

## M7222 – 2. CVIČENÍ : GLM02a

*(Zotavení v závislosti na závažnosti nemoci a návštěvě nemocnice)*

Nejprve načteme vstupní data pomocí příkazu `read.csv2()` a podíváme se na jejich strukturu pomocí příkazu `str()`.

```
> fileDat <- paste(data.library, "InfectionSeverity.csv", sep = "")  
> data <- read.csv2(fileDat, header = TRUE, sep = ";", dec = ".")  
> str(data)

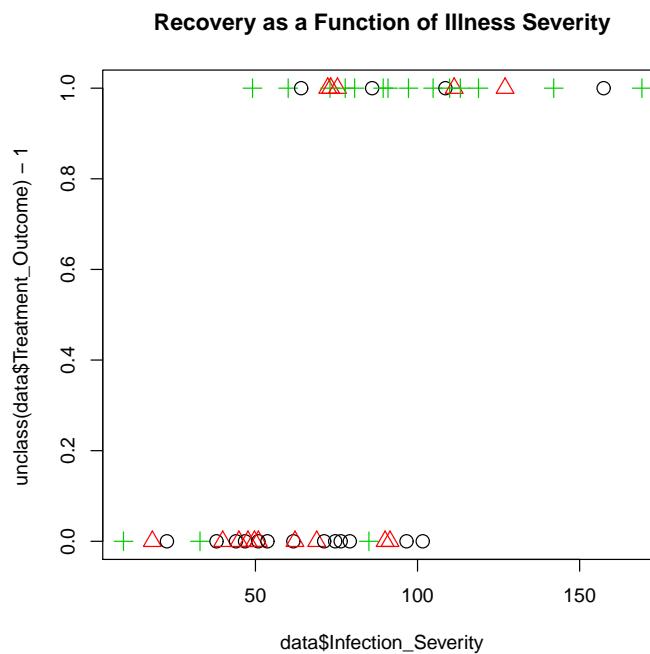
,data.frame,: 49 obs. of  3 variables:  
$ Infection_Severity: num  9.3 18.2 22.7 32.9 38 39.9 44 44.9 46.8 47.7 ...  
$ Treatment_Outcome : int  0 0 0 0 0 0 0 0 0 0 ...  
$ Hospital          : int  3 2 1 3 1 2 1 2 1 2 ...
```

Z proměnných, které jsou kategoriální, utvoříme pomocí příkazu `factor()` proměnné typu faktor.

```
> data$Treatment_Outcome <- factor(data$Treatment_Outcome, labels = c("survived",  
"died"))  
> data$Hospital <- factor(data$Hospital, labels = c("A", "B", "C"))
```

Data vykreslíme

```
> plot(data$Infection_Severity, unclass(data$Treatment_Outcome) - 1, type = "p",  
      pch = unclass(data$Hospital), col = unclass(data$Hospital), cex = 1.5,  
      main = "Recovery as a Function of Illness Severity")
```



Obrázek 1: Vykreslení dat pomocí příkazu `plot`.

Protože tento graf je málo srozumitelný, provedeme nejprve kategorizaci proměnné `Infection_Severity` do 10 subintervalů. Pak zjistíme počet osob, které přežily, popř. zemřely v jednotlivých subintervalech, na základě toho odpovídající relativní četnosti zemřelých.

```
> breaks_f_sev <- seq(0, 170, length.out = 11)
> f_sev <- cut(data$Infection_Severity, breaks = breaks_f_sev)
> (TabSurvDied <- table(f_sev, data$Treatment_Outcome))
```

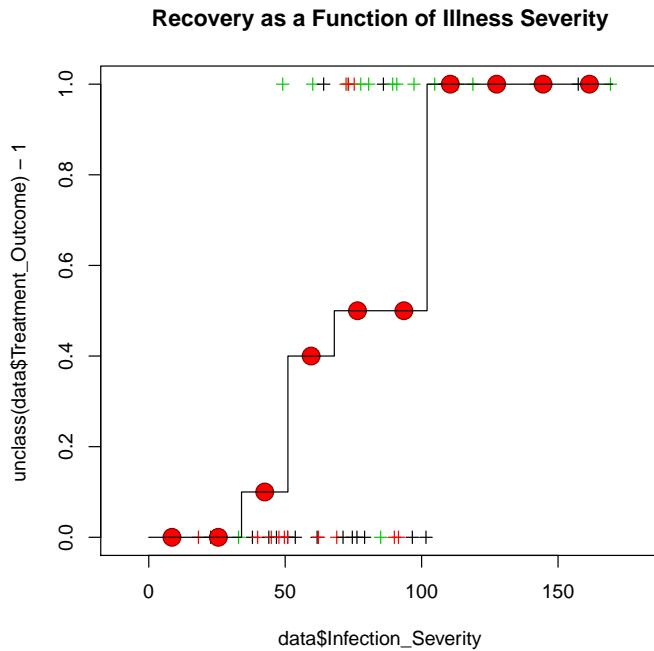
f_sev	survived	died
(0,17]	1	0
(17,34]	3	0
(34,51]	9	1
(51,68]	3	2
(68,85]	6	6
(85,102]	4	4
(102,119]	0	6
(119,136]	0	1
(136,153]	0	1
(153,170]	0	2

```
> RelativDied <- TabSurvDied[, 2]/rowSums(TabSurvDied)
> (tab2 <- cbind(TabSurvDied, RelativDied))
```

	survived	died	RelativDied
(0,17]	1	0	0.0
(17,34]	3	0	0.0
(34,51]	9	1	0.1
(51,68]	3	2	0.4
(68,85]	6	6	0.5
(85,102]	4	4	0.5
(102,119]	0	6	1.0
(119,136]	0	1	1.0
(136,153]	0	1	1.0
(153,170]	0	2	1.0

Předchozí graf nyní budeme modifikovat tak, abychom doplnili relativní četnosti zemřelých v jednotlivých kategoriích

```
> delta2 <- 0.5 * diff(breaks_f_sev)[1]
> N <- length(breaks_f_sev)
> plot(data$Infection_Severity, unclass(data$Treatment_Outcome) -
  1, type = "p", pch = 3, xlim = c(-10, 180), col = unclass(data$Hospital),
  main = "Recovery as a Function of Illness Severity")
> points(breaks_f_sev[1:(N - 1)] + delta2, tab2[, 3],
  pch = 21, col = "darkred", cex = 2, bg = "red")
> lines(breaks_f_sev, c(0, tab2[, 3]), type = "S")
```



Obrázek 2: Vykreslení relativních četností zemřelých.

MODEL 1 - binární regresní model s jedinou spojitou kovariátou  
**Infection\_Severity**

Za  $g$  volíme některou z linkovacích funkcí, takže dostáváme

$$\eta(\mathbf{x}) = g_1(\pi(\mathbf{x})) = \Phi^{-1}(\pi(\mathbf{x})) \quad \text{probitový model} \quad (1)$$

$$\eta(\mathbf{x}) = g_2(\pi(\mathbf{x})) = \log\left(\frac{\pi(\mathbf{x})}{1-\pi(\mathbf{x})}\right) \quad \text{logistický model} \quad (2)$$

$$\eta(\mathbf{x}) = g_3(\pi(\mathbf{x})) = \log[-\log(1-\pi(\mathbf{x}))] \quad \text{komplementární log-log model} \quad (3)$$

Nejprve zvolíme kanonickou linkovací funkci, takže dostaneme logistický regresní model:

```
> m1.logit <- glm(Treatment_Outcome ~ Infection_Severity,
  family = binomial(logit), data = data)
> summary(m1.logit)
```

```
Call:
glm(formula = Treatment_Outcome ~ Infection_Severity, family = binomial(logit),
  data = data)

Deviance Residuals:
    Min      1Q   Median      3Q      Max 
-1.7891 -0.6459 -0.2365  0.7533  1.9474
```

```

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept) -4.64050   1.38335 -3.355 0.000795 ***
Infection_Severity 0.05921   0.01758  3.368 0.000756 ***
---
Signif. codes:  0 ,***, 0.001 **, 0.01 *, 0.05 ., 0.1 , , 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 67.745  on 48  degrees of freedom
Residual deviance: 45.994  on 47  degrees of freedom
AIC: 49.994

Number of Fisher Scoring iterations: 5

