

Řešení tohoto příkladu je podobné řešením mnoha příkladů, které jsme tento semestr probírali. Doporučuji tedy vykoušet si řešení příkladu samostatně a následující text považovat pouze pro kontrolu =).

1. Vytvoříme funkci `SimTSBinom()`, která pro zadání hodnoty parametrů p , N a počet simulací M vykreslí jeden graf s histogramem. Součástí histogramu bude popisek s Haldovou podmínkou. Barva histogramu se bude měnit v závislosti na hodnotě Haldovy podmínky $N \cdot p(1-p) > 9$.
- $Np(1-p) \leq 9 \Rightarrow$ barva histogramu bude červená
 $Np(1-p) > 9 \Rightarrow$ barva histogramu bude zelená

`SimTSBinom` ← function($N, p, M = \dots$) {

`X` ← replicate(..., rbinom(1, ...)) ... vektor $M=1000$ máh. reličin $\approx \text{Bin}(N, p)$ ($M=1000 \times$ vygenerujeme 1 máh. reličin $\approx \text{Bin}(N, p)$)

`zW` ← $\frac{x/N - p}{\sqrt{p(1-p)/N}}$... vektor $M=1000$ test. statistik `zW` pro $M=1000$ máh. reličin $X \approx \text{Bin}(N, p)$

`xfit` ← ... poloprůměr od $\min(zW) - 2$ do $\max(zW) + 2$ a dále minimálně 500

`yfit` ← `dnorm(...)` hustota $N(0,1)$ nad poloprůměrem `xfit`

`Hp` ← `round(...)` ... Haldova podmínka $Np(1-p)$ zaokrouhlená na 4 des. místa

`d` ← `max(yfit, hist(zW, plot=F)$dens)` ... máme nejvyšší hodnotu z nejširší sloupce histogramu a hustoty $N(0,1)$ nad pol. `xfit`

`if(Hp <= 9) { c.hist <- 'red'; c.lines <- 'darkred' }` ... nastavení červených odstínů histogramu a

`if(Hp > 9) { c.hist <- ... ; ... }` ... nastavení zelených odstínů histogramu a křivky hustoty, když $Np(1-p) \leq 9$

`hist(zW, ... , col=c.hist, breaks=seq(floor(min(zW)), ceiling(max(zW)), by=0.5),`

`ylim=c(0,d), ...)` ... histogram `zW`

`box(bty='o')` ...

`lines(... , col=c.lines, ...)` ... křivka $N(0,1)$; barva závisí na hodnotě složené v proměnné `c.lines`

`mtext(bquote(...), ...)` ... popisek `zW`

`mtext(paste(...), ...)` ... popisek $N = \dots, p = \dots, Hp = \dots$

}

2. Vytvoříme animaci ukazující změnu rozdělení test. statistik `zW` při $N \rightarrow \infty$ pro (a) $p=0.1$; (b) $p=0.5$; (c) $p=0.9$ majícíma.

`N` ← c(5, 10, ...) ... poloprůměr N u nastavení příkladu
 ... úvodní nastavení animace

`saveLatex` (for(i in 1:length(`N`))) {

`par(...)` ; 4×2

`SimTSBinom(N=N[i], p=0.1)` (a)

`SimTSBinom(...)` (b)

`SimTSBinom(...)` (c)

}

Nezapomeňte uvést komentář, zda podle vás Haldova podmínka dobře ukazuje na situaci, kdy je možné rozdělení testovací statistiky `zW` aproximovat normálním rozdělením $N(0,1)$ a kdy neapakah.

$X \sim \text{Bin}(N, p)$, $N=30$, $p=0.8$. V $N=30$ mas kato celkem $x=24$ uspěchů $\Rightarrow \hat{p} = \text{Pr}(X=1) = \frac{24}{30} = 0.8$.

skutečná, teoretická hodnota parametru p
(máme ji, odhadujeme ji)

odhad parametru p ma
podobu naměřených dat (počet
uspěchů v N pokusech)

Waldov (1- α)100%. DIS pro parametr p :

$$(dh_j, hh_j) = \left(\frac{x}{N} - u_{1-\alpha/2} \sqrt{p(1-p)/N}, \frac{x}{N} + u_{\alpha/2} \sqrt{p(1-p)/N} \right) = (0.657, 0.943)$$

