

# Přednáška 11:

## Férovost a zkreslení při testování

---

10. 12. 2024 | PSYn4790 | Psychometrika: Měření v psychologii  
Katedra psychologie, Fakulta sociálních studií MU

Hynek Cígler | cigler@fss.muni.cz

Co si představíte  
pod termínem férovost...

Co si představíte  
pod termínem férovost...  
... v psychodiagnostice?

Co si představíte  
pod termínem férovost...  
... v psychodiagnostice?  
... a v psychometrice?

# Férovost v psychometrice

---

2. kapitola českého překladu *Standardů pro pedagogické a psychologické testování* (AERA, 2001).

- Doporučuji vydání 2014 v Aj
  - A to i pro studium PSYn4020/PSYn5340.

„Férovost“ a s ní související téma multikulturního testování je jedním z důležitých témat současné psychometriky (zejména v rámci tzv. edukativního testování).

# Klíčové pojmy

---

## Přístupnost (accesibility).

- Měřený rys je stejně dostupný u všech potenciálních probandů.
- Příslušnost ke skupině probandů neovlivňuje výsledek v testu po kontrole rysu.
- Např. zrakové/sluchové znevýhodnění, znalost jazyka apod.

## Univerzální design.

- Charakteristika testu, která zajišťuje přístupnost.
- Např. snaha o vyřazení položek se silnou kulturní specificitou.
- Nebo zvážení rozdílnost účelu testu napříč skupinami probandů.

## Zkreslení (bias).

- Systematický zdroj rozptylu nesouvisející s měřeným rysem.
- Situace, kdy je test rozdílně nebo vůbec (ne)přístupný u některých (skupin) probandů.

# 4 základní významy férovosti (AERA, 2014)

---

## Férovost zacházení během testování.

- *Psychodiagnostika.*
- „Objektivita“, rovné zacházení... se všemi zacházím stejně.
- *Standardizace* I dle Urbánka ([2010](#)).

## Nepřítomnost testového zkreslení.

- *Psychometrika.*
- „Test bias“, „item-bias“.
- Test a položky měří u všech stejný rys.
- DIF, DTF, DPF, invariance atd.

## Férovost jako přístupnost, otevřenost.

- *Psychometrika, psychodiagnostika, teorie.*
- „Accessibility“, „provability“.
- Vlastnost je u respondenta měřitelná.

## Férovost jako interpretace individuálního skóre pro daný účel

- *Psychodiagnostika.*
- Zvážení jedinečnosti každého respondenta.
- Jaká individuální specifika ovlivňují výkon.
- Akomodace, individuální úpravy testu.
- *Důsledky testování* (Messick).

# Bias = zkreslení

---

## Bias = systematické zkreslení testových výsledků

- Reliabilita: náhodné chyby měření, není tedy otázkou zkreslení.
- Úvaha o zkreslení tedy patří do validity, ale z praktických důvodů je vyčleňována.
- Slovem zkreslení označujeme nenáhodné, systematické, specifické chyby měření.
- „*Měří test jinak pro některé populace než pro jiné?*“
- „*Měří test jinak pro některé specifické osoby?*“
- „*Měří test obecně spravedlivě?*“

Může znamenat, že v různých populacích např.:

- Je test/položka příliš snadná/obtížná.
- Má test/položka jiný vztah k rysu.
- Test má jinou faktorovou strukturu.
- Test měří zcela či částečně něco jiného.
- ...
- *Výkon v testu je ovlivněn systematicky něčím, co nemá souvislost s tím, co chci měřit („konstruktově irrelevantní rozptyl“).*
- A nejde o nahodilý, ale systematický vliv.

# Bias = zkreslení

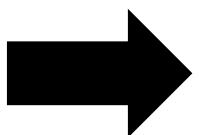
Konstruktově-irelevantní  
rozptyl



# Bias = zkreslení

Konstruktově-irelevantní  
rozptyl

atribut  
+  
bias



Pozorované  
měření

atd...



# Důsledky zkreslení

## PŘEDPOKLAD

CTT model měření pro nezkreslený pozorovaný skór  $X$ :

$$X = T + e$$

Reliabilita:

$$r_{xx'} = \frac{\sigma_T^2}{\sigma_T^2 + \sigma_e^2}$$

## DŮSLEDEK ZKRESLENÍ

CTT model měření pro zkreslený pozorovaný skór  $Y$ :

$$Y = T + B_1 + B_2 + \cdots + B_n + e$$

Reliabilita:

$$r_{yy'} = \frac{\sigma_T^2 + \sigma_{B_1}^2 + \sigma_{B_2}^2 + \cdots + \sigma_{B_n}^2}{\sigma_T^2 + \sigma_{B_1}^2 + \sigma_{B_2}^2 + \cdots + \sigma_{B_n}^2 + \sigma_e^2}$$

**Otzáka: Jaké dopady to bude mít na reliabilitu a validitu?**

Protože  $\sigma_T^2 < \sigma_T^2 + \sigma_{B_1}^2 + \sigma_{B_2}^2 + \cdots + \sigma_{B_n}^2$ , pak často platí  $r_{yy'} > r_{xx'}$ .

- Jinými slovy, testové zkreslení může **zvyšovat reliabilitu** ve smyslu stability měření (dimension-free).

Protože ale  $B_1 + B_2 + \cdots + B_n$  nesouvisí s případným kritériem, snižuje validitu.

- Respektive snižuje reliabilitu ve smyslu rozptylu vysvětleného měřenou latentní proměnnou (model-based).

# Důsledky zkreslení

---

Testové zkreslení tedy zkreslení představuje zdroj rozptylu, který...

- a) reprezentuje rozdíly mezi osobami
- b) nesouvisí s měřeným rysem
- c) je systematický

Koncept je trochu problematický v rámci CTT.

- Zejména na úrovni celého testu – pravé skóre jako výsledek interakce testu a respondenta.
- Jak uvažovat o rozdílech vztahu pozorovaného a pravého skóre, když pravé skóre „neexistuje“?
- Nicméně na úrovni položek: položky jsou *jinak paralelní* napříč skupinami osob.

Framework pro ověřování zkreslení hlavně v modelech latentních proměnných.

- CFA, IRT.

# Příklad potenciálních oblastí zkreslení

---

**Objektivita:** Zkreslení na úrovni examinátora a testové situace, nestranné zacházení.

- Je zacházeno se všemi respondenty stejně?

**Response bias:** Zkreslení odpovědí na úrovni respondenta.

- Záměrné i nezáměrné zkreslení ovlivňující vztah měřeného latentního rysu a pozorovaného skóre.

**Item bias:** Systematické zkreslení položky.

- Systematické rozdíly mezi osobami/skupinami v odpovědi na položku, nevysvětlitelné úrovní rysu.