```

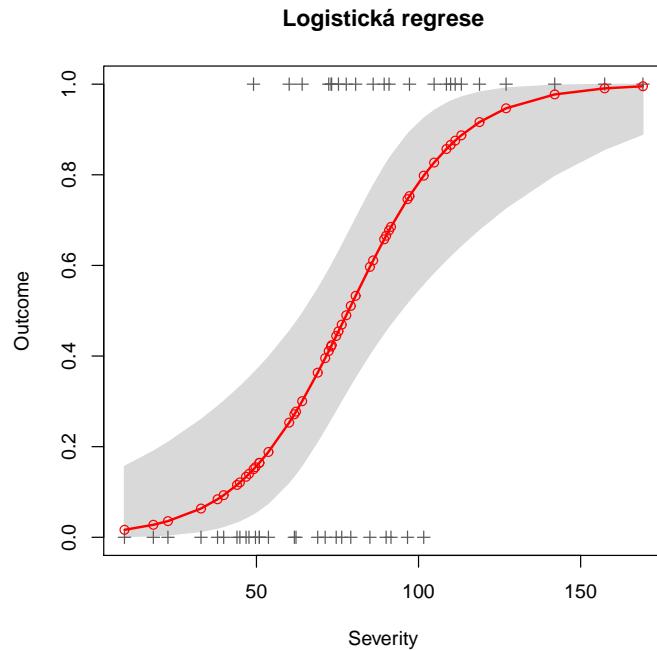
Vidíme, že kovariáta `Infection_Severity` je v tomto modelu statisticky významná.

Provedeme vykreslení výsledné logistické křivky spolu s asymptotickými intervaly spolehlivosti:

```

> predicted.logit <- predict(m1.logit, type = "link",
+                               newdata = data, se = T)
> data$CI.lower.logit <- plogis(predicted.logit$fit -
+                                     1.96 * predicted.logit$se.fit)
> data$fitted.logit <- plogis(predicted.logit$fit)
> data$CI.higher.logit <- plogis(predicted.logit$fit +
+                                     1.96 * predicted.logit$se.fit)
> x <- c(data$Infection_Severity, rev(data$Infection_Severity))
> y <- c(data$CI.lower.logit, rev(data$CI.higher.logit))
> plot(data$Infection_Severity, unclass(data$Treatment_Outcome) -
+       1, type = "n", pch = 3, ylab = "Outcome", xlab = "Severity",
+       main = "Logistická regrese")
> polygon(x, y, col = "gray85", border = "gray85")
> points(data$Infection_Severity, unclass(data$Treatment_Outcome) -
+          1, pch = 3, ylab = "Outcome", xlab = "Severity",
+          col = "gray35")
> lines(data$Infection_Severity, data$fitted.logit, col = "red",
+        lwd = 2)
> points(data$Infection_Severity, data$fitted.logit, col = "red")

```



Obrázek 3: Logistická regrese s intervaly spolehlivosti.

Podívejme se, jak dopadne **probitový regresní model** s jedinou kovariátou Infection\_Severity, to znamená musíme zvolit místo kanonické linkovací funkce jinou, a to probitovou linkovací funkci.

```
> m1.probit <- glm(Treatment_Outcome ~ Infection_Severity,
  family = binomial(probit), data = data)
> summary(m1.probit)
```

```
Call:
glm(formula = Treatment_Outcome ~ Infection_Severity, family = binomial(probit),
  data = data)

Deviance Residuals:
    Min      1Q   Median      3Q     Max 
-1.7885 -0.6427 -0.1742  0.7577  1.9636 

Coefficients:
            Estimate Std. Error z value Pr(>|z|)    
(Intercept) -2.824141   0.763012 -3.701 0.000214 *** 
Infection_Severity 0.036010   0.009699  3.713 0.000205 *** 
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

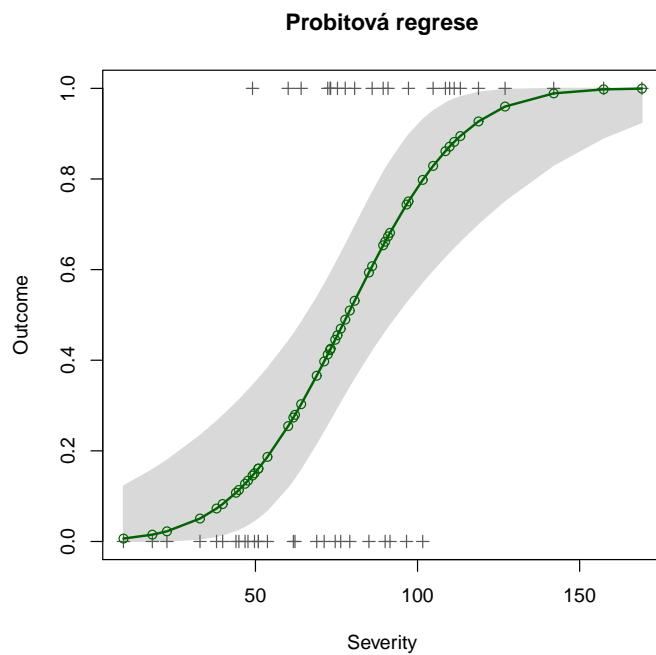
Null deviance: 67.745 on 48 degrees of freedom
Residual deviance: 45.597 on 47 degrees of freedom
AIC: 49.597

Number of Fisher Scoring iterations: 6
```

I v tomto modelu je kovariáta `Infection_Severity` statisticky významná.

Opět vykreslíme výslednou probitovou křivku spolu s asymptotickými intervaly spolehlivosti do grafu:

```
> predicted.probit <- predict(m1.probit, type = "link",
+     newdata = data, se = T)
> data$CI.lower.probit <- pnorm(predicted.probit$fit -
+     1.96 * predicted.probit$se.fit)
> data$fitted.probit <- pnorm(predicted.probit$fit)
> data$CI.higher.probit <- pnorm(predicted.probit$fit +
+     1.96 * predicted.probit$se.fit)
> x <- c(data$Infection_Severity, rev(data$Infection_Severity))
> y <- c(data$CI.lower.probit, rev(data$CI.higher.probit))
> plot(data$Infection_Severity, unclass(data$Treatment_Outcome) -
+     1, type = "n", pch = 3, ylab = "Outcome", xlab = "Severity",
+     main = "Probitová regrese")
> polygon(x, y, col = "gray85", border = "gray85")
> points(data$Infection_Severity, unclass(data$Treatment_Outcome) -
+     1, pch = 3, ylab = "Outcome", xlab = "Severity",
+     col = "gray35")
> lines(data$Infection_Severity, data$fitted.probit, col = "darkgreen",
+     lwd = 2)
> points(data$Infection_Severity, data$fitted.probit,
+     col = "darkgreen")
```



Obrázek 4: Probitová regrese s intervaly spolehlivosti.

Nakonec uvažujme poslední možnost, a to komplementární log-log linkovací funkci. GLM model pro binární proměnnou budeme opět konstruovat pro jedinou kovariátu `Infection_Severity`.

```
> m1.cloglog <- glm(Treatment_Outcome ~ Infection_Severity,
+     family = binomial(cloglog), data = data)
> summary(m1.cloglog)
```

```

Call:
glm(formula = Treatment_Outcome ~ Infection_Severity, family = binomial(cloglog),
     data = data)

Deviance Residuals:
    Min      1Q   Median      3Q      Max
-1.7952 -0.6639 -0.3177  0.7782  1.8936

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept) -3.74248   1.00860 -3.711 0.000207 ***
Infection_Severity 0.04153   0.01159  3.582 0.000341 ***
---
Signif. codes:  0 ,***, 0.001 ,**, 0.01 ,*, 0.05 ,., 0.1 , , 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 67.745 on 48 degrees of freedom
Residual deviance: 45.964 on 47 degrees of freedom
AIC: 49.964

Number of Fisher Scoring iterations: 6

```

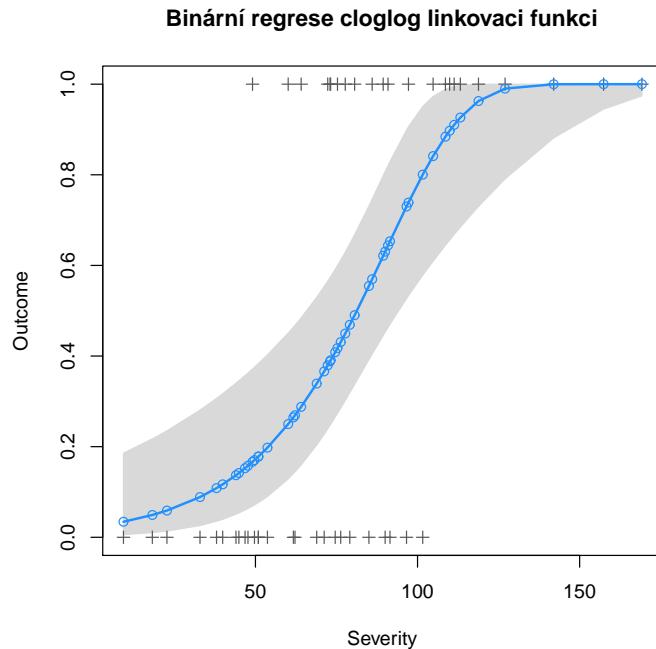
I v tomto modelu je kovariáta Infection\_Severity statisticky významná.