Myslenka výpočtu při pokrytí Waldova (1- α)100%. IS je odlišná od té, kterou jsme používali při výpočtu při pokrytí Waldova IS pro μ (resp. σ^2). Zde vyvíjíme toho, že počet úspěchů v N pokusech je konečný. Při pokrytí počítáme podle vzorce:

$$\text{Pr}(\text{pokrytí}) = \sum_j \text{Pr}(X=Np_j : p \in \text{Waldova } 95\% \text{ DIS pro } p_j), \quad (*)$$

$$p_j \in \left\{ \frac{1}{N}, \frac{2}{N}, \dots, \frac{N-2}{N}, \frac{N-1}{N} \right\}$$

Myslenku vzorce je nejnadhší vyvíjet márově pomocí tabulky, která je jedním z finálních výsledků příkladu. Zaměřte-li se postupně na jednotlivé sloupce tabulky, pochopíte i jednotlivé kroky vedoucí k výsledné při pokrytí.

x_j	p_j	dh_j	hh_j	$\text{Pr}(X=Np_j)$	$p \in IS_j$
1	1/30	-0.0309	0.0976	0	0
2	2/30	-0.0226	0.1559	0	0
...
13	13/30	0.2560	0.6107	0	0
14	14/30	0.2881	0.6452	0	0
15	15/30	0.3211	0.6789	0.0001	0
16	16/30	0.3548	0.7119	0.0007	0
...
26	26/30	0.7450	0.9883	0.1325	1
27	27/30	0.7926	1.0074	0.0785	1
28	28/30	0.8441	1.0226	0.0337	0
29	29/30	0.9024	1.0309	0.0093	0

$$\frac{x_j}{N} = u_{1-\alpha/2} \sqrt{p_j(1-p_j)/N}$$

dobrá hranice Waldova IS pro p_j

$$\frac{x_j}{N} = u_{\alpha/2} \sqrt{p_j(1-p_j)/N}$$

dobrá hranice Waldova IS pro p_j

$$\text{Pr}(X=Np_j) = \text{binom}(x_j, N, p)$$

Při x_j na počtu úspěchů, že $X \sim \text{Bin}(N, p)$, bude počet úspěchů právě x_j

$$I(p \in (dh_j, hh_j))$$

indikační funkce: $I(\dots) = 1$, pokud $p \in (dh_j, hh_j)$
 $I(\dots) = 0$, pokud $p \notin (dh_j, hh_j)$
Nakonec odhad $p(\hat{p})$ do Waldova IS.

$$\text{Pr}(\text{pokrytí}) = \sum_j \text{Pr}(X=Np_j : p \in (dh_j, hh_j)) = \text{sum}(\text{Pr}(X=Np_j) * (p \in IS_j))$$

1. Vytvoříme funkci PokrytiWSL(), která pro nastané hodnoty N, p, α a zvolený typ intervalu (každým pouze Waldův) vrátí (a) tabulku 29 x 6 uvedenou ve výsledcích; (b) pst. pokrytí. V rámci příkladu 8.3 dohalíme tuto funkci o skóre a věrohodnostní typ intervalu.

```
PokrytiWSL <- function(p, N, alpha = ..., type = 'wald') {
```

```
  xj <- ... posloupnost celých čísel od 1 do (N-1). Lze definovat např. pomocí:
```

```
  pj <- xj / N ... vektor pravděpodobnosti pj (délka = N-1 = 29 (pro N=30))
```

```
  if (type == 'wald') {
```

```
    dhj <- xj / N - u_{1-\alpha/2} \sqrt{p_j(1-p_j)/N} ... vektor dolních hranic Waldových IS (délka = N-1)
```

```
    hhj <- xj / N + u_{\alpha/2} \sqrt{p_j(1-p_j)/N} ... vektor horních hranic Waldových IS (délka = N-1)
```

```
  }
```