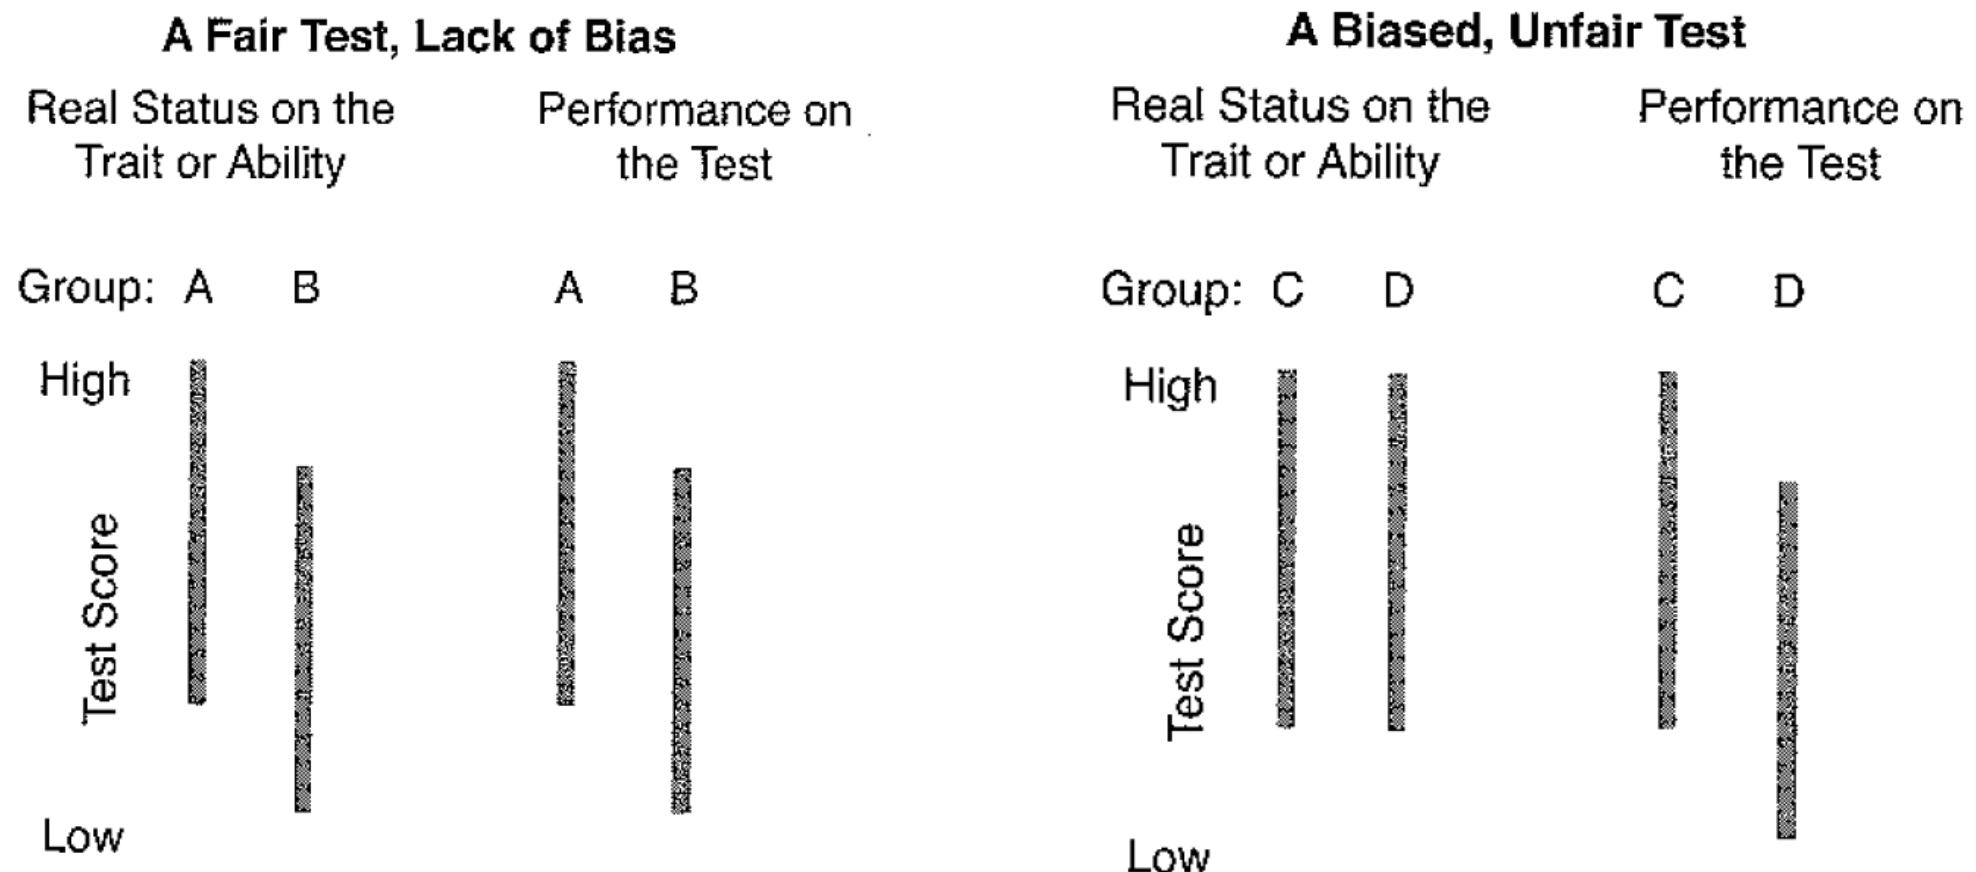
**Test bias:** Systematické zkreslení testu.

- Systematické rozdíly celkových skórů/výsledků testu, nevysvětlitelné úrovní rysu.

**Predictive bias:** Systematické zkreslení testu (prediktivní/kriteriální validity).

- Rozdílný vztah testových výsledků s kritériem pro různé skupiny osob.

# Test bias, test fairness



# Test bias, test fairness

**A Fair Test, Lack of Bias**

Real Status on the  
Trait or Ability

Group: A    B

High

Test Score

Low

Performance on  
the Test

A    B

High

Test Score

Low

**A Biased, Unfair Test**

Real Status on the  
Trait or Ability

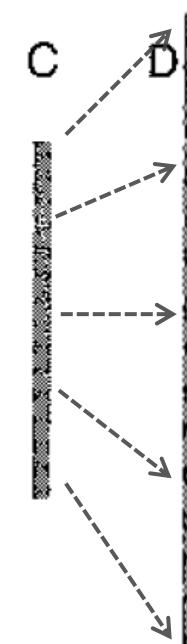
Group: C    D

High

Test Score

Low

Performance on  
the Test



# Test bias, test fairness

**A Fair Test, Lack of Bias**

Real Status on the  
Trait or Ability

Group: A    B

High

Test Score

Low

Performance on  
the Test

A    B

High

Test Score

Low

**A Biased, Unfair Test**

Real Status on the  
Trait or Ability

Group: C    D

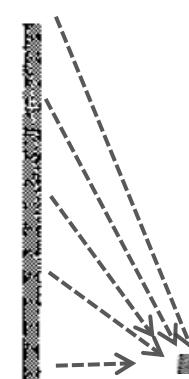
High

Test Score

Low

Performance on  
the Test

C    D



# Zdroje ohrožení férovosti testování

---

## **Obsah testu**

- Který znevýhodňuje některé skupiny, osoby atd.

## **Kontext testové situace**

## **Odpovědi na položky**

- Formát položek, interpretace při kvalitativním skórování výsledků...

## **Příležitost k přípravě na test**

A další...

# Kontext testové situace

---

Tohle je otázka spíše do psychologické diagnostiky/etiky.

Cílem je zajistit, aby každý respondent měl možnost projevit ty stejné schopnosti ve stejném míře.

- APA standard 7.12: „*Testování nebo hodnocení by mělo probíhat takovým způsobem, aby se všem testovaným osobám dostalo stejného nebo srovnatelného zacházení během všech fází testování.*“

Administrátor testu rovněž musí být kompetentní s konkrétním testem pracovat (školení, zácvik...).

# Možnost přípravy

---

Všichni respondenti musí mít shodné možnosti zácviku, poučení o cíli testování...

- Na tohle pozor! Běžná praxe neomlouvá...

Př. 1: „Tajné“ informace o způsobu dopravně-psychologického vyšetření.

Př. 2: Placené (a drahé) přípravné testy na přijímačky.

Př. 3: Neformálně dostupné informace o průběhu forenzního vyšetření.

Př. 4: Různý způsob informování před zahájením vyšetření.

# Férovost jako přístupnost

---

## Příklad: Přijímačky do bc studia na FSS (formát z minulých let)

2 testy: studijní předpoklady (váha 0,4), ZSV (váha 0,6)

Studijní předpoklady – na výběr:

- SCIO (až 5 pokusů, bere se nejlepší)
- TSP od MU (1 pokus)

ZSV – jediná možnost:

- SCIO (až 5 pokusů, bere se nejlepší)

Jaké jsou nevýhody daného designu z hlediska psychometriky?

Co byste studentům řekli, aby měli rovné podmínky?