Stejně jako v předchozích případech vykreslíme výslednou křivku spolu s asymptotickými intervaly spolehlivosti:

```

> Icloglog <- function(x) return(1 - exp(-exp(x)))
> predicted.cloglog <- predict(m1.cloglog, type = "link",
+                                 newdata = data, se = T)
> data$CI.lower.cloglog <- Icloglog(predicted.cloglog$fit -
+                                         1.96 * predicted.cloglog$se.fit)
> data$fitted.cloglog <- Icloglog(predicted.cloglog$fit)
> data$CI.higher.cloglog <- Icloglog(predicted.cloglog$fit +
+                                         1.96 * predicted.cloglog$se.fit)
> x <- c(data$Infection_Severity, rev(data$Infection_Severity))
> y <- c(data$CI.lower.cloglog, rev(data$CI.higher.cloglog))
> plot(data$Infection_Severity, unclass(data$Treatment_Outcome) -
+       1, type = "n", pch = 3, ylab = "Outcome", xlab = "Severity",
+       main = "Binární regrese cloglog linkovaci funkci")
> polygon(x, y, col = "gray85", border = "gray85")
> points(data$Infection_Severity, unclass(data$Treatment_Outcome) -
+         1, pch = 3, ylab = "Outcome", xlab = "Severity",
+         col = "gray35")
> lines(data$Infection_Severity, data$fitted.cloglog,
+        col = "dodgerblue", lwd = 2)
> points(data$Infection_Severity, data$fitted.cloglog,
+         col = "dodgerblue")

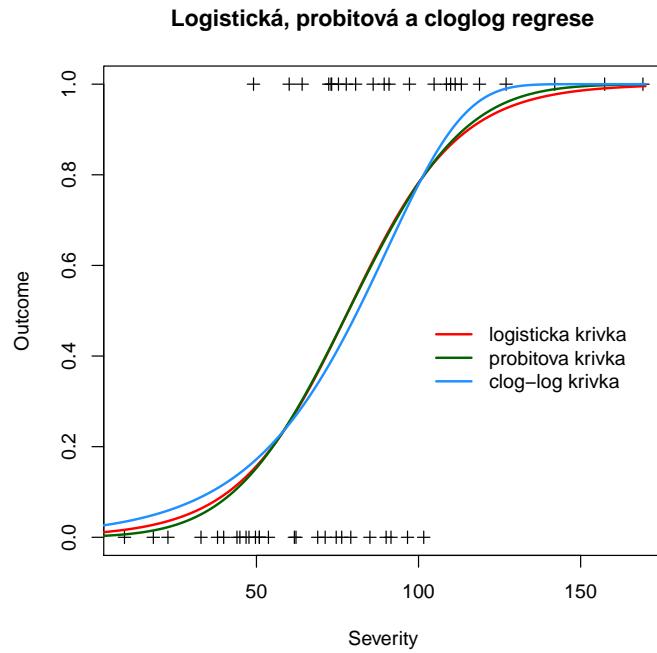
```



Obrázek 5: Binární regrese s komplementární log-log linkovací funkcí s intervaly spolehlivosti.

Nyní zakreslíme všechny křivky do jediného grafu a aby byl výsledný graf kvalitnější, nepoužijeme předchozí odhady s 49 body, ale síť pro x–ové hodnoty zjemníme.

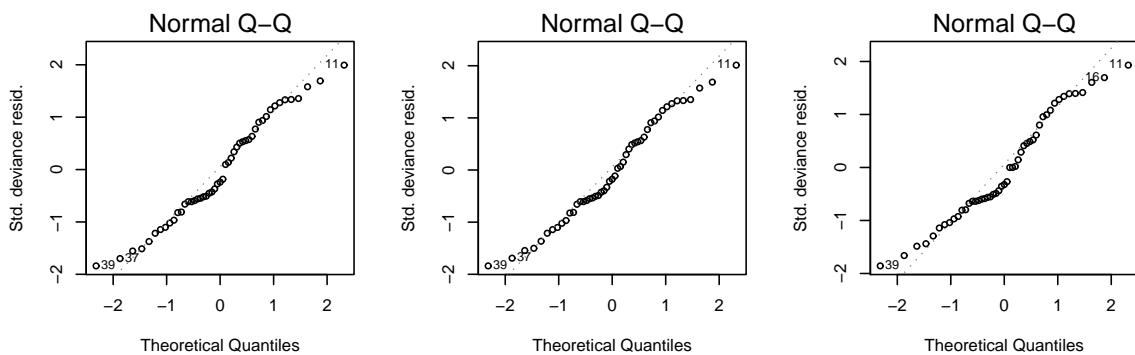
```
> xx <- seq(0, 170, length.out = 200)
> yy.logit <- predict(m1.logit, list(Inflection_Severity = xx),
+ type = "response")
> yy.probit <- predict(m1.probit, list(Inflection_Severity = xx),
+ type = "response")
> yy.cloglog <- predict(m1.cloglog, list(Inflection_Severity = xx),
+ type = "response")
> plot(data$Inflection_Severity, unclass(data$Treatment_Outcome) -
+ 1, pch = 3, ylab = "Outcome", xlab = "Severity",
+ main = "Logistická, probitová a cloglog regrese")
> lines(xx, yy.logit, col = "red", lwd = 2)
> lines(xx, yy.probit, col = "darkgreen", lwd = 2)
> lines(xx, yy.cloglog, col = "dodgerblue", lwd = 2)
> legend(100, 0.5, bty = "n", col = c("red", "darkgreen",
+ "dodgerblue"), lty = c(1, 1, 1), lwd = c(2, 2, 2),
+ legend = c("logisticka krivka", "probitova krivka",
+ "clog-log krivka"))
```



Obrázek 6: Porovnání všech binárních regresí.

Vhodný model se pokusíme vybrat na základě analýzy reziduů.

```
> par(mfrow = c(1, 3))
> plot(m1.logit, which = 2, cex = 0.75)
> plot(m1.probit, which = 2, cex = 0.75)
> plot(m1.cloglog, which = 2, cex = 0.75)
```



Obrázek 7: Srovnání logistické, probitové a cloglog regrese pomocí Q-Q grafů.

Na základě těchto grafů nejsme schopni rozhodnout, který model je nejvhodnější. Pro binární výstupy však máme k dispozici velmi účinný grafický nástroj, který se nazývá ROC křivky.

### POZNÁMKY K ROC ANALÝZE VZTAHUJÍCÍ SE K BINÁRNÍ REGRESI

Klasická ROC křivka je definována pro **binární klasifikační pravidla**, tj. pro pravidla jejichž výstupem jsou pouze **dvě kategorie (třídy, populace)**.

Zkratka ROC je odvozená od slov *Receiver Operating Characteristic*, nebot' se původně využívala jako operační charakteristika radiolokátoru.

**Binární klasifikační pravidlo** je **předpis** určující, zda jedinec či objekt popsaný pomocí jednorozměrného nebo i vícerozměrného statistického znaku patří do **jedné ze dvou** rozlišitelných **tříd** nebo **populací**. Výstupem klasifikačního pravidla je tedy označení jisté třídy, populace či kategorie, např.

- zdravý, nemocný;
- prospěl, neprospěl.

Jde o kvalitativní proměnnou, která se obyčejně kóduje čísly, např. 0 a 1.