(*)... zde potom v rámci příkladu 8.3 doplníme výpočet dolní a horní hranice skóre a věrohodnostního IS.

```
  pr.X.Npj <- dbinom(...) ... Pr(X=Npj) za předp. že  $X \sim \text{Bin}(N, p)$  ... vektor o délce N-1
```

```
  p.in.ISj <- (p > dhj & p < hhj) ... p \in ISj ... vektor o délce N-1
```

```
  tab <- data.frame(...) ... tabulka výsledků se sloupci xj, pj, dhj, hhj, pr.X.Npj, p.in.ISj
```

```
  pst.pokryti <- sum(Pr(X=Npj) * (p \in ISj)) ... výpočet pst. pokrytí (1 číslo)
```

```
  return(list(tab=tab, pst.pokryti = pst.pokryti)) ... seznam(list) výsledků používáme tehdy, když chceme, aby funkce měla více výstupů. Na každý výstup se potom odvoláváme přes $. (viz bod 2.)
```

2. Pomocí funkce PokrytiWSL() vygenerujeme tabulku 29 x 6 pro (a) $N=30, p=0.8$; (b) $N=30, p=0.79$. Při tom si vyhovíme 'dovolaání se konkrétního výsledku pomocí \$'.

```
tab80 <- PokrytiWSL(p=0.8, N=30, ...) $ tab
```

```
round(tab80, 4) ... zaokrouhlení na 4 des. místa
```

```
tab79 <- PokrytiWSL(...) $ tab
```

```
round(tab79, ...) ... zaokrouhlení na 4 des. místa
```

3. Pomocí funkce PokrytiWSL(...) vypočítáme pst. pokrytí pro Waldův 95% IS při (a) $N=30, p=0.8$; (b) $N=30, p=0.79$.

```
pst.pokryti80 <- PokrytiWSL(...) $ pst.pokryti
```

```
pst.pokryti79 <- PokrytiWSL(...) $ pst ... konkrétní výstup získáme, když jej přes $ navolaáme jeho názvem. Názvem však nemusíme psát celý. Vyhovíme si to tak, že místo $ pst.pokryti napíšeme pouze $pst nebo $p, apod.
```

```
tab.pst <- data.frame(...) ... tabulka obsahující obě pst. pokrytí.
```

```
round(tab.pst)
```

Komentář: $\alpha=0.05 \rightarrow$ Očekávaná pst. pokrytí Waldova 95% IS je tedy 0.95. Uvědomme si, že pokud máme reálnou situaci, kdy v $N=30$ pokusech sledujeme počet úspěchů, potom odhad skutečného pst. nastání úspěchu p (tj. $\hat{p} = \frac{X}{N}$) je velmi hrubý, protože je založen na diskrétním počtu úspěchů x . Tento deficit se projevuje právě např. na níže pst. pokrytí. Pokud skutečná pst. úspěchu $p=0.8$, a počet úspěchů v $N=30$ pokusech je 24, tj. $\hat{p} = \frac{X}{N} = \frac{24}{30} = 0.8$, je vše v pořádku a pst. pokrytí Waldova IS je cca 0.95. Nicméně, co když je skutečná pst. úspěchu $p=0.79$? Nejblížeším odhadem je opět $\hat{p} = \frac{24}{30} = 0.8$, ale vidíme, že tento odhad už je nepřesný. Pst. pokrytí v tomto případě klesá na cca 0.89.

V tomto příkladu se zaměříme na globální pohled na psi pokrytí Waldova 95% DIS. Začínáme v příkladu 56.2 jsme spočítali psi pokrytí Waldova 95% DIS na předpokladu, že $X \sim \text{Bin}(N, p)$, kde (a) $p = 0.80$, (b) $p = 0.79$, kde si psi pokrytí spočítáme pro každé $p \in \{0.001, 0.003, \dots, 0.997, 0.999\}$. Následně vykreslíme graf závislosti psi pokrytí na hodnotě p . Graf vykreslíme pro (i) $N=30$; (ii) $N=100$; (iii) $N=500$. Nakonec do funkce `PokrytiWSL()` doprogramujeme výpočet psi pokrytí pro skóre DIS a věrohodnosti DIS a vykreslíme analogické grafy pro skóre a věrohodnosti 95% DIS.