Simulace:

<http://fssvm6.fss.muni.cz/prijimZk/>

# Férovost jako přístupnost

## Příklad: Přijímačky do bc studia na FSS

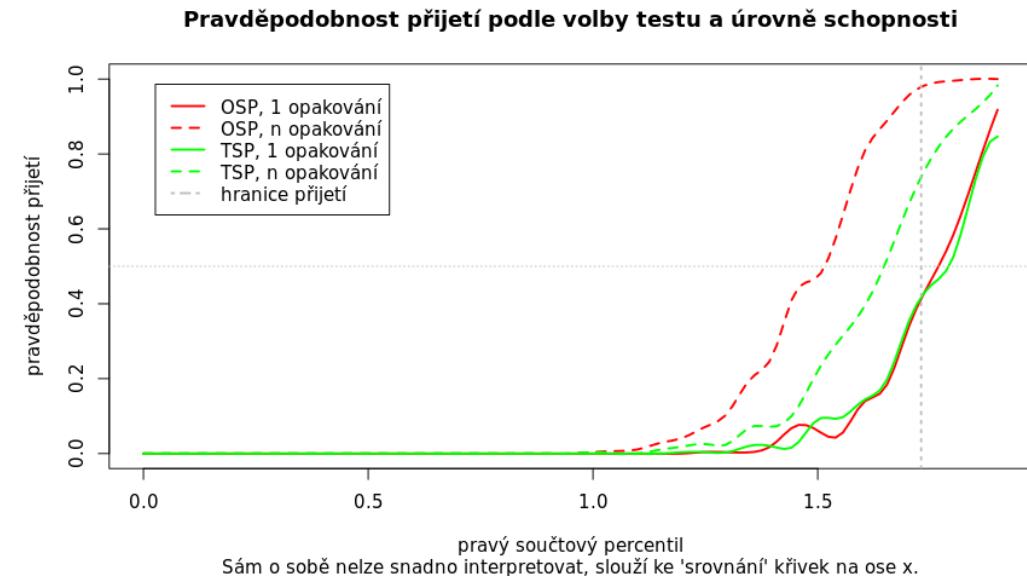
2 testy: studijní předpoklady (váha 0,4), ZSV (váha 0,6)

Studijní předpoklady – na výběr:

- SCIO (až 5 pokusů, bere se nejlepší)
- TSP od MU (1 pokus)

ZSV – jediná možnost:

- SCIO (až 5 pokusů, bere se nejlepší)



pravděpodobnost přijetí náhodného uchazeče podle varianty testu:	1x OSP + 1x ZSV	1x TSP + 1x ZSV	Nx OSP + Nx ZSV	1x TSP + Nx ZSV
	0.09	0.09	0.22	0.15

# Response bias

---

Jde o určitý styl odpovídání specifický konkrétnímu respondentovi v konkrétní situaci, který znehodnotí/zneplatní testové výsledky (sníží jejich validitu):

## Nahodilé odpovědi a záměrné zneplatnění výsledků.

Zkreslení v užším významu (např. Paulhus a kol.<sup>1</sup>).

- Simulování a sebeznevýhodňování (záměrné). Tzv. „**impression management**“.
- Sociální žádoucnost a nezáměrné zkreslení. Tzv. „**self-deception**“.

## Odpovědní styl (response style)

- Tendence k souhlasu nebo nesouhlasu.
- Tendence k extrémním nebo průměrným odpovědím.

Hádání, tipování.

---

<sup>1</sup> Řada dílčích publikací o self-presentation, overclaiming, self-management atd.

# Response bias – možnosti řešení

---

Změna settingu testové situace, aby respondent nebyl motivován výsledky zkreslovat.

- Anonymita, redukce stresu, srovnání úrovně motivace...

## Úprava obsahu a formátu položek

- Jednoduché položky – krátké jednoznačné stimuly, krátké jednoznačné a „ne-extrémní“ distraktory.
- U delších odpověďových (Likertových škál) je zřejmě větší prostor pro zkreslení.
- Zajištění absence chybějících odpovědí.
- Rozdílná valence položek (negativní skórování).
- Nucená volba (pak ale obtíže s psychometrickým zpracováním).

## Odhalení zkreslení

- Tzv. „validizační škály“ či „lži škály“ (např. v případě MMPI-II 6 různých škál).
- Dodatečné testy (Malingering scale – máme v KDM).
- Netestová detekce ☺.

# Metody ověření systematického zkreslení

---

**Expertní panelová review:** Obsahová validita.

**Diferenciální fungování položek:** Vnitřní struktura testu.

- Na úrovni položek.

**Testová invariance:** Vnitřní struktura testu.

- Na úrovni celého testu.

**Diferenciální predikce testu:** Prediktivní/kriteriální validita

# Panel review

---

Používá se zejména v případě (pedagogických) high-stakes testů.

Pečlivá volba tzv. expertního panelu (Subject Matter Experts, SME).

SME panel vytváří, reviduje a připomínkuje položky a složení testu (zejm. didaktické a edukativní testy).

- Experti musí být experty na měřený konstrukt.
- Zároveň by ale měli dobrě **reprezentovat testovanou populaci**.
- Muži i ženy, minority...
- Jsou ale SME z určité minority dobrými reprezentanty této minorit?

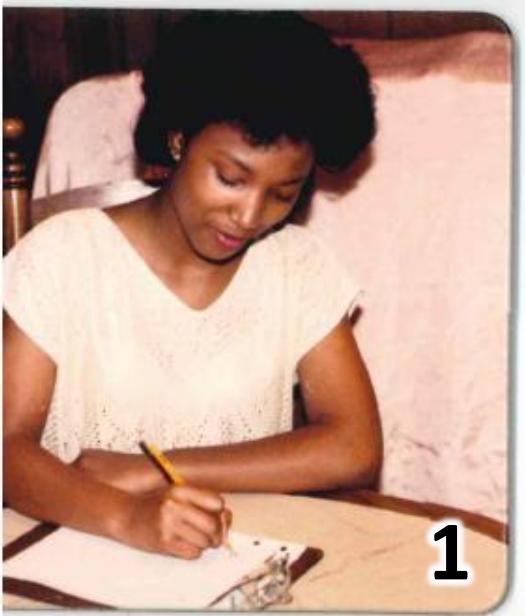
# Test bias, item bias: Férovost z hlediska psychometriky.

---

DIFFERENTIAL ITEM FUNCTIONING (DIF)

DIFFERENTIAL TEST FUNCTIONING (DTF)





1



2



3



4



5



6

# Test/item bias

---

Nelze odvodit bez dat (jen odhadovat).

- Empirické důkazy a technická řešení.

Respondent se snaží odpovídat pravdivě, ale test měří v různých skupinách něco jiného.

WAIS-III: „*Co uděláte, když najdete na zemi zalepenou poštovní obálku s napsanou adresou, známkou, ale bez razítka?*“

WISC-III: „*Co uděláte, když chcete uvařit čaj?*“

Skupiny: etnikum, pohlaví, jazyk, socio-ekonomický status, region...

# Dva hlavní empirické přístupy k férovosti

---

## **Na úrovni jedné položky** (item bias analysis).

- Které položky (a zda ta která položka) vykazují rozdílný styl odpovídání napříč skupinami, který nelze přičíst rozdílům v úrovni latentního rysu?
- **DIF analýza** (Differential Item Functioning).

## **Na úrovni celého testu** (test bias analysis).

- Do jaké míry test jako celek (soubor mnoha různých položek) měří ten stejný rys pro různé skupiny?
- Lze srovnávat naměřené skóry napříč skupinami?
- **Analýza testové invariance.**

# Logika ověření zkreslení

---

**Předpoklad férovosti:**

*Atribut (latentní rys) „způsobuje“ pozorované odpovědi.*

**Systematické zkreslení znamená:**

Příslušnost ke skupině moderuje tento vztah.

- Zvyšuje/snižuje intercept závislé proměnné.
- Zvyšuje/snižuje regresní koeficient.
- Zvyšuje/snižuje reziduální rozptyl.