V případě **binární regrese** máme k dispozici (pro  $i = 1, \dots, n$ ):

$$\begin{aligned} Y_i & \quad \text{binární proměnné nabývajících hodnot } \{0, 1\} \\ \mathbf{x}_i = (x_{i1}, \dots, x_{im})^T & \quad \text{nezávisle proměnné - jednorozměrný či vícerozměrný znak} \\ & \quad \text{charakterizující jedince} \end{aligned}$$

Pomocí GLM modelu s vhodnou linkovací funkcí  $g$  získáme odhadы

$$\hat{\pi}_i = \hat{\pi}(\mathbf{x}_i) = g^{-1}(\mathbf{x}_i^T \hat{\beta}_{\text{MLE}}) \quad \text{pro } i = 1, \dots, n,$$

které lze v prostředí R získat například příkazem `fitted(model)`.

Pak se jako **klasifikátor** používá následující klasifikační pravidlo:

$$\hat{Y}_i = \begin{cases} 1 & \text{aposteriorní pravděpodobnost } \hat{\pi}(\mathbf{x}_i) > c, \text{ obvykle se volí } c = 0.5, \\ 0 & \text{jinak.} \end{cases}$$

Bod  $c$  se nazývá **dělícím či kritickým bodem** (*decision limit, cutoff point, threshold*).

Při hodnocení **úspěšnosti** konkrétního binárního klasifikačního pravidla (které je spojeno s přesně daným dělícím bodem) se vychází z následující **kontingenční tabulky**, nazývané též *matice záměn* či *konfusní matice*.

		KONTINGENČNÍ TABULKA	
SKUTEČNÁ KATEGORIE	KLASIFIKOVANÁ KATEGORIE		
	0 (NEGATIVNÍ)	1 (POZITIVNÍ)	
0 (NEGATIVNÍ)	<i>správně negativní</i> <i>specifickita</i> $1 - \alpha$	<i>nesprávně pozitivní</i> <i>chyba 1. druhu</i> $\alpha$	
	<i>nesprávně negativní</i> <i>chyba 2. druhu</i> $\beta$	<i>správně pozitivní</i> <i>senzitivita</i> $1 - \beta$	

Podle toho, která chyba má závažnější důsledky, je pak možné změnit dělící bod a mít pod kontrolou velikost vybrané chyby.

**Binární klasifikační pravidlo** (také se mu v diagnostice říká **diagnostický test** či **testové kritérium**) je náhodnou veličinou, která v našem případě nabývá spojitých hodnot mezi nulou a jedničkou. Označme ji například symbolem  $T$ .

Dále označme symbolem  $T_0$  náhodnou veličinu  $T$  za podmínky, že jedinec ve skutečnosti patří do skupiny 0 (*undiseased population*), obdobně označme symbolem  $T_1$  náhodnou veličinu  $T$  za podmínky, že jedinec ve skutečnosti patří do skupiny 1 (*diseased population*). Příslušné hustoty a distribuční funkce označme symboly  $f_0, F_0$  a  $f_1, F_1$ .

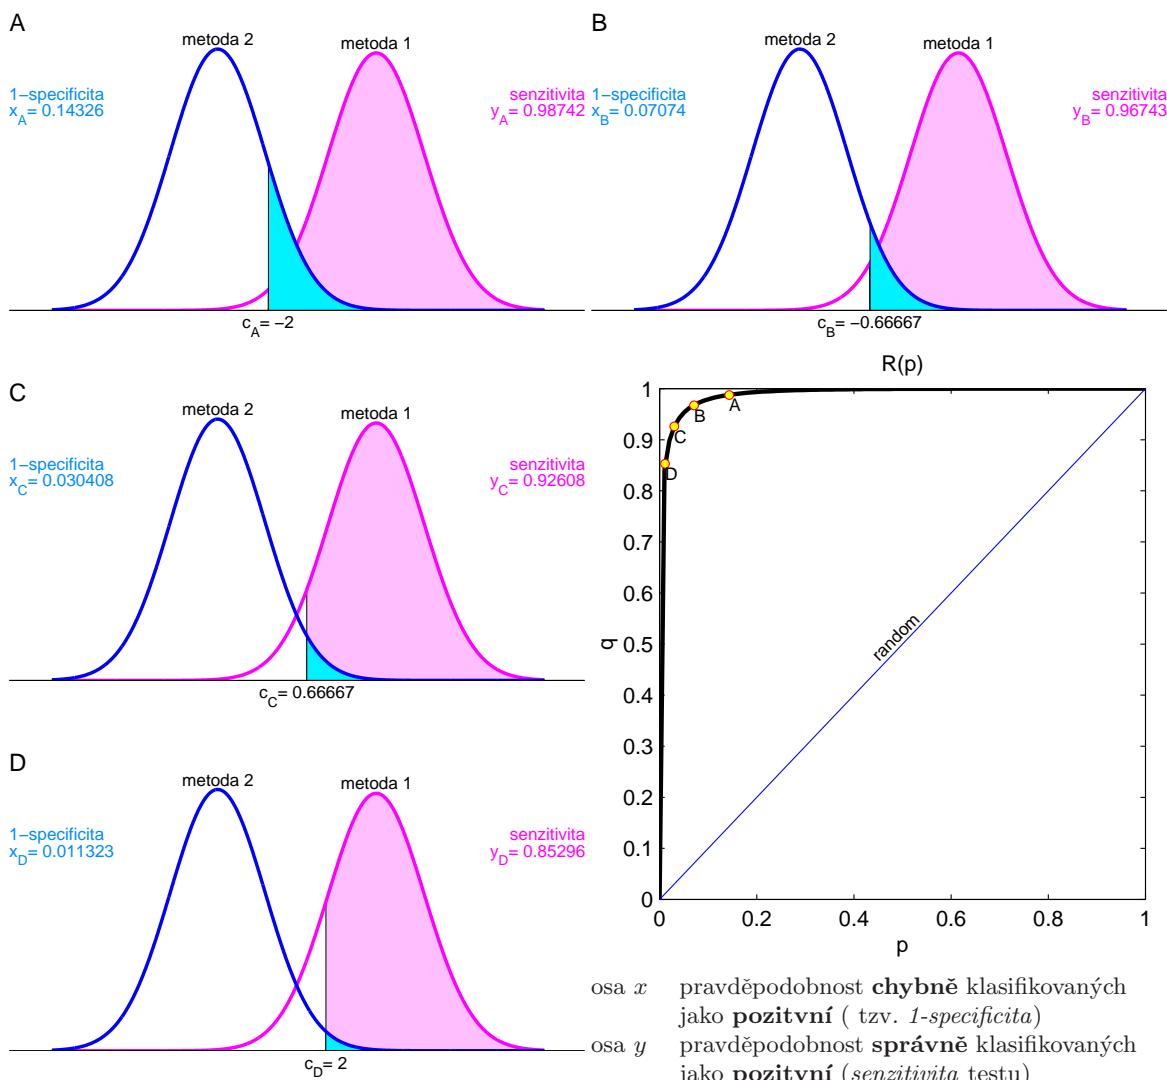
Dále budeme předpokládat, že vyšší hodnoty kritéria  $T$  vedou k vyšší pravděpodobnosti výskytu nějaké zkoumané nemoci (tj. k vyšší pravděpodobnosti, že jedinec patří do populace 1, tedy je pozitivní).

$$\text{Pak pro } \forall c \text{ platí} \quad FP(c) = P(T_0 > c) = 1 - F_0(c) \quad (\text{false positive}=1-\text{specificity}) \\ TP(c) = P(T_1 > c) = 1 - F_1(c) \quad (\text{true positive}=\text{sensitivity})$$

$$\text{a } ROC \text{ křivku tvoří dvojice bodů: } (FP(c), TP(c)) = (\underbrace{1 - F_0(c)}_x, \underbrace{1 - F_1(c)}_y)$$

$$\text{nebo-li} \quad ROC(p) = 1 - F_1(F_0^{-1}(1-p)) \quad 0 \leq p \leq 1.$$

Na následujících grafech vidíme názorně, jak se konstruuje  $ROC$  křivka pro měnící se dělící bod. V tomto případě metoda 2 představuje populaci s indexem 0.



Klasifikační pravidlo je o to přesnější, čím více se *ROC* křivka přimyká k levého hornímu bodu  $(0, 1)$ .

Velmi důležitou charakteristikou je také plocha pod *ROC* křivkou

$$AUC = \int_0^1 ROC(p) dp \quad (\text{Area Under the ROC Curve}).$$

Jestliže kovariáty charakterizované vektorem  $\mathbf{x}$  nemají vliv na klasifikaci do dvou tříd, pak hodnota AUC bude 0.5. Čím vhodnější kovariáty byly zvoleny, tím více se hodnota AUC blíží k jedné.