I. Vykreslení grafu psi pokrytí Waldova 95% DIS:

Paramátka: Ze zadání víme, že máme finálně vykreslit 3 grafy pro Waldov 95% DIS, 3 grafy pro skóre 95% DIS a 3 grafy pro věrohodnosti 95% DIS. Nejlegantnější lidky bude vytvořit funkci `PokrytiPlot()`, která pro zadání hodnoty N , α a typ IS máti příslušný graf.

1. Vytvoříme fci:

```

PokrytiPlot ← function(N, alpha = ..., type = 'wald') {
  pst ← ... posl. od 0.001 do 0.999 po kroku 0.002
  pokryti ← NULL ... příprava prázdného vektoru
  for(i in 1:length(pst)) {
    pokryti[i] ← PokrytiWSL(p = pst[i], N = N, alpha = alpha, type = type)
  } ... cyklus... pro každou hodnotu  $p$  vektoru  $pst$  spočítá  $pst$  pokrytí.
  if(type == 'wald') {text ← bquote(paste(...))} ... popisek 'Waldov XX% IS, N = ...'
  (*) if( -||- 'score') {text ← ...} ... popisek 'Skóre XX% IS, N = ...'
  if( -||- 'likely') {text ← ...} ... popisek 'Věrohodnosti XX% IS, N = ...'
  par(...) ... 4  $\frac{2}{5}$ 
  plot(pst, pokryti, ylim = c(0.6, 1), ...) ... vykreslení grafu psi pokrytí
  mtext(...) ... popisek 'p'
  mtext(text, ...) ... popisek zvolený v závislosti na typu IS (viz (*))
  abline(...) ... vodorovná šedá čára v hodnotě koeficientu spolehlivosti (1- $\alpha$ )
}

```

Annotations:
 - `type = 'wald'`: automaticky se mění podle `type IS` ve fci `PokrytiWSL()` bude taková, jakou zadáme ve fci `PokrytiPlot()`.
 - `type = 'score'`: automaticky se mění podle `type IS` ve fci `PokrytiWSL()` bude stejný jako si zvolíme ve fci `PokrytiPlot()`.
 - `type = 'likely'`: automaticky se mění podle `N`.
 - `par(...)`: automaticky se mění podle `N`.
 - `abline(...)`: automaticky se mění podle `N`.
 - `popisek 'Waldov XX% IS, N = ...'`: $\cdot ((1-\alpha)*100)$ $\cdot (N)$

2. Fci `PokrytiPlot()` použijeme pro vykreslení grafu psi pokrytí Waldova 95% DIS pro (i) $N=30$; (ii) $N=100$; (iii) $N=500$:

```

par(...) ...  $\frac{2}{5}$  ... abno rozdělíme na 9 grafů: 3x3
N ← c(30, 100, 500)
for(i in 1:length(N)) { PokrytiPlot(N = N[i], type = 'wald') }

```

Tip: Analogicky si ověřte vykreslení psi pokrytí Waldova 99% DIS. Zkontrolujte si, zda se vám správně změnil popisek pod osou x i poloha horizontální referenční čáry.

Zopakujte si definici konzervativního a liberálního IS (viz cv. 04). V komentářích uveďte zda je Waldov DIS pro parametru p konzervativní, liberální, nebo ani jedno.

II. Doplnění vzorů na výpočet psi pokrytí skóre a věrohodnostního (1- α)100% DIS.

V této části se vrátíme k funkci **PokrytiWSL()**, kde na výpočetní místo (*) doplníme výpočet vektoru dolních hranic a vektoru horních hranic (1) skóre DIS pro $p_j, j=1, \dots, N-1$; (2) věrohodnostních DIS pro $p_j, j=1, \dots, N-1$. V obou případech pojmemujeme vektor dolních hranic dh_j a vektor horních hranic hh_j . Tím zajistíme hladkou návaznost následujících příkazů (pr. X.Np $j \leftarrow \dots, (\dots)$, **return(list(...))** bez ohledu na zvolený typ IS.

