married.



Jan s Marií se včera vzali.

John and Mary married yesterday.



Jan s Marií se včera v kostele vzali.

John and Mary are married in church yesterday.



Jan s Marií se včera v kostele svatého Ducha vzali.

John and Mary yesterday in the Church of the Holy Spirit took.



# Problém negace

- ▶ Francouzská negace je okolo slovesa:  
Je ne parle pas français.

# Problém negace

- ▶ Francouzská negace je okolo slovesa:

Je ne parle pas français.

- ▶ Česká negace bývá zdvojená:

Nemám žádné námitky.

# Problém negace

- ▶ Francouzská negace je okolo slovesa:

Je ne parle pas français.

- ▶ Česká negace bývá zdvojená:

Nemám žádné námítky.

Zdvojená negace vede ke ztrátě negace při překladu:

Nemám žádného psa.

I have no dog.

Viděl kočku.

He saw a cat.

# Problém negace

- ▶ Francouzská negace je okolo slovesa:

Je ne parle pas français.

- ▶ Česká negace bývá zdvojená:

Nemám žádné námítky.

Zdvojená negace vede ke ztrátě negace při překladu:

Nemám žádného psa.  
I have no dog.

Viděl kočku.  
He saw a cat.

# Problém negace

- ▶ Francouzská negace je okolo slovesa:

Je ne parle pas français.

- ▶ Česká negace bývá zdvojená:

Nemám žádné námítky.

Zdvojená negace vede ke ztrátě negace při překladu:

Nemám žádného psa.  
I have no dog.

Viděl kočku.  
He saw a cat.

# Problém negace

- ▶ Francouzská negace je okolo slovesa:

Je ne parle pas français.

- ▶ Česká negace bývá zdvojená:

Nemám žádné námítky.

Zdvojená negace vede ke ztrátě negace při překladu:

Nemám žádného psa.  
I have no dog.

Viděl kočku.  
He saw a cat.

Nový vstup: Nemám kočku.

# Problém negace

- ▶ Francouzská negace je okolo slovesa:

Je ne parle pas français.

- ▶ Česká negace bývá zdvojená:

Nemám žádné námítky.

Zdvojená negace vede ke ztrátě negace při překladu:

Nemám žádného psa.  
I have no dog.

Viděl kočku.  
He saw a cat.

Nový vstup: Nemám kočku.  
I have

# Problém negace

- ▶ Francouzská negace je okolo slovesa:

Je ne parle pas français.

- ▶ Česká negace bývá zdvojená:

Nemám žádné námítky.

Zdvojená negace vede ke ztrátě negace při překladu:

Nemám žádného psa.  
I have no dog.

Viděl kočku.  
He saw a cat.

Nový vstup: Nemám kočku.  
I have a cat. 

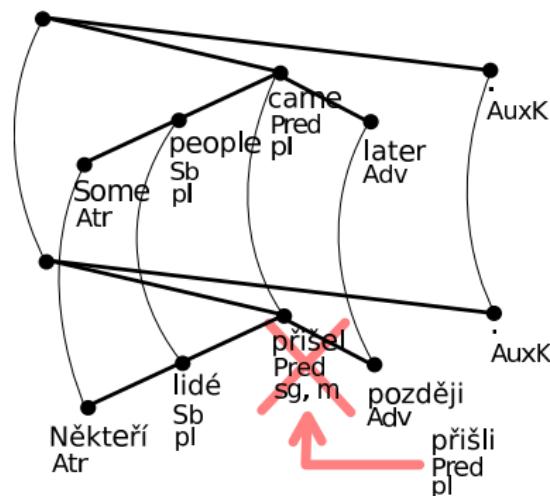


## Oprava negace a gramatiky Depfix



# Oprava gramatiky (DEPFIK)

1. Zarovnání vstupu a hypotézy.
  2. Větný rozbor vstupu a hypotézy.
  3. Pravidla opravující časté chyby:
    - ▶ Korekce rozboru hypotézy.
    - ▶ Negace, gramatické shody, pády po předložce...
- ... 50–60 % změněných vět změněno k lepšímu.
- ... přesnost vrácení ztracené negace: 90 %



# Nejlepší je kombinace

	System	BLEU	TER	Manual
WMT13		20.0	<b>0.693</b>	<b>0.664</b>
		<b>20.1</b>	0.696	0.637
		19.5	0.713	–
	GOOGLE TRANSLATE	18.9	0.720	0.618
		14.7	0.741	0.455
WMT14		21.1	0.670	<b>0.373</b>
	UEDIN-UNCONSTR.	<b>21.6</b>	<b>0.667</b>	0.357
		20.9	0.674	0.333
	GOOGLE TRANSLATE	20.2	0.687	0.168
		15.2	0.716	-0.177
WMT15		<b>18.8</b>	<b>0.715</b>	<b>0.686</b>
		18.7	0.717	–
		17.6	0.730	–
	GOOGLE TRANSLATE	16.4	0.750	0.515
		13.4	0.763	0.209

# Náš vítězný systém: Chiméra



- ▶ Vstup:
  - ▶ Famous cases also relate to graphic elements.
- ▶ 🏰 Hloubkový překlad přeloží pomocí větného rozboru:
  - ▶ Slavné případy se být týkají grafické prvky.
- ▶ 🚛 Frázový překlad přidá 200M en-cs a 3,6G cs slov:
  - ▶ Slavné případy se týkají také grafické prvky.
- ▶ 🚗 Automatické opravy chyb jako shoda či negace:
  - ▶ Slavné případy se týkají také grafických prvků.

(Google: Slavné případy týkat i grafické prvy.)

# Shrnutí

- ▶ Nejlepší výsledek: kombinace přístupů.
  - ▶ 🎉 Hloubkový + 🚗 frázový + 💬 korektura.
- ▶ Hloubkový překlad náročný na lingvistické zdroje.
- ▶ Frázový překlad potřebuje jen paralelní data.
- ▶ Chyby v současných modelech zatím nevyhnutelné (negace, . . . )
- ▶ Při dostatku dat výstup vhodný k posteditaci.