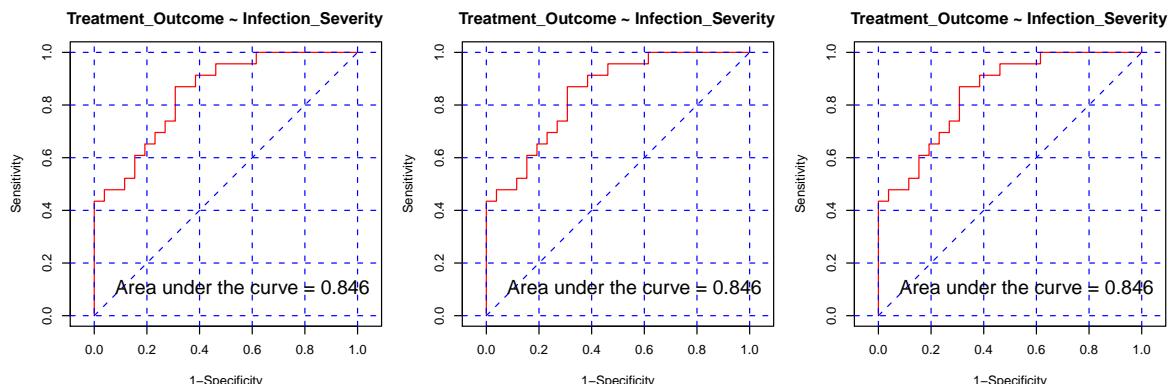
Protože skutečné rozdělení klasifikačního kritéria neznáme, musíme *ROC* křivku nějak odhadnout. Používá se celá řada přístupů:

- *parametrický* předpokládající například normalitu testového kritéria
- *neparametrický* neznámé podmíněné distribuční funkce se odhadují například pomocí jádrových odhadů.

Nejčastěji se však používá neparametrický přístup založený na **empických distribučních funkcích**. V tom případě má odhadnutá *ROC* křivka schodovitý tvar.

V prostředí R existuje celá řada balíků, které dokáží vykreslit *ROC* křivku a vypočítat AUC hodnotu. Nejprve si ukážeme grafy získané z knihovny **epicalc**.

```
> library(epicalc)
> par(mfrow = c(1, 3), mar = c(5, 5, 3, 0) + 0.1)
> graf1 <- lroc(m1.logit, title = TRUE, auc.coords = c(0.05,
  0.1), cex = 1.5, cex.main = 1.25)
> graf2 <- lroc(m1.probit, title = TRUE, auc.coords = c(0.05,
  0.1), cex = 1.5, cex.main = 1.25)
> graf3 <- lroc(m1.cloglog, title = TRUE, auc.coords = c(0.05,
  0.1), cex = 1.5, cex.main = 1.25)
```

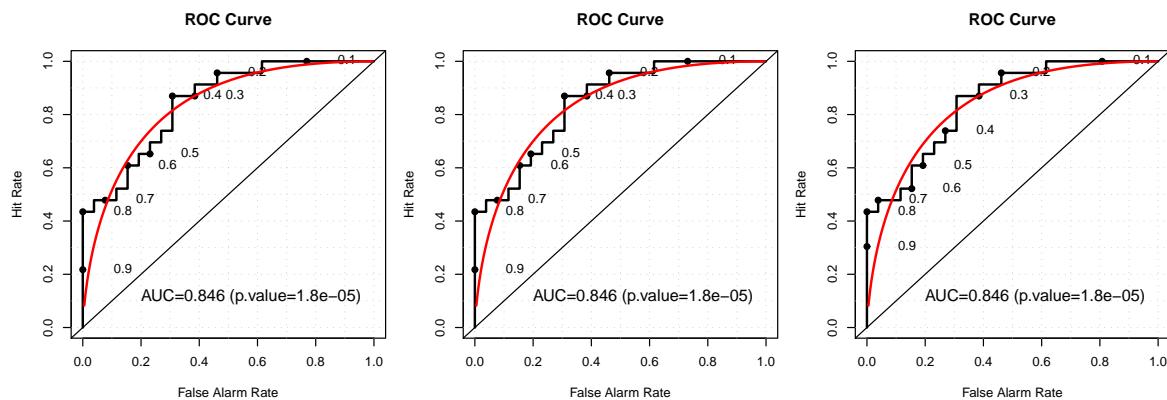


Obrázek 8: Porovnání *ROC* křivek a hodnot AUC pro logistickou, probitovou a cloglog binární regresi (pomocí příkazu `lroc` z knihovny **epicalc**).

Z výsledných grafů je patrné, že ani v *ROC* křivce, ani v AUC hodnotě se metody neliší.

Ještě si ukážeme, jaký typ grafu pro ROC křivku nabízí knihovna **verification**. V tomto případě vedle empirického odhadu lze získat také ROC křivku, která se z výchozích dat odhadne za předpokladu, že  $T_0$  i  $T_1$  mají normální rozdělení.

```
> library(verification)
> par(mfrow = c(1, 3), mar = c(5, 5, 3, 0) + 0.1)
> binvar <- unclass(data$Treatment_Outcome) - 1
> T <- fitted(m1.logit)
> AUC <- roc.area(binvar, T)
> auc.txt <- paste("AUC=", round(AUC$A, 3), " (p.value=", round(AUC$p.value,
+ 6), ") ", sep = "")
> roc.plot(binvar, T, binormal = T, plot = "both")
> text(0.2, 0.1, auc.txt, adj = c(0, 0), cex = 1.25)
> T <- fitted(m1.probit)
> AUC <- roc.area(binvar, T)
> auc.txt <- paste("AUC=", round(AUC$A, 3), " (p.value=", round(AUC$p.value,
+ 6), ") ", sep = "")
> roc.plot(binvar, T, binormal = T, plot = "both")
> text(0.2, 0.1, auc.txt, adj = c(0, 0), cex = 1.25)
> T <- fitted(m1.cloglog)
> AUC <- roc.area(binvar, T)
> auc.txt <- paste("AUC=", round(AUC$A, 3), " (p.value=", round(AUC$p.value,
+ 6), ") ", sep = "")
> roc.plot(binvar, T, binormal = T, plot = "both")
> text(0.2, 0.1, auc.txt, adj = c(0, 0), cex = 1.25)
```



Obrázek 9: Porovnání ROC křivek a hodnot AUC pro logistickou, probitovou a cloglog binární regresi (pomocí příkazů `roc.area` a `roc.plot` z knihovny `verification`).

P–hodnota v závorce u AUC hodnoty se vztahuje k testování hypotézy  $H_0 : AUC = 0.5$ . Vidíme, že tuto hypotézu zamítáme, což značí že proměnná `Infection_Severity` má významný vliv na přežití.

Podívejme se, jak dopadly konfusní matice pro jednotlivé binární modely

```
> fitY.logit <- factor(fitted(m1.logit) > 0.5, labels = c("pred.survived",
  "pred.died"))
> table(data$Treatment_Outcome, fitY.logit)

  fitY.logit
  pred.survived pred.died
survived        20       6
died           8      15

> fitY.probit <- factor(fitted(m1.probit) > 0.5, labels = c("pred.survived",
  "pred.died"))
> table(data$Treatment_Outcome, fitY.probit)

  fitY.probit
  pred.survived pred.died
survived        20       6
died           8      15

> fitY.cloglog <- factor(fitted(m1.cloglog) > 0.5, labels = c("pred.survived",
  "pred.died"))
> table(data$Treatment_Outcome, fitY.cloglog)

  fitY.cloglog
  pred.survived pred.died
survived        21       5
died           9      14
```

Vidíme, že konfusní matice jsou všechny stejné. Ukážeme si dále, jak lze místo absolutních četností získat relativní četnosti. Nejprve pro celou tabulku

```
> prop.table(table(data$Treatment_Outcome, fitY.logit))

  fitY.logit
  pred.survived pred.died
survived    0.4081633 0.1224490
died       0.1632653 0.3061224
```

Relativní četnosti podle řádků dostaneme příkazem

```
> prop.table(table(data$Treatment_Outcome, fitY.probit), 1)

  fitY.probit
  pred.survived pred.died
survived    0.7692308 0.2307692
died       0.3478261 0.6521739
```

A nakonec relativní četnosti podle sloupců dostaneme takto

```
> prop.table(table(data$Treatment_Outcome, fitY.cloglog), 2)
```

```
fitY.cloglog
pred.survived pred.died
survived      0.7000000 0.2631579
died         0.3000000 0.7368421
```

Mnohem více možností máme, pokud použijeme příkaz `CrossTable()` z knihovny `gmodels`.

```
> library(gmodels)
> CrossTable(table(data$Treatment_Outcome, fitY.cloglog), prop.r = T,
prop.c = T, prop.t = T, prop.chisq = F)
```

Cell Contents			
	N	N / Row Total	N / Col Total
	N / Table Total		
Total Observations in Table:	49		
		fitY.cloglog	
	pred.survived	pred.died	Row Total
survived	21	5	26
	0.808	0.192	0.531
	0.700	0.263	
	0.429	0.102	
died	9	14	23
	0.391	0.609	0.469
	0.300	0.737	
	0.184	0.286	
Column Total	30	19	49
	0.612	0.388	

Nyní se vrátíme k binární regresi a zjistíme, zda se model nezlepší, jestliže přidáme další vysvětlující proměnnou, a to proměnnou `Hospital`.