1. Doplnění výpočtu hranic skóre (1- α)100% DIS ve fci **PokrytiWSL()**:

Hranice (1- α)100% skóre DIS vyjádříme explicitně pomocí následujícího vzorce (ochvězení finálního vzoru viz teorie, slidy k přednáškám nebo kniha Aplikovaná štatistická inferencia I (Kalina, Králík, Hupková))

$$IS = (dh_j; hh_j) = \left(\hat{p} \left(\frac{N}{N+u^2} \right) + \frac{1}{2} \frac{u^2}{N+u^2} - u \sqrt{\frac{1}{N+u^2} \left[\hat{p}(1-\hat{p}) \frac{N}{N+u^2} + \frac{1}{4} \frac{u^2}{N+u^2} \right]}; \right. \\ \left. \hat{p} \left(\frac{N}{N+u^2} \right) + \frac{1}{2} \frac{u^2}{N+u^2} + u \sqrt{\frac{1}{N+u^2} \left[\hat{p}(1-\hat{p}) \frac{N}{N+u^2} + \frac{1}{4} \frac{u^2}{N+u^2} \right]} \right)$$

kde $u = u_{1-\alpha/2} = qnorm(1-\alpha/2)$.

```
if (type == 'score') {
  u <- qnorm(...) ... u_{1-\alpha/2}
  dh_j <- p_j * (N/(N+u^2)) + ... vektor dolních hranic skóre IS (délka = N-1)
  hh_j <- p_j * (N/(N+u^2)) + ... vektor horních hranic skóre IS (délka = N-1)
}
```

Pozn: Nuvapomínka w útem monci mabadi
 \hat{p} vektorem p_j . Analogicky jako jsme to provedli w příkazech posílajících vektor dolních, resp. horních hranic Waldova IS w 6.2.

Pozn: Při opisování vzorců do proměnných dh_j a hh_j buďte velmi opatrní a napiš si několikrát zkontrolujte. Vzorce jsou opravdu složité a často si w nich při přepisu chybně!!!

2. Doplnění výpočtu hranic věrohodnostního (1- α)100% DIS ve fci **PokrytiWSL()**:

Pro výpočet hranic věrohodnostního DIS explicitní vzorce neexistují. Oblast věroh. DIS je opět definována jako množina hodnot p , pro které je test. statistika $ULR < \chi^2_{1-\alpha}(1)$. Přibližné hranice DIS bychom tedy mohli nalézt analogicky jako w příkladech 5.8, 6.6 a 7.3. Přesnost hranic však w těchto příkladech závisela na zvolení parametrů (μ, σ^2 , resp. g). Zde si ukážeme nový přístup, který nám hranice IS spočítá přesně. Stejný postup si pak můžeme cvičně zkusit pověřit w příkladech 5.8, 6.6 a 7.3 a vypočítat si přesné hranice těchto IS.

Mýšlenka nového přístupu je založena na převedení nerovnosti $ULR < \chi^2_{1-\alpha}(1)$ na rovnost $ULR - \chi^2_{1-\alpha}(1) < 0$. Tj. graficky:



Hranice věrohodnostního (1- α)100% DIS nalazeme jako kořeny rovnice $ULR - \chi^2_{1-\alpha}(1) \leq 0$ např. pomocí funkce **uniroot()**. Nalazení \leq ka $<$ mám w tomto případě w tolik mervadi. Kulaté rovnosti okolo IS definují, že hraniční hodnoty do IS stejně nespadají \Rightarrow .

```
if(type == 'likely') {
```

Připravte funkci `ULRchisq()`, která vráti hodnotu $U_{LR} - \chi^2_{1-\alpha}(1)$:

```
ULRchisq <- function(x, p, N, alpha = ... ) {
```

$$ULRchisq \leftarrow U_{LR} - \chi^2_{1-\alpha}(1) = -2 \ln(\lambda(X)) - \chi^2_{1-\alpha}(1) = 2 \left(x \ln \frac{x}{Np} + (N-x) \ln \frac{N-x}{N-Np} \right) - \chi^2_{1-\alpha}(1)$$

$-\ln(\lambda(X))$
(odvození viz teorie, slidy, nebo kniha A&SI.)

