

Pravidlá pre domáce úlohy

Počas semestra budú zadávané domáce úlohy, ktoré sa budú týkať riešenia optimalizačnej úlohy, opísanej v druhej časti tohto dokumentu, pomocou aktuálne preberaných metód.

Dokopy budú mať domáce úlohy hodnotu 40 bodov (40 % hodnotenia) a budete ich robiť v skupinách (1-4 študenti, rovnakí pre všetky úlohy).

Riešenie domácej úlohy bude pozostávať z na TEXovaného **pdf súboru** obsahujujúceho potrebné výstupy (číselné výstupy, obrázky, popisy, zhodnotenie, ...) a z **matlabovských súborov** s použitými kódmi.

Na domácej úlohe môžete pracovať aj na cvičení (po dokončení obsahu cvičenia) a konzultovať riešenie s cvičiacim.

Termín na odovzdanie domácej úlohy bude do nasledujúceho cvičenia.