## MODEL 2 - binární regresní model s jedinou spojitou proměnnou Infection\_Severity a kategoriální proměnnou Hospital

Začneme s modelem, ve kterém budeme uvažovat i interakce mezi proměnnými Infection\_Severity a Hospital. Nejprve zvolíme kanonickou linkovací funkci.

```
> m2a.logit <- glm(Treatment_Outcome ~ Infection_Severity *
+                     Hospital, family = binomial(logit), data = data)
> summary(m2a.logit)

Call:
glm(formula = Treatment_Outcome ~ Infection_Severity * Hospital,
     family = binomial(logit), data = data)

Deviance Residuals:
    Min      1Q   Median      3Q      Max 
-2.2565 -0.4597 -0.1565  0.3539  2.0989 

Coefficients:
              Estimate Std. Error z value Pr(>|z|)    
(Intercept) -5.664355  2.803449 -2.020  0.0433 *  
Infection_Severity 0.055830  0.032493  1.718  0.0858 .  
HospitalB   -0.012466  3.989376 -0.003  0.9975    
HospitalC    2.817310  3.600700  0.782  0.4340    
Infection_Severity:HospitalB 0.012591  0.049197  0.256  0.7980  
Infection_Severity:HospitalC  0.006657  0.046875  0.142  0.8871  
---
Signif. codes:  0 ,***, 0.001 ,**, 0.01 ,*, 0.05 ,., 0.1 , , 1 

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 67.745  on 48  degrees of freedom
Residual deviance: 34.676  on 43  degrees of freedom
AIC: 46.676

Number of Fisher Scoring iterations: 6
```

Vidíme, že významnost jednotlivých proměnných se výrazně zhoršila, proto uvažujme jednodušší model bez interakcí

```
> m2b.logit <- glm(Treatment_Outcome ~ Infection_Severity +
+                     Hospital, family = binomial(logit), data = data)
> summary(m2b.logit)

Call:
glm(formula = Treatment_Outcome ~ Infection_Severity + Hospital,
     family = binomial(logit), data = data)

Deviance Residuals:
    Min      1Q   Median      3Q      Max 
-2.2528 -0.4932 -0.1835  0.3643  2.1508 

Coefficients:
```

```

              Estimate Std. Error z value Pr(>|z|)
(Intercept) -6.18858   1.81807 -3.404 0.000664 ***
Infection_Severity 0.06209   0.01985  3.128 0.001760 **
HospitalB    0.98306   1.01251  0.971 0.331595
HospitalC    3.36626   1.20231  2.800 0.005113 **
---
Signif. codes:  0 ,***, 0.001 ,**, 0.01 ,*, 0.05 ,., 0.1 , , 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 67.745 on 48 degrees of freedom
Residual deviance: 34.742 on 45 degrees of freedom
AIC: 42.742

Number of Fisher Scoring iterations: 6

```

Ještě zkонтrolujme, zda nedošlo k výraznému zhoršení tohoto modelu oproti předchozímu

```
> anova(m2a.logit, m2b.logit, test = "Chisq")
```

#### Analysis of Deviance Table

Model	Treatment_Outcome ~ Infection_Severity * Hospital	Treatment_Outcome ~ Infection_Severity + Hospital		
Resid. Df	Resid. Dev	Df	Deviance	P(> Chi )
1	43		34.676	
2	45	-2	34.742	0.966078

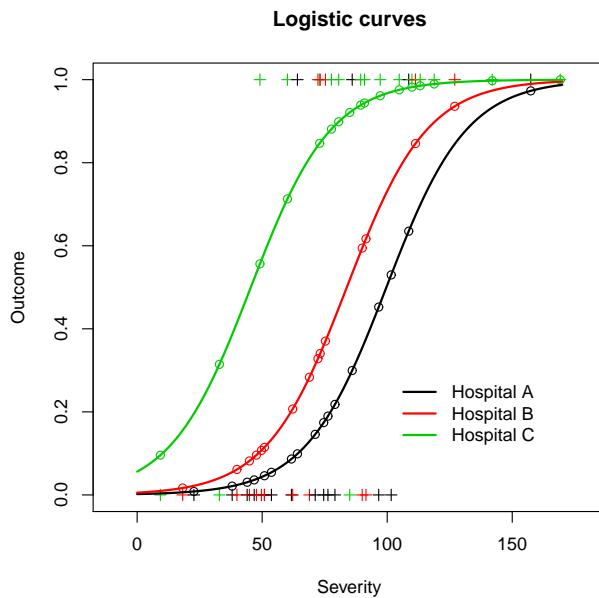
Protože P-hodnota není menší než 0.05, vypuštěním interakcí nedošlo k výraznému zhoršení modelu.

Provedeme vykreslení výsledných logistických křivek pro jednotlivé nemocnice.

```

> plot(data$Infection_Severity, unclass(data$Treatment_Outcome) -
  1, type = "p", pch = 3, xlim = c(-10, 180), col = unclass(data$Hospital),
  ylab = "Outcome", xlab = "Severity", main = "Logistic curves")
> points(data$Infection_Severity, fitted(m2b.logit), col = unclass(data$Hospital))
> xx <- seq(0, 170, length.out = 200)
> yA.logit <- predict(m2b.logit, list(Infection_Severity = xx,
  Hospital = factor(rep("A", 200))), type = "response")
> lines(xx, yA.logit, col = 1, lwd = 2)
> yB.logit <- predict(m2b.logit, list(Infection_Severity = xx,
  Hospital = factor(rep("B", 200))), type = "response")
> lines(xx, yB.logit, col = 2, lwd = 2)
> yC.logit <- predict(m2b.logit, list(Infection_Severity = xx,
  Hospital = factor(rep("C", 200))), type = "response")
> lines(xx, yC.logit, col = 3, lwd = 2)
> legend(100, 0.3, bty = "n", col = c(1, 2, 3), lty = c(1,
  1, 1), lwd = c(2, 2, 2), legend = c("Hospital A", "Hospital B",
  "Hospital C"))

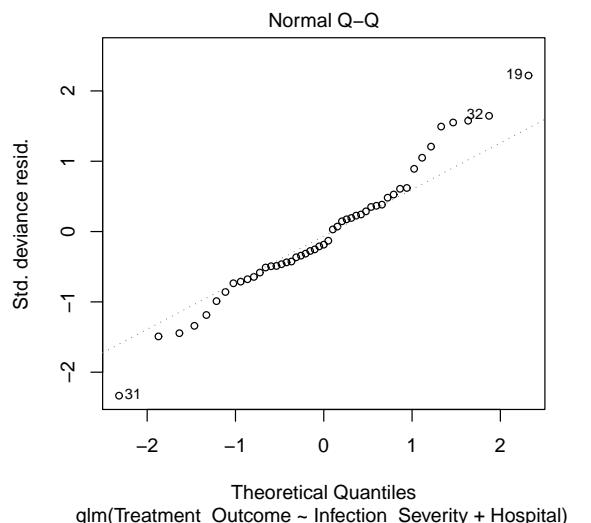
```



Obrázek 10: Logistické křivky pro jednotlivé nemocnice.

Pro tento model opět provedeme grafickou analýzu reziduí a vykreslíme ROC křivku.