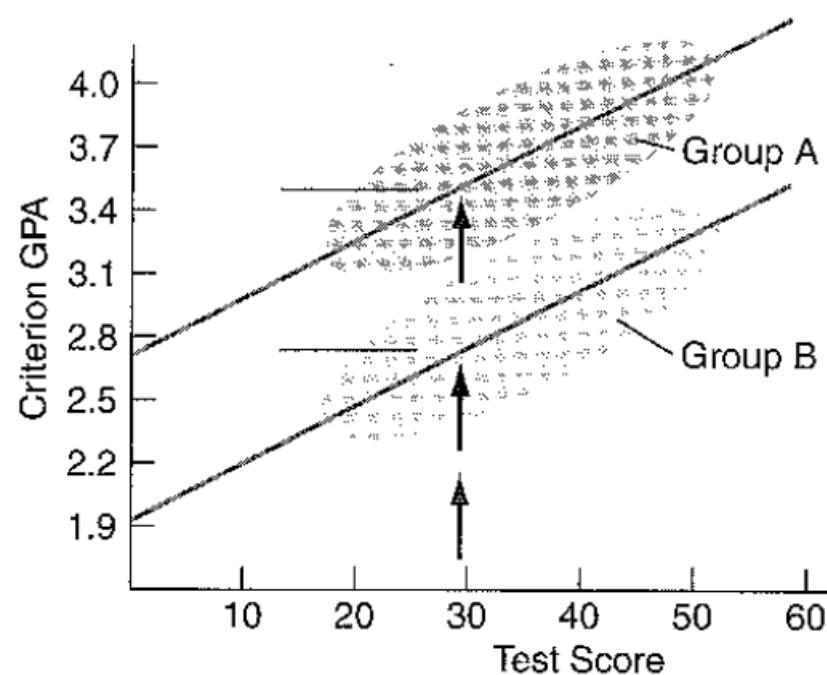
**Bias/zkreslení = moderace.**

# Test bias (prediktivní zkreslení)

např. přijímací zkoušky vs. státnice

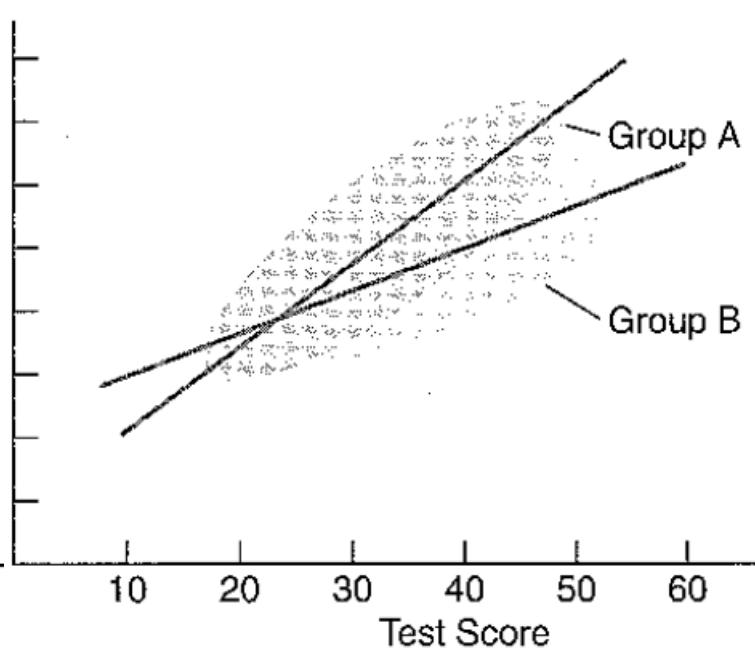
**situace A**

rozdíl v průměru predikce



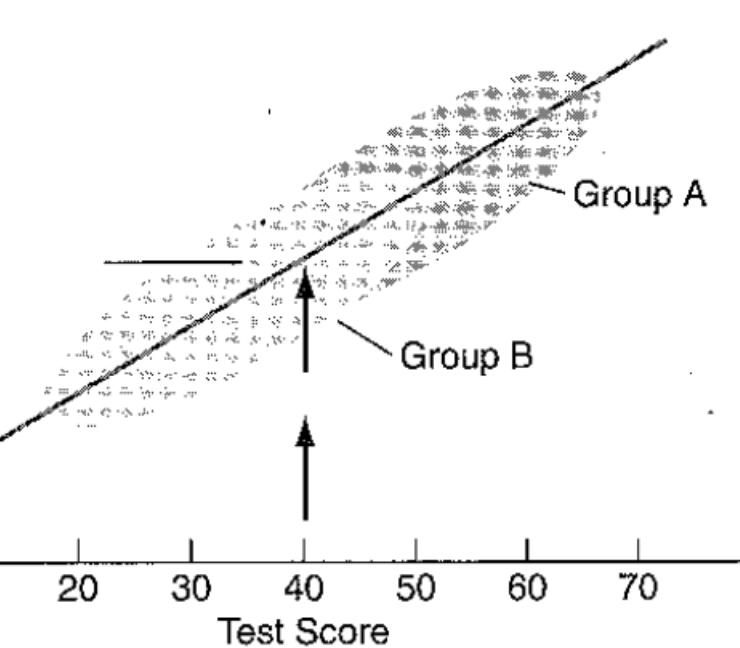
**situace B**

rozdíl v přesnosti (a průměru) predikce



**situace C**

férový test



# Test bias (prediktivní zkreslení)

---

Ověření typicky pomocí moderačního modelu (lineární i logistická regrese).

- **Krok 0:** centrování.

**Krok 1:** vytvoření interakční proměnné součinem prediktoru a moderátoru.

**Krok 2:** prostá lineární regrese

- Prediktivní nebo kriteriální validita.

$$Y = aX + b$$

- $Y$  – kritérium,  $X$  – výsledek testu
- $a$  – směrnice,  $b$  – průsečík.

**Krok 3:** přidání moderátoru do regrese.

- (Výhodnější je přidávat členy postupně.)

$$Y = aX + b + (cM + d(M \cdot X))$$

- $M$  – moderátor (skupina osob...)

Signifikantní F-test rozdílu 1. a 2. modelu ( $\Delta R^2$ ) → přítomnost zkreslení.

- sig.  $c$  → rozdíl v průměru predikce.
- sig.  $d$  → rozdíl v přesnosti predikce.

**Srovnáváme nestandardizované koeficienty!**

- Standardizované jsou ovlivněné populačními charakteristikami, které se lišit mohou.

# Příklad: Dotazník výšky

Rečka (2018); [ShinyItemAnalysis::HeightInventory](#).

Celý vzorek dohromady:

- Reliabilita:  $\omega = 0,968$ ,  $\lambda_4 = 0,977$ .
- Validita:  $r = 0,873$ .

Muži:

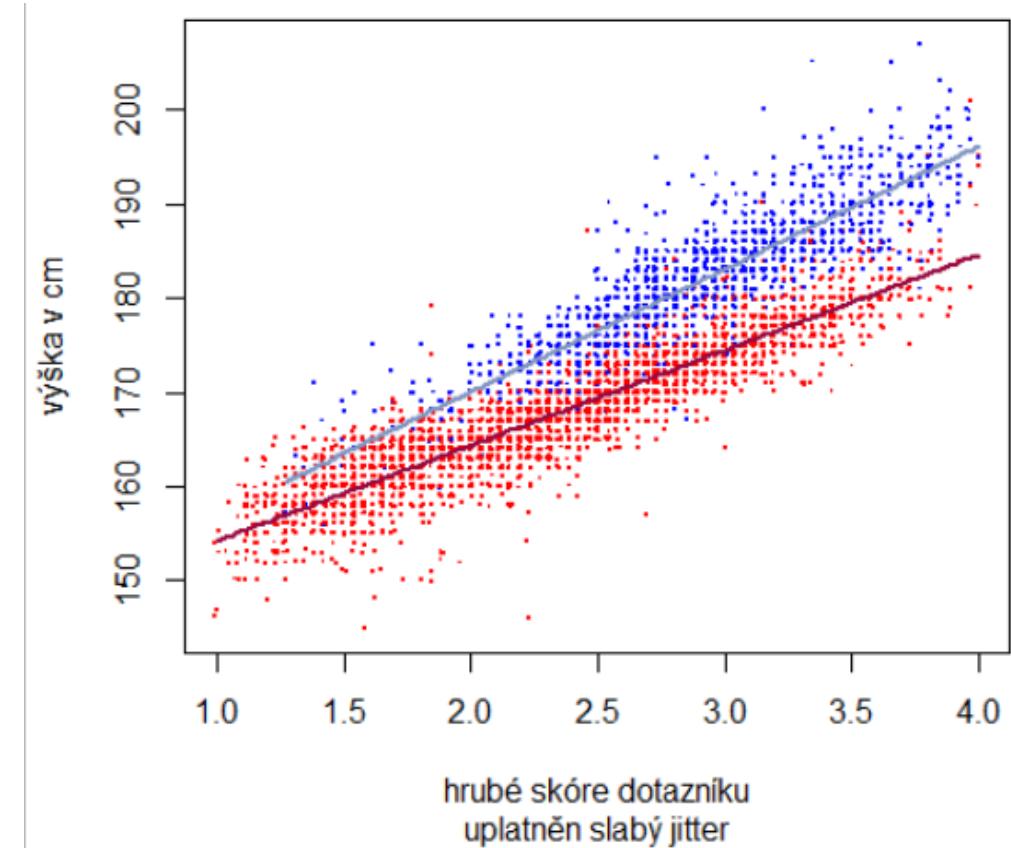
- Reliabilita:  $\omega = 0,953$ ,  $\lambda_4 = 0,967$
- Validita:  $r = 0,876$