`qchisq(...)`

```
return(...)
```

Vypočítá vektorů dolních a horních hranic IS (délka = N-1):

```
dhj <- hhj <- NULL
```

definováno v úvodu fce `Pokryti.WSL()`

```
for(i in 1:length(pj)) {
```

```
dhj[j] <- uniroot(f = ULRchisq, ... fce, její kořen hledáme
```

`interval = c(1e-6, pj[j])`, interval, kde kořen leží (dolní hranice IS j bude určitě menší než 0 a hodnotou `pj` (protože `pj` je střed IS j))

```
x = xj[j], N = N, alpha = alpha) $root
```

specifikace všech ostatních parametrů fce `ULRchisq()`.

fce `uniroot()` otáčí více výsledků najednou. Hodnota kořene je uložena ve výsledku `root`.

```
hhj[j] <- uniroot(..., interval = c(pj[j], 1-1e-6), ...) ... vektor horních hranic vektoru DIS (délka = N-1).
```

Pozn: Ptáte se, proč jsme tento postup výpočtu přesných hranic nepoužili už dříve v příkladech 5.8, 6.6 a 7.3? Protože i já se přibližně učím nové metody a vylepšuji staré postupy, ma lepší a přesnější. A toto je přesně ten případ =>

3. Vykreslení grafů pátí pokrytí skóre a věrohodnostního 95% DIS:

Grafy vykreslíme opět pro (i) N=30; (ii) N=100; (iii) N=500, a to pomocí fce `Pokryti.Plot()`.

Pokud jsme fce maprogramovali pomocí postupu uvedeného v I-1, nemusíme už nic modifikovat.

Pouze znovu spusíme kód obou funkcí `Pokryti.WSL()` a `Pokryti.Plot()`, abychom je aktualizovali a můžeme vykreslovat.

```
N <- c(30, 100, 500)
```

```
for(i in 1:length(N)) { Pokryti.Plot(..., type = 'score') } ... kójice grafů pátí pokrytí skóre DIS (N=30, 100, 500)
```

```
for(i in 1:length(N)) { Pokryti.Plot(..., type = 'likely') } ... kójice grafů pátí pokrytí věroh. DIS (-11-).
```

Pozn: Závěrem opět v komentářích uvedte, zda je skóre a věrohodnostní DIS konzervativní, liberální, nebo ani jedno.

Pozn: Výpočet pátí pokrytí věrohodnostního DIS je časově i výpoččetně náročný. Uvědomme si, že pro situaci N=500 hledáme pro každé $p \in \{0.001, 0.003, \dots, 0.999\}$ 499 x dolní hranici (pro $\forall p_j, j=1 \dots (N-1)$) a 499 x horní hranici. Množina $\{0.001, 0.003, \dots, 0.999\}$ obsahuje 500 hodnot. Funkce `uniroot()` tedy pro N=500 potřebuje $499 \times 500 \times 2 = 499\,000 \times$. Z toho důvodu může vykreslení grafů (v závislosti na počítači) trvat dle. (U mě mapř. 2-3 minuty.)

Z řešení příkladu 8.3 vidíme, že Waldův IS si ve všech tří případech intervalů vedl nejhůř. Jeho aktuální psd pokrytí je pro malá N výrazně nižší než nominální psd pokrytí. Stejně tak je aktuální psd pokrytí neuspokojivá pro velká N ($N=500$) je-li psd p moc malá ($p < 0.1$) nebo moc velká ($p > 0.9$). Navíc se v praxi může stát že dolní hranice Waldova IS bude menší než 0 (pokud \hat{p} bude blízký 0) nebo větší než 1 (pokud \hat{p} bude blízký 1). Toto všechno jsou nežádoucí vlastnosti Waldova DIS. Jeho nespornou výhodou je však výpočetní jednoduchost (malá náročnost při srovnání s rozhodnutím DIS). Smotou statistiku tedy bylo najít kompromis mezi výpočetní jednoduchostí a uspokojivými vlastnostmi DIS. Jednou z cest jsou tzv. zpětně transformované DIS. Jejich myšlenka je založena na tom, že vytvoříme vhodnou transformaci parametru p (tj. $g(p)$), pomocí Δ metody spočítáme odhad rozptylu této transformace (tj. $\text{Var}[g(\hat{p})]$). Vypočítáme dolní a horní hranici DIS pro tuto transformaci (výpočet DIS je založen na Waldově principu), tj. obě:

$$(dh_g; hh_g) = \left(g(\hat{p}) - u_{1-\alpha/2} \sqrt{\text{Var}[g(\hat{p})]} ; g(\hat{p}) - u_{\alpha/2} \sqrt{\text{Var}[g(\hat{p})]} \right)$$

a nakonec hranice IS pro transformaci zpětně transformujeme (vhodnou transformací) na hranice IS pro parametru p .