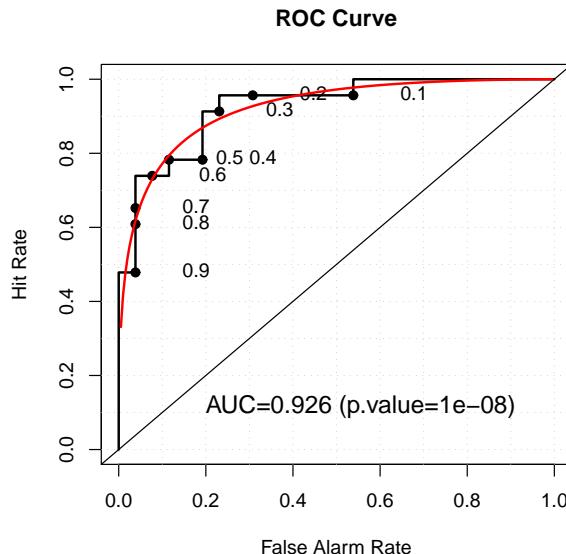
```
> plot(m2b.logit, which = 2, cex = 0.75)
```



Obrázek 11: Q-Q graf reziduí modelu 2b s logit linkovací funkcí.

```
> library(verification)
> par(mar = c(5, 5, 3, 0) + 0.1)
> binvar <- unclass(data$Treatment_Outcome) - 1
> T <- fitted(m2b.logit)
> AUC <- roc.area(binvar, T)
> auc.txt <- paste("AUC=", round(AUC$A, 3), " (p.value=", round(AUC$p.value,
8), ") ", sep = "")
```

```
> roc.plot(binvar, T, binormal = T, plot = "both")
> text(0.2, 0.1, auc.txt, adj = c(0, 0), cex = 1.25)
```



Obrázek 12: ROC křivka a hodnota AUC pro logistickou binární regresi – MODEL 2B ( pomocí příkazů `roc.area` a `roc.plot` z knihovny `verification`).

Vidíme, že přidáním další proměnné se hodnota AUC z 0.846 zvedla na 0.926. Nezapomeňme také na konfusní matici:

```
> library(gmodels)
> fitY.logit <- factor(fitted(m2b.logit) > 0.5, labels = c("pred.survived",
  "pred.died"))
> CrossTable(table(data$Treatment_Outcome, fitY.cloglog), prop.r = T,
  prop.c = T, prop.t = T, prop.chisq = F)
```

Cell Contents	
	N
N / Row Total	
N / Col Total	
N / Table Total	

Total Observations in Table: 49

	fitY.cloglog	pred.survived	pred.died	Row Total
survived		21	5	26
		0.808	0.192	0.531
		0.700	0.263	
		0.429	0.102	

died	9	14	23
	0.391	0.609	0.469
	0.300	0.737	
	0.184	0.286	
----- ----- ----- -----			
Column Total	30	19	49
	0.612	0.388	
----- ----- ----- -----			

Pro úplnost spočítejme Model 2b pro zbývající dvě linkovací funkce. Vypočteme model, do jednoho grafu zakreslíme výsledné křivky pro všechny nemocnice, provedeme grafickou analýzu reziduí, vytvoříme ROC křivku a nakonec vypočteme konfusní matici.

```
> m2b.probit <- glm(Treatment_Outcome ~ Infection_Severity +
  Hospital, family = binomial(probit), data = data)
> summary(m2b.probit)
```

Call:  
 glm(formula = Treatment\_Outcome ~ Infection\_Severity + Hospital,  
 family = binomial(probit), data = data)

Deviance Residuals:  
 Min 1Q Median 3Q Max  
 -2.2245 -0.4837 -0.1249 0.3579 2.1404

Coefficients:  

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-3.61785	0.95185	-3.801	0.000144 ***
Infection_Severity	0.03655	0.01058	3.454	0.000552 ***
HospitalB	0.53274	0.57472	0.927	0.353948
HospitalC	1.88787	0.64180	2.942	0.003266 **

 ---  
 Signif. codes: 0 ,\*\*\*, 0.001 ,\*\*, 0.01 ,\*, 0.05 ,., 0.1 , , 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 67.745 on 48 degrees of freedom  
 Residual deviance: 34.511 on 45 degrees of freedom  
 AIC: 42.511

Number of Fisher Scoring iterations: 7

```
> m2b.cloglog <- glm(Treatment_Outcome ~ Infection_Severity +
  Hospital, family = binomial(cloglog), data = data)
> summary(m2b.cloglog)
```

Call:  
 glm(formula = Treatment\_Outcome ~ Infection\_Severity + Hospital,  
 family = binomial(cloglog), data = data)

Deviance Residuals:  
 Min 1Q Median 3Q Max  
 -2.2131 -0.5651 -0.2920 0.3321 2.0368

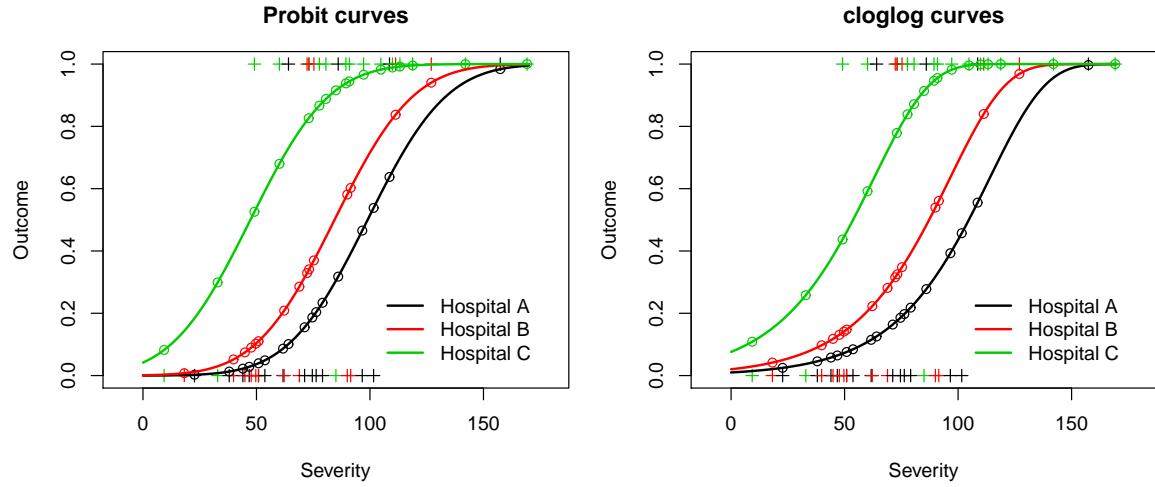
```
Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept) -4.59689   1.23198 -3.731 0.000191 ***
Infection_Severity 0.04039   0.01258  3.210 0.001329 **
HospitalB     0.70634   0.75040  0.941 0.346561
HospitalC      2.05929   0.73198  2.813 0.004903 **
---
Signif. codes:  0 ,***, 0.001 ,**, 0.01 ,*, 0.05 ,., 0.1 , , 1
```

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 67.745 on 48 degrees of freedom  
 Residual deviance: 35.482 on 45 degrees of freedom  
 AIC: 43.482