Ženy:

- Reliabilita:  $\omega = 0,966$ ,  $\lambda_4 = 0,975$ .
- Validita:  $r = 0,903$

Lineární regrese:  $_{adj}R^2 = 0,889$  ( $R = 0,943$ )

- $\beta_{HS} = 0,875$ ;  $\beta_{sex} = -0,342$ ;  $\beta_{HS*sex} = -0,161$  (centrováno)
- všechna  $p < 0,00001$ .



# DIF v CTT

---

DIF = Differential Item Functioning

Nepružné, protože CTT a FA nedobře modeluje odpovědi na položku v závislosti na HS (předpoklad linearity odpovědí).

**Komparace ULI indexů:** Rozdělíme vzorek pro výpočet ULI napříč skupinami.

- ULI následně spočítáme pro celý vzorek, pro jednu i druhou skupinu.
- Jsou stejné? Jaká je korelace ULI napříč skupinami?

**Komparace popularit položek.**

- Je pořadí položek dle obtížnosti stejné napříč skupinami?
- Korelují popularity položek napříč skupinami?
- Spearmanova korelace obtížností položek.

# DIF v CTT (korektněji)

---

**Mantelův-Haenszelův test.** Chí-kvadrát pozorovaných odpovědí pro každou úroveň HS a následná agregace výsledků.

Postupy založené na **logistické regresi**.

- Podobný přístup jako v případě test bias.
- Prediktorem je hrubé skóre (IRT/FA odhad latentního rysu), závislou odpověď na položku, moderátorem příslušnost ke skupině.
- binární položky: logistická regrese
- ordinální položky: ordinální nebo multinomická logistická regrese.

# IRT: Differential Item Functioning (DIF)

---

DIF analýza se používá zejména v kontextu IRT.

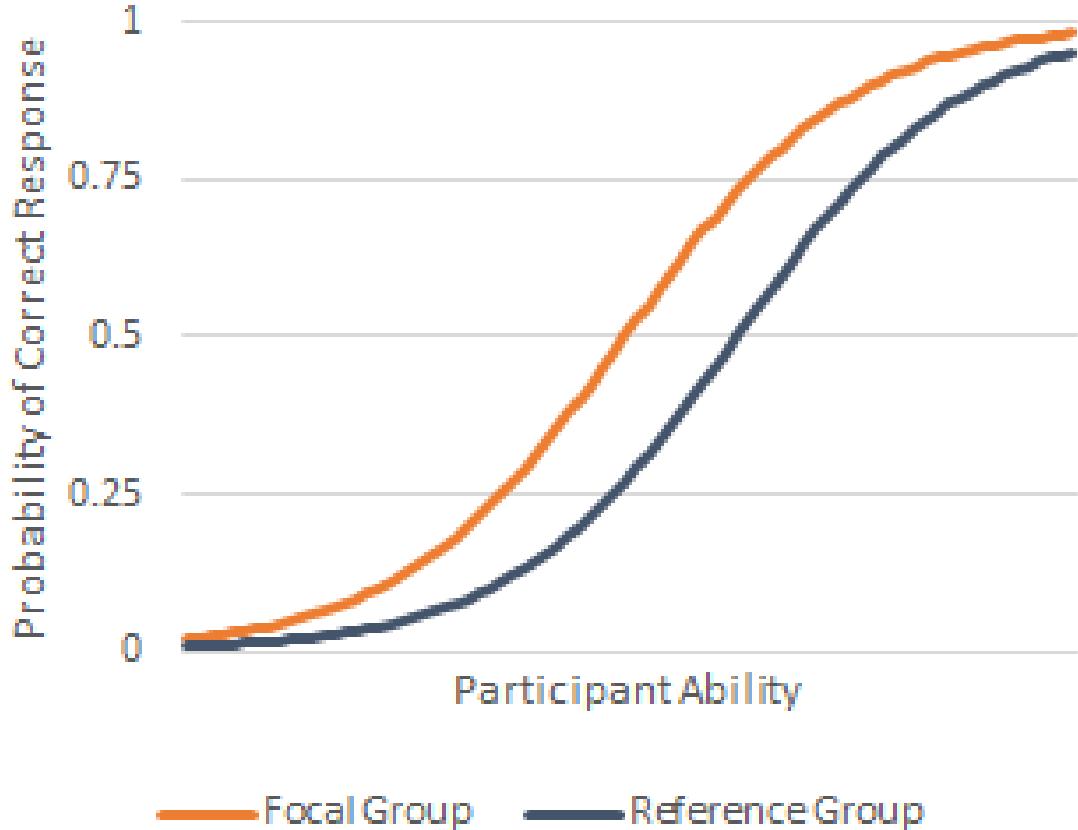
Obecný framework pro usuzování na neférovost jednotlivých položek.

- Některé postupy aplikovatelné i v CTT, ale IRT je výrazně vhodnější.
- V CTT je např. problematické testovat non-uniform DIF (viz dále), nebo DIF mezi skupinami, které se výrazně liší svým výkonem.

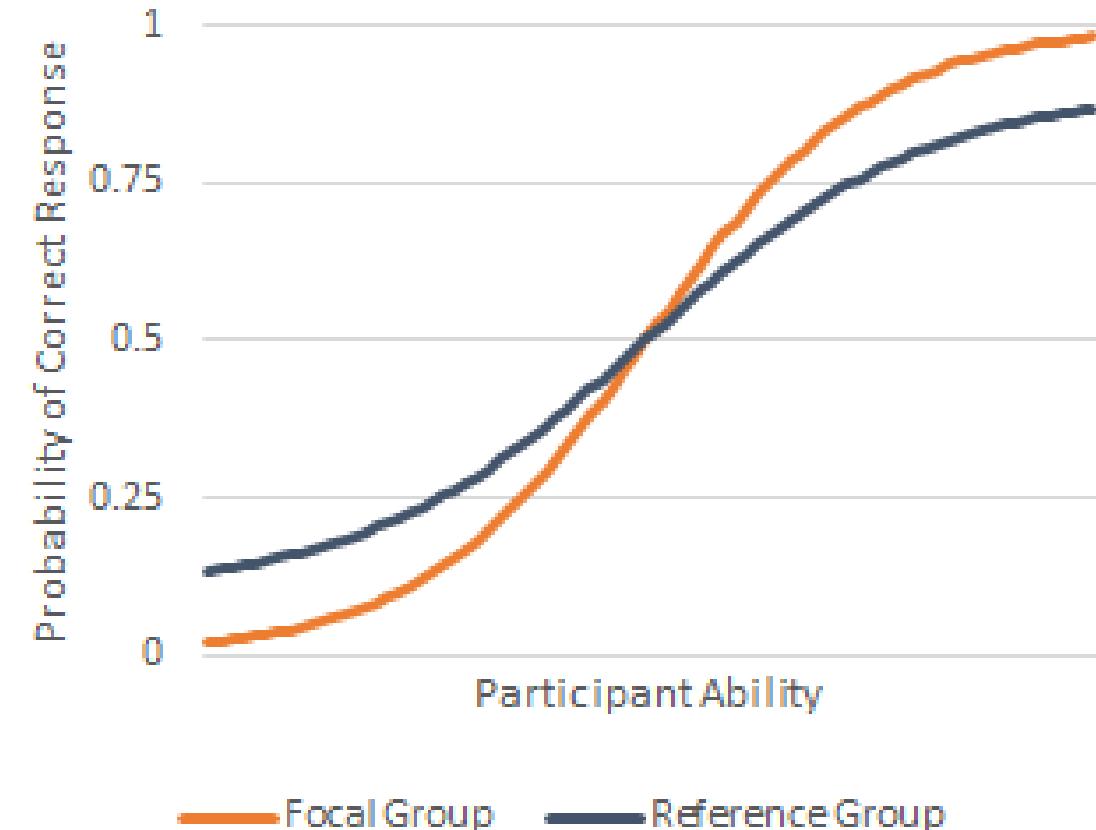
Základní princip:

**srovnání charakteristické funkce položky napříč skupinami.**

### Item Characteristic Curve: Uniform DIF



### Item Characteristic Curve: Non-Uniform DIF



# Příklad: Žádné DIF

Dotazník výšky:

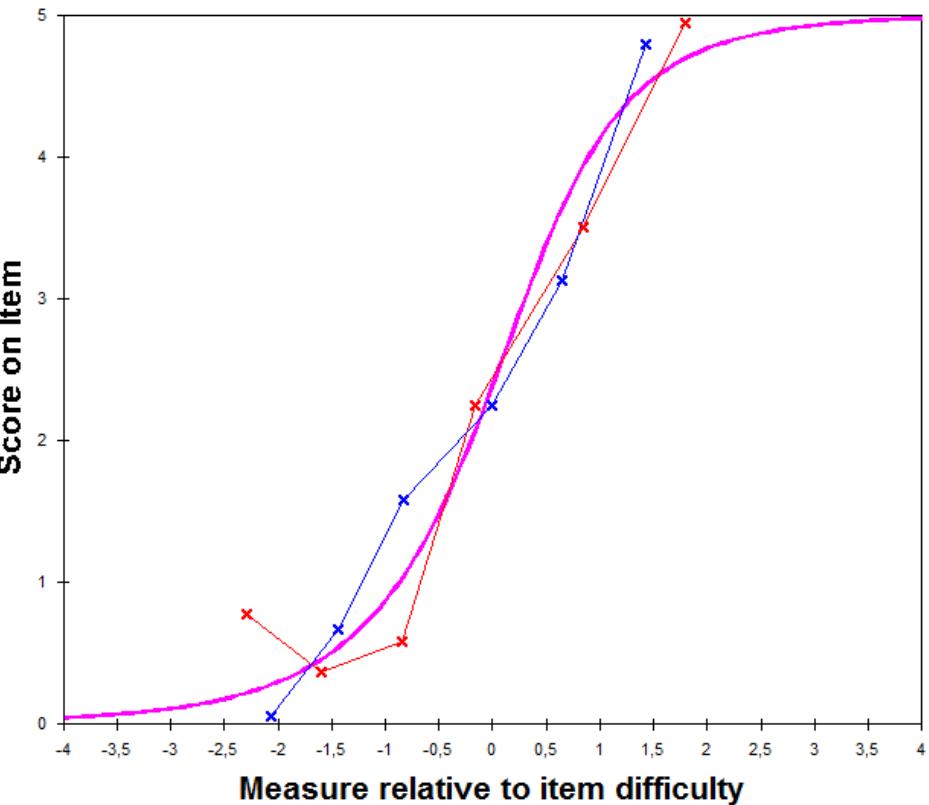
*Někdy se uhodím do hlavy  
o nízký strop, futro a podobně.*

DIF:

- t-test:  $t(86) = -0,31$ ,  $p=0,756$
- M-H:  $\chi^2(1)=0,44$ ,  $p=0,508$ .

Modrá muži, červená ženy.

4. Někdy se uhodím do hlavy o nízký strop, futro a podobně (DIF=\$S1W1)



# Příklad: Uniformní DIF

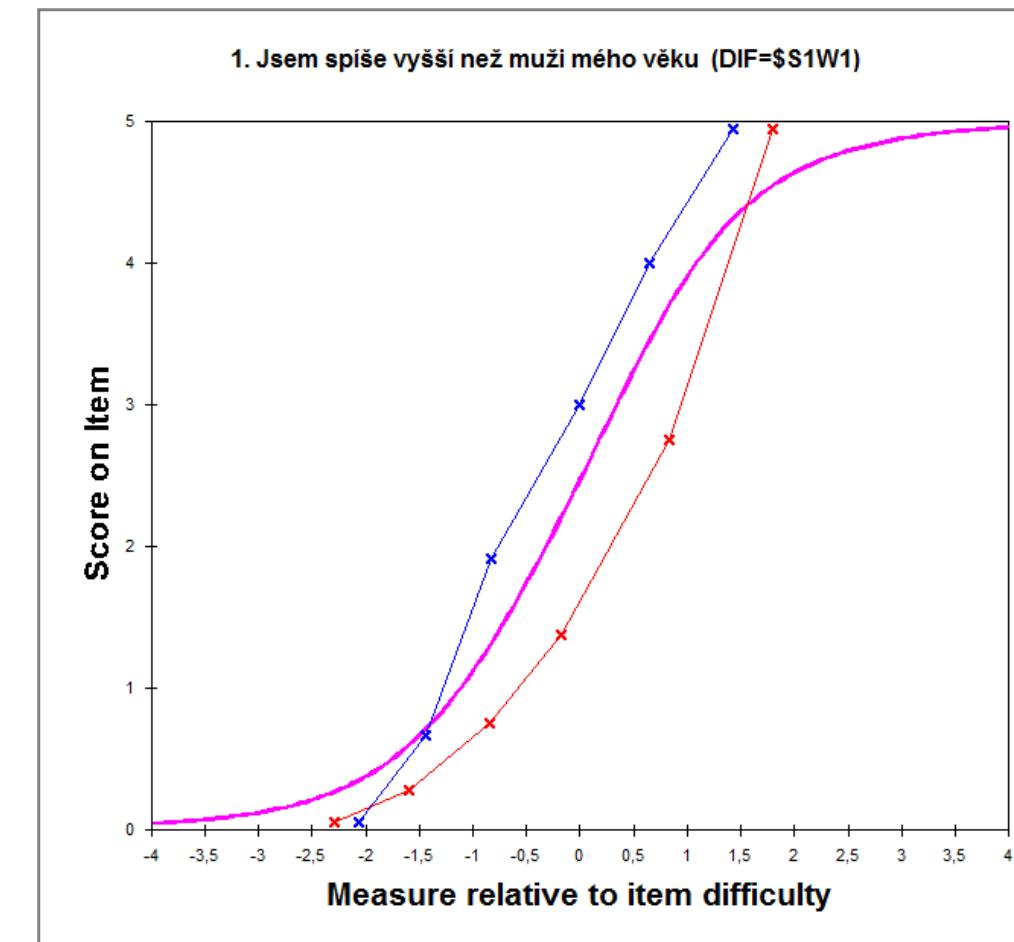
Dotazník výšky:

*Jsem spíše vyšší  
než muži mého věku.*

DIF:

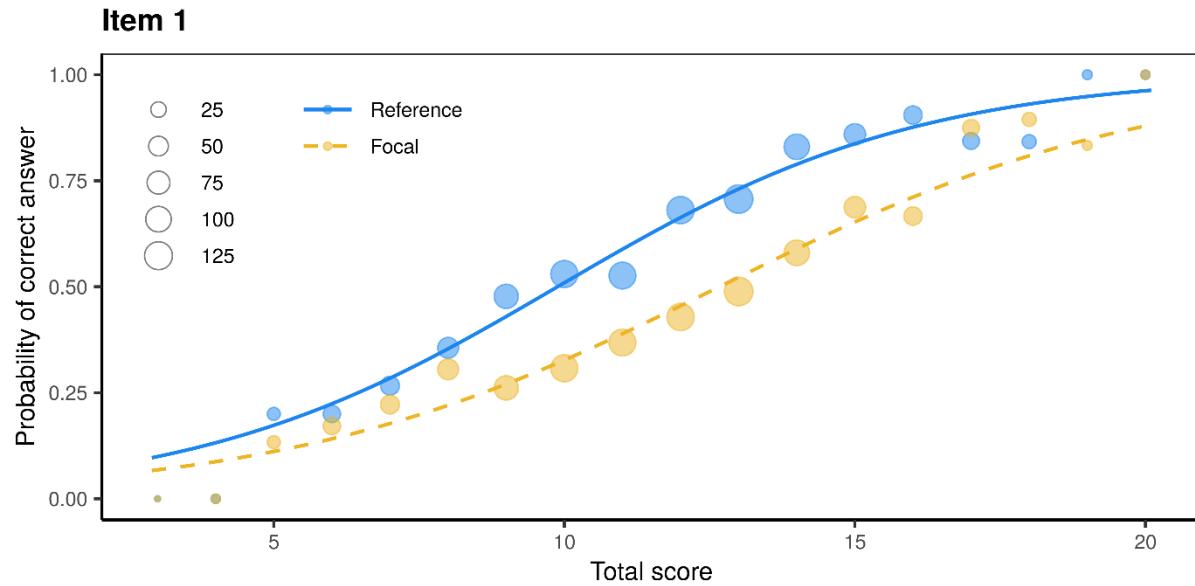
- t-test:  $t(86) = -4,63$ ,  $p < 0,001$
- M-H:  $\chi^2(1) = 18,7$ ,  $p < 0,001$ .

Modrá muži, červená ženy.

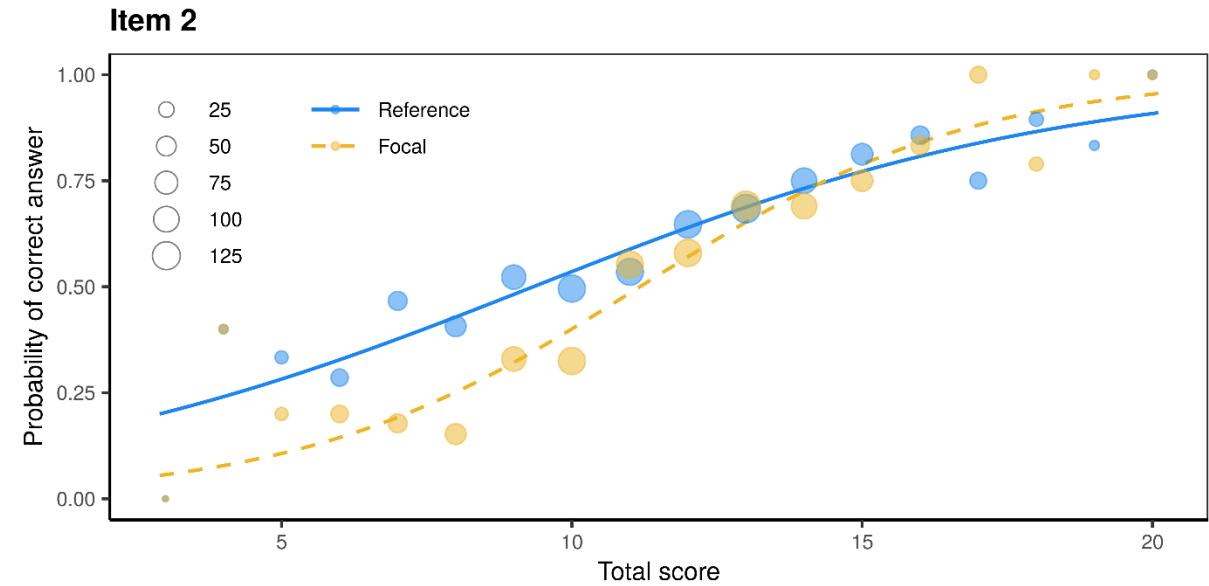


# Příklad: uniformní vs. non-uniformní DIF

## Uniformní DIF



## Non-uniformní DIF



# IRT přístupy k DIF

---

## Srovnání modelů (Model Comparison)

- Odhad multigroup IRT modelu (MG IRT) se stejnými koeficienty napříč skupinami.
- Odhad MG IRT modelů s uvolněnými koeficienty separátně pro každou položku.
- Modely jsou srovnány (LRT test, změna indexů přibližné shody modelu s daty – TLI, RMSEA, BIC...).
  - Signifikance modelu znamená DIF, velikost efektu lze vyjádřit rozdílem shody modelu s daty nebo velikostí rozdílu parametrů.
- **Bottom-up:** východiskem je konfigurální model, fixování koeficientů (model se nesmí zhoršit).
- **Top-down:** východiskem je restriktivní model, uvolňování koeficientů (model se nesmí zlepšit).

## Explanační IRT modely, LLTM modely atp.

- Podobné přístupu založenému na logistické regresi.
- K položkám jsou doplněny vysvětlující skupinově-specifické proměnné.
- Pozornost je věnována signifikanci těchto proměnných na úrovni jedné položky.

Mnoho testů → LASSO, EBICglasso, korekce proti opakovanému testování atd.

# Software

---

Zejména R, různé balíčky

- difNLR, mirt, difR, lordif, DIFlasso, DIFtree...

On-line aplikace: <https://shiny.cs.cas.cz/ShinyItemAnalysis/>

Jakýkoli statistický program, který disponuje modulem pro (ordinální) logistickou regresi.

# Invariance měření: Férovost z hlediska psychometriky.

---

KONFIGURÁLNÍ, METRICKÁ, SKALÁRNÍ

# Test bias: Invariance měření

---

Zkreslení na úrovni testu není nutné ověřovat jen pomocí prediktivní validity.

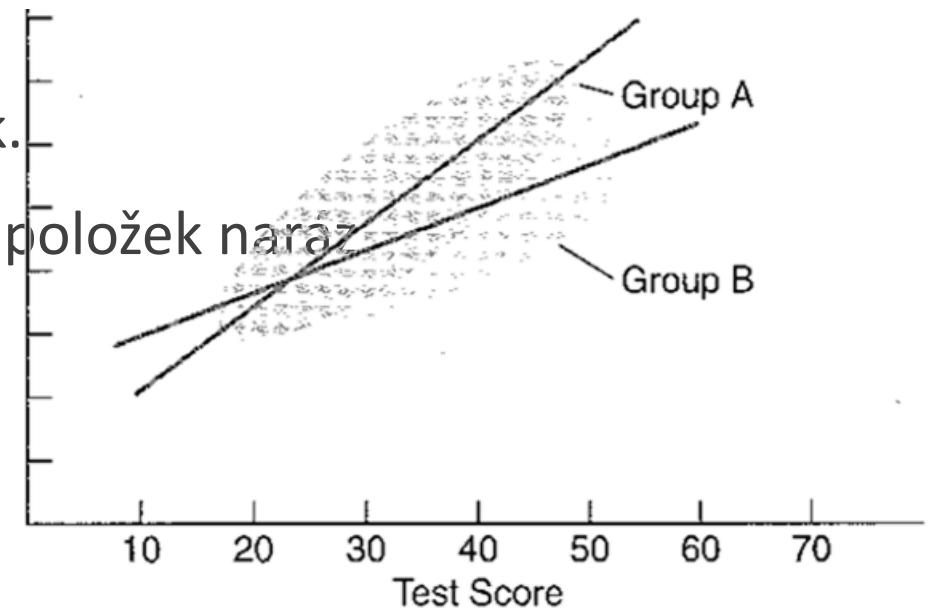
„Měří test stejný konstrukt napříč skupinami“?

Pokud ano, vztah odpovědí a úrovně latentního rysu by měl být shodný.

- A tedy i parametry položek by měly být shodné.

DIF se zaměřuje na parametry jednotlivých položek.

**Invariance měření** sleduje shodu všech parametrů položek naraz.



# Test bias: Invariance měření

---

Postup založený na konfirmační faktorové analýze, ale je použitelný i v IRT.

- Tzv. multiple-group CFA/IRT (MG CFA, MG IRT).

Ověřuje shodnost faktorové struktury (modelu měření) napříč skupinami.

- Rozdílné úrovně invariance umožňují rozdílné možnosti srovnání skupin.

Typicky se řeší při:

- Při konstrukci diagnostických metod: je test jako celek „férový“ pro různé skupiny respondentů?
- Large-scale assessment: Do jaké míry mohu srovnávat skóry respondentů napříč zeměmi/státy/kulturami atd.?
- Teoreticky při každém použití t-testu by měla být vyargumentovaná invariance napříč oběma skupinami, aby je bylo možné srovnat.

# Test bias: Invariance měření

---

Konstrukce série multi-group modelů.

- V úvodním (konfigurálním) modelu jsou parametry odhadnuty zcela volně.
- V dalších modelech jsou parametry postupně *omezovány* na stejné hodnoty napříč skupinami.

V každém kroku testujeme, zda se shoda modelu s daty nezhoršila.

Absolutní shoda: LRT,  $\Delta\chi^2$  test (signifikance rozdílu ve shodě s daty).

- Teoreticky chí-rozložení se statistikou  $\Delta\chi^2 = \chi^2_{H_1} - \chi^2_{H_0}$  a s  $\Delta df = df_{H_1} - df_{H_0}$  stupni volnosti.
- Prakticky se nepoužívá; pokud je použit robustní odhad CFA modelu, je potřeba statistiky škálovat.
- Masivní síla testu, detekuje i věcně bezvýznamné rozdíly.

Relativní shoda:  $\Delta CFI$ ,  $\Delta TLI$ ,  $\Delta RMSEA$ ,  $\Delta SRMR$  menší než cut-off.

- Řada různých doporučení, která se výrazně liší. Typicky jsou rozdíly do 0,015 zanedbatelné.
- Doporučuji konvence reportování podle Putnicka a Bornsteina ([2016](#)).

# Stupně invariance:

---

## Základní stupně:

- 1. Konfigurální invariance.
- 2. Metrická (slabá invariance).
- 3. Skalární (silná invariance).

## „Doplňkový“ stupeň:

- 4. Reziduální (striktní) invariance.

## Ekvivalence populací

- 5. Shoda faktorových průměrů.
- 6. Shoda faktorových rozptylů.

## Jednotlivé stupně/úrovně:

- Vyšší úrovně zahrnují všechny požadavky úrovní nižších.
- Nižší úrovně jsou předpokladem úrovní vyšších.

## Analogie k „paralelním položkám“

- Paralelní položky: srovnání různých položek navzájem uvnitř jedné skupiny.
- Invariance: srovnání stejných položek napříč skupinami.

# Stupně invariance:

---

## 1. Konfigurální invariance:

- Test má stejnou strukturu (počet faktorů, přiřazení položek faktorům atd.) napříč skupinami.
- Měří tedy obsahově „ty stejné rysy“, ale klidně úplně „jinak“.
- Přesná definice rysů se může mírně lišit.
- Nelze srovnávat M a SD napříč skupinami, měřítko metody je jiné.

## 2. Metrická (slabá) invariance:

- Faktorové náboje v CFA jsou shodné (intercepty se mohou lišit).
- „Definice“ latentního rysu je stejná, má „stejné měřítko“, ale referenční bod je odlišný.
- Umožňuje srovnávat korelace latentních skóru napříč skupinami apod.
- Analogie tau-ekvivalentních položek.

# Stupně invariance:

---

## 3. Skalární (silná) invariance

- Intercepty v CFA jsou stejné napříč skupinami.
- Umožňuje srovnávat průměry latentních skóru skupin či respondenty napříč skupinami.
  - Např.: Češi mají vyšší skóre v PISA testech než Slováci (asi nemají ☺).
  - Např.: Pacienti v dotazníku dosahují nižšího skóre než neklinická populace.
- Analogie paralelních položek.
- V tomto případě má prostý součet položek stále trochu jiný „význam“ (kvůli rozdílným reziduálním rozptylům).
  - Lze ale zanedbat, má vliv jen na signifikanci srovnání skupin a velikost efektu, nikoliv na „možnost“ takového srovnání.

# Stupně invariance:

---

## 4. Reziduální (striktní) invariance

- Položky mají v CFA modelu stejný chybový rozptyl.
- Analogie striktně-paralelních položek.
  - Vztah součtu položek a latentního rysu je napříč skupinami stejný.

## 5. a 6. Paralelní skupiny

- Na rozdíl od předchozího není vlastností testu, ale skupiny.
- Jednotlivé skupiny respondentů mají stejné průměry a rozptyly.
- Jinými slovy: neexistuje rozdíl napříč skupinami v měřených proměnných.
  - Vzorky byly vybráni ze „stejné populace“.

# Typické stupně invariance

- Alternativně lze fixovat vybraný faktorový náboj, nikoliv lat. rozptyl.
- Pořadí není zcela pevně dané, jen 1. a 2. krok jsou nezbytné pro všechny další;
- Krok 3 je předpokladem pro 5a a 6; 5a a 5b lze přeskočit a rovnou testovat 6.
- Pozor, v ordinální CFA a v IRT jsou určité odlišnosti!

	náboje	intercepty	rezidua	lat. průměry	lat. rozptyly
<b>1. konfigurální</b>	volné	volné	volné	fixované (0)	fixované (1)
<b>2. metrická (slabá)</b>	omezené	volné	volné	fixované (0)	ref. skup. fixované (1) další skup.: volné
<b>3. skalární (sílná)</b>	omezené	omezené	volné	ref. skup. fixované (0) další skup.: volné	ref. skup. fixované (1) další skup.: volné
<b>4. reziduální (striktní)</b>	omezené	omezené	omezené	ref. skup. fixované (0) další skup.: volné	ref. skup. fixované (1) další skup.: volné
<b>5a. ekvivalence průměrů</b>	omezené	omezené	omezené	fixované (0)	ref. skup. fixované (1) další skup.: volné
<b>5b. ekvivalence rozptylů</b>	omezené	omezené	omezené	ref. skup. fixované (0) další skup.: volné	fixované (1)
<b>6. ekvivalentní skupiny</b>	omezené	omezené	omezené	fixované (0)	fixované (1)

# Alternativní způsoby ověření invariance

---

Multi-group CFA není jediným postupem.

Přehled všech postupů předkládá [Kim, Cao, Wang and Nguyen \(2017\)](#).

- Multiple group confirmatory factor analysis (MG CFA).
- Multilevel confirmatory factor analysis (ML CFA).
- Multilevel factor mixture modeling (ML FMM).
- Bayesian approximate M.I. testing (using BSEM).
- Alignment optimization.

Není nutné znát. MG CFA je zlatý standard a v psychologii postačuje.

- Potíž nastává při velkém množství skupin, kdy jsou alignment, ML CFA a BSEM výhodnější (typicky v mezinárodních ILSA studiích).

# Invariance: Další téma

---

## Invariance v IRT a ordinální CFA

- Typicky je komplikovanější odlišení metrické a skalární invariance.
- Řada různých parametrizací, řada zádrhelů.

## Modifikační indexy invariantní MG CFA modelu

- Analogie top-down DIF analýzy.

## Longitudinální invariance

- Měří test ten samý rys u těch stejných respondentů v průběhu času?
- Vývojová psychologie, intervence, terapie...

## Využití invariance a DIF při vyvažování paralelních forem

- Invariance kotevních testů, DIF kotevních položek.

## Invariance jako nedílná součást ILSA (International Large Scale Assessment)

- Dost krize.

# Doporučený postup

(Cígler, personal communication ☺)

---

Během vývoje testu: průběžné DIF analýzy (souběžně s položkovými analýzami) pro ověření kvality položek.

Během standardizace:

- Ověření invariance metody.
- Pokud je non-invariantní, pak DIF analýza pro identifikaci problémových položek.
- Vyřazení problémových položek, případně úprava skórování.
- U raschovských metod někdy agregace DIF analýz namísto analýzy invariance (WJ-IV).

Během vyvažování paralelních forem testu či adaptace.

- Kombinace analýz DIF a invariance.

Po standardizaci za účelem validizace.

- Dodatečné analýzy invariance pro skupiny nezahrnuté do standardizační studie.

# Take-home message

---

1. Férovost (fairness) je zavedený termín v oblasti validity.
2. Diagnostická vs. psychometrická rovina férovosti.
3. Nelze srovnávat lidi napříč různými skupinami bez dostatečné empirické podpory.
4. Dobrá diagnostická metoda by měla poskytovat výsledky analýz invariance a DIF napříč smysluplnými populacemi.
5. Zvážení férovosti je nezbytnou součástí psychologické diagnostiky.  
„Dodal mi vydavatel testu dostatek informací“?  
„Cítím dostatečnou podporu pro validitu ve smyslu důsledků testování“?
6. Termíny: DIF, invariance, response/item/test/predictive bias, accessibility, universal design, akomodace/modifikace.