Z teorie již známe tři (více či méně vhodné) transformace parametru p :

1. podíl šancí:

$$g(p) = \frac{p}{1-p} \quad \text{Var}[g(\hat{p})] = \frac{\hat{p}}{N(1-\hat{p})^2}$$

Zpětná transformace: $(dh; hh) = \left(\frac{dh_g}{1+dh_g} ; \frac{hh_g}{1+hh_g} \right)$

2. logaritmus podílu šancí:

$$g(p) = \ln\left(\frac{p}{1-p}\right) \quad \text{Var}[g(\hat{p})] = \frac{1}{N\hat{p}(1-\hat{p})}$$

Zpětná transformace: $(dh; hh) = \left(\frac{e^{dh_g}}{1+e^{dh_g}} ; \frac{e^{hh_g}}{1+e^{hh_g}} \right)$

3. arcussinus:

$$g(p) = \arcsin(\sqrt{p}) \quad \text{Var}[g(\hat{p})] = \frac{1}{4N}$$

Zpětná transformace: $(dh; hh) = (\sin^2(dh_g) ; \sin^2(hh_g))$

Jak kvalitní jsou vlastnosti všech tří výše uvedených DIS z hlediska psd pokrytí si ukážeme v tomto příkladu. =)

Tip: Proverte si odvození $\text{Var}[g(\hat{p})]$ pomocí Δ metody ve všech 3 případech.

Zde si pro ukázkou odvodíme $\text{Var}[g(\hat{p})]$ pro $g(p) = \ln\left(\frac{p}{1-p}\right)$:

$$L(p|x) = p^x (1-p)^{N-x}$$

$$l(p|x) = x \ln p + (N-x) \ln(1-p)$$

$$\frac{\partial}{\partial p} l(p|x) = \frac{x}{p} - \frac{N-x}{1-p}$$

$$\frac{\partial^2}{\partial p^2} l(p|x) = -\frac{x}{p^2} - \frac{N-x}{(1-p)^2}$$

$$I(p) = -\frac{\partial^2}{\partial p^2} l(p|x) = \frac{x}{p^2} + \frac{N-x}{(1-p)^2}$$

$$\begin{aligned} I(\hat{p}) &= \frac{x}{\hat{p}^2} + \frac{N-x}{(1-\hat{p})^2} \quad | x = N\hat{p} \\ &= \frac{N\hat{p}}{\hat{p}^2} + \frac{N-N\hat{p}}{(1-\hat{p})^2} = \frac{N}{\hat{p}} + \frac{N}{1-\hat{p}} \\ &= \frac{N(1-\hat{p}) + N\hat{p}}{\hat{p}(1-\hat{p})} = \frac{N}{\hat{p}(1-\hat{p})} \end{aligned}$$

$$g(p) = \ln\left(\frac{p}{1-p}\right)$$

$$\begin{aligned} \frac{\partial}{\partial p} \ln\left(\frac{p}{1-p}\right) &= \frac{1}{\frac{p}{1-p}} \cdot (p(1-p))^{-1} = \frac{1-p}{p} \cdot \frac{1-p+p}{(1-p)^2} \\ &= \frac{1-p}{p} \cdot \frac{1}{(1-p)} = \frac{1}{p(1-p)} \end{aligned}$$

Δ metoda:

$$\text{Var}[g(\hat{\theta})] = \left[\frac{\partial}{\partial \theta} g(\theta) \Big|_{\theta=\hat{\theta}} \right]^2 / I(\hat{\theta})$$

$$\text{Var}[g(\hat{p})] = \left[\frac{\partial}{\partial p} g(p) \Big|_{p=\hat{p}} \right]^2 / I(\hat{p})$$

$$= \left[\frac{\partial}{\partial p} \ln\left(\frac{p}{1-p}\right) \Big|_{p=\hat{p}} \right]^2 / I(\hat{p})$$

$$= \left[\frac{1}{\hat{p}(1-\hat{p})} \right]^2 / \left(\frac{N}{\hat{p}(1-\hat{p})} \right)$$

$$= \frac{1}{\hat{p}^2(1-\hat{p})^2} \cdot \frac{\hat{p}(1-\hat{p})}{N} = \frac{1}{N\hat{p}(1-\hat{p})}$$