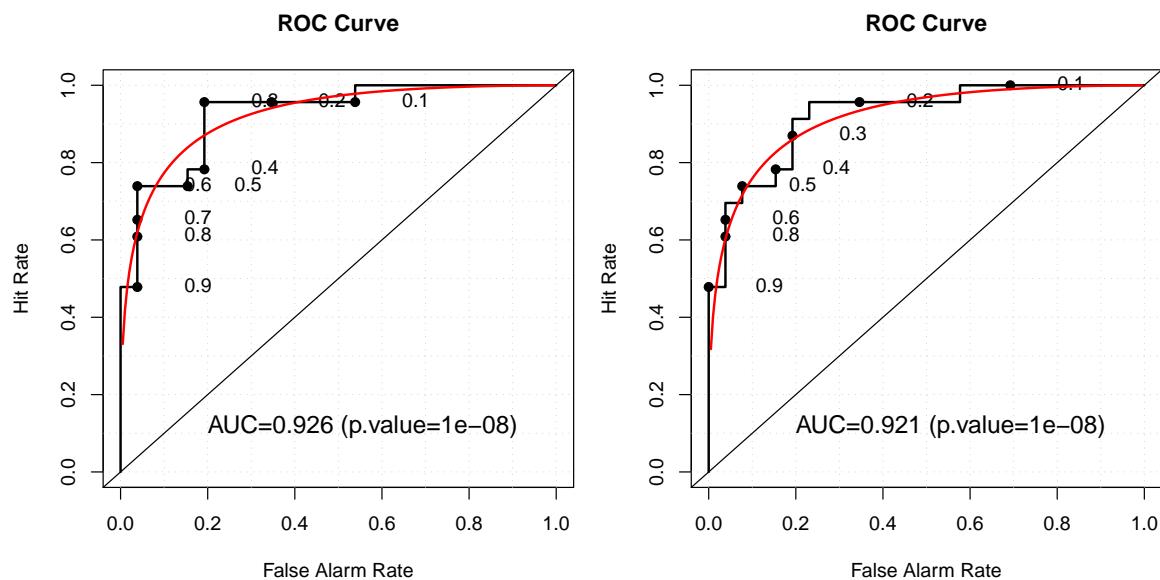
Number of Fisher Scoring iterations: 7

```
> par(mfrow = c(1, 2), mar = c(5, 5, 3, 0) + 0.1)
> xx <- seq(0, 170, length.out = 200)
> yA.probit <- predict(m2b.probit, list(Infection_Severity = xx,
  Hospital = factor(rep("A", 200))), type = "response")
> yB.probit <- predict(m2b.probit, list(Infection_Severity = xx,
  Hospital = factor(rep("B", 200))), type = "response")
> yC.probit <- predict(m2b.probit, list(Infection_Severity = xx,
  Hospital = factor(rep("C", 200))), type = "response")
> plot(data$Infection_Severity, unclass(data$Treatment_Outcome) -
  1, type = "p", pch = 3, xlim = c(-10, 180), col = unclass(data$Hospital),
  ylab = "Outcome", xlab = "Severity", main = "Probit curves")
> points(data$Infection_Severity, fitted(m2b.probit), col = unclass(data$Hospital))
> lines(xx, yA.probit, col = 1, lwd = 2)
> lines(xx, yB.probit, col = 2, lwd = 2)
> lines(xx, yC.probit, col = 3, lwd = 2)
> legend(100, 0.3, bty = "n", col = c(1, 2, 3), lty = c(1,
  1, 1), lwd = c(2, 2, 2), legend = c("Hospital A", "Hospital B",
  "Hospital C"))
> plot(data$Infection_Severity, unclass(data$Treatment_Outcome) -
  1, type = "p", pch = 3, xlim = c(-10, 180), col = unclass(data$Hospital),
  ylab = "Outcome", xlab = "Severity", main = "cloglog curves")
> points(data$Infection_Severity, fitted(m2b.cloglog), col = unclass(data$Hospital))
> yA.cloglog <- predict(m2b.cloglog, list(Infection_Severity = xx,
  Hospital = factor(rep("A", 200))), type = "response")
> yB.cloglog <- predict(m2b.cloglog, list(Infection_Severity = xx,
  Hospital = factor(rep("B", 200))), type = "response")
> yC.cloglog <- predict(m2b.cloglog, list(Infection_Severity = xx,
  Hospital = factor(rep("C", 200))), type = "response")
> lines(xx, yA.cloglog, col = 1, lwd = 2)
> lines(xx, yB.cloglog, col = 2, lwd = 2)
> lines(xx, yC.cloglog, col = 3, lwd = 2)
> legend(100, 0.3, bty = "n", col = c(1, 2, 3), lty = c(1,
  1, 1), lwd = c(2, 2, 2), legend = c("Hospital A", "Hospital B",
  "Hospital C"))
```



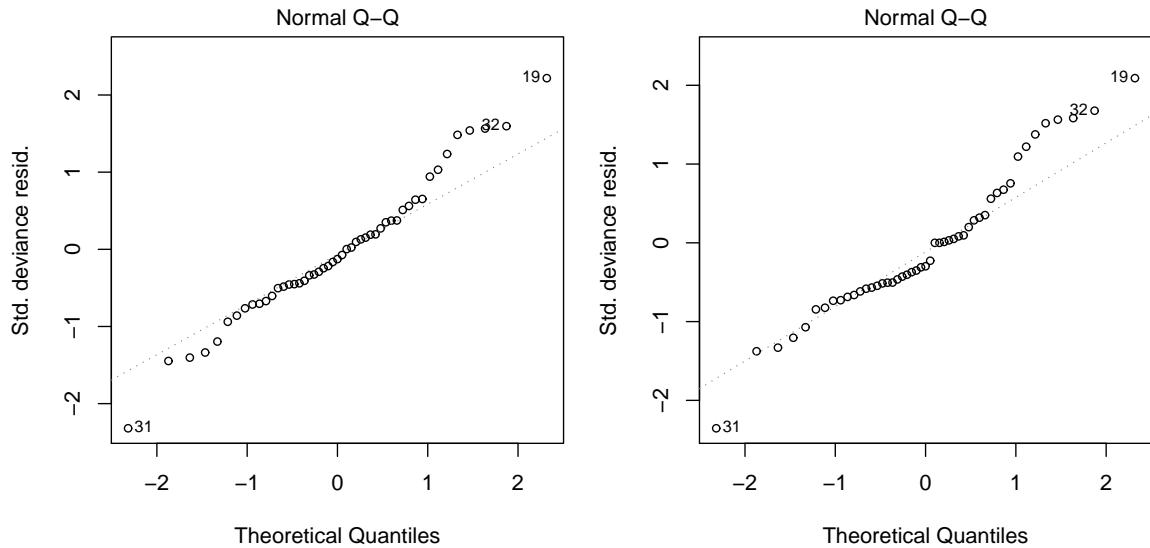
Obrázek 13: Výsledné křivky: probit a komplementární loglog

```
> par(mfrow = c(1, 2))
> binvar <- unclass(data$Treatment_Outcome) - 1
> T <- fitted(m2b.probit)
> AUC <- roc.area(binvar, T)
> auc.txt <- paste("AUC=", round(AUC$A, 3), " (p.value=", round(AUC$p.value,
8), ") ", sep = "")
> roc.plot(binvar, T, binormal = T, plot = "both")
> text(0.2, 0.1, auc.txt, adj = c(0, 0), cex = 1.25)
> T <- fitted(m2b.cloglog)
> AUC <- roc.area(binvar, T)
> auc.txt <- paste("AUC=", round(AUC$A, 3), " (p.value=", round(AUC$p.value,
8), ") ", sep = "")
> roc.plot(binvar, T, binormal = T, plot = "both")
> text(0.2, 0.1, auc.txt, adj = c(0, 0), cex = 1.25)
```



Obrázek 14: ROC křivky pro modely s probit a komplementární loglog linkovací funkcí

```
> par(mfrow = c(1, 2), mar = c(5, 5, 3, 0) + 0.1)
> plot(m2b.probit, which = 2, cex = 0.75)
> plot(m2b.cloglog, which = 2, cex = 0.75)
```



Obrázek 15: Q-Q grafy reziduí modelu 2b s linkovacími funkcemi probit a cloglog.

```
> library(gmodels)
> fitY.probit <- factor(fitted(m2b.probit) > 0.5, labels = c("pred.survived",
+ "pred.died"))
> CrossTable(table(data$Treatment_Outcome, fitY.cloglog), prop.r = T,
+ prop.c = T, prop.t = T, prop.chisq = F)
```

Cell Contents	
	N
	N / Row Total
	N / Col Total
	N / Table Total

Total Observations in Table: 49

	fitY.cloglog			
	pred.survived	pred.died		Row Total
survived	21	5		26
	0.808	0.192		0.531
	0.700	0.263		
	0.429	0.102		

died	9	14	23
	0.391	0.609	0.469
	0.300	0.737	
	0.184	0.286	
Column Total	30	19	49
	0.612	0.388	

```
> fitY.cloglog <- factor(fitted(m2b.cloglog) > 0.5, labels = c("pred.survived",
  "pred.died"))
> CrossTable(table(data$Treatment_Outcome, fitY.cloglog), prop.r = T,
  prop.c = T, prop.t = T, prop.chisq = F)
```

Cell Contents	
	N
	N / Row Total
	N / Col Total
	N / Table Total

Total Observations in Table: 49

	fitY.cloglog	pred.survived	pred.died	Row Total
survived		23	3	26
		0.885	0.115	0.531
		0.793	0.150	
		0.469	0.061	
died		6	17	23
		0.261	0.739	0.469
		0.207	0.850	
		0.122	0.347	
Column Total		29	20	49
		0.592	0.408	