1. Řešení příkladu je podobné řešením uvedeným v příkladech 8.1, 8.2 a 8.3. Nejprve vytvoříme funkci Pokryti ZT(), která pro zadání N, p, d a zvolenou transformaci vrátí pst. pokrytí.

```

Pokryti ZT <- function(p, N, alpha = ..., type = 'or'){
  xj <- ... pol. 1,2,...,(N-1)
  pj <- ... vektor psti pj (délka = N-1)

  if(type == 'or'){
    dhg <-  $\frac{p_j}{1-p_j} - u_{1-d/2} \sqrt{\frac{p_j}{N(1-p_j)^2}}$  ... vektor dolních hranic ISj pro podíl šanci (délka = N-1)
    hhg <-  $\frac{p_j}{1-p_j} + u_{d/2} \sqrt{\frac{p_j}{N(1-p_j)^2}}$  ... vektor horních hranic ISj pro podíl šanci (N-1)
    dh <-  $\frac{dhg}{1+dhg}$  ... (zpětná transform.) ; vektor dolních hranic zpětné transf. IS pro parametr p (N-1)
    hh <-  $\frac{hhg}{1+hhg}$  ... (zpětná transf.) ; vektor horních hranic zpětné transf. IS pro parametr p (N-1)
  }

  if(type == 'log'){
    dhg <- ... vektor dolních hranic ISj pro logaritmus podílu šanci (N-1)
    hhg <- ... vektor horních hranic ISj pro logaritmus podílu šanci (N-1)
    dh <- ... (zpětná transf.) ; vektor dolních hranic zpětné transf. IS pro parametr p (N-1)
    hh <- ... (zpětná transf.) ; vektor horních hranic zpětné transf. IS pro parametr p (N-1)
  }

  if(type == 'arcsin'){
    dhg <-  $\text{asin}(\sqrt{p_j})$  - ... vektor dolních hranic ISj pro arcsin( $\sqrt{\cdot}$ ) (délka = N-1)
    hhg <-  $\text{asin}(\sqrt{p_j})$  - ... -||- horních hranic -||- (N-1)
    dh <- ... (zpětná transf.) ; vektor dolních hranic zpětné transf. IS pro parametr p (N-1)
    hh <- ... (zpětná transf.) ; -||- horních hranic -||- (N-1)
  }
}

```

Stejně jako v Pokryti WSL()

```

{
  pr.X.Npj <- dbinom(...) ... Pr(X=Npj) na předpokladu, že X ~ Bin(N, p) ... (délka = N-1)
  p.in.ISj <- ... p ∈ ISj ... vektor o délce N+1
  pst.pokryti <- sum(Pr(X=Npj) * (p ∈ ISj)) ... výpočet psti pokrytí (číslo)
  return(pst.pokryti)
}

```

2. Vytvoříme funkci Pokryti ZTPlot(), která pro zadání hodnoty N, d a zvolený typ transformace vrátí příslušný graf.

Tip: funkce Pokryti ZTPlot() je analogická funkci Pokryti Plot(). Právě si ji můžete vytvořit sami. Stačí kód funkce Pokryti Plot() zkopírovat a vhodně modifikovat. =>

Tip2: Nechejte-li se vám vytvářet dvě nové funkce Pokryti ZT() a Pokryti ZTPlot(), můžete zkusit pouze rozšířit funkci Pokryti WSL() a Pokryti Plot() o kód s transformacemi a grafy psti pokrytí zpětné transf. DIS vygeneroval pomocí nich.

3. Vykreslíme grafy psti pokrytí zpětné transf. DIS s transformací (a) podílu šanci; (b) logaritmu podílu šanci; (c) arcsin($\sqrt{\cdot}$) pro (i) N=30; (ii) N=100; (iii) N=500. (Viz 8.3). + Nezapomejte na komentáře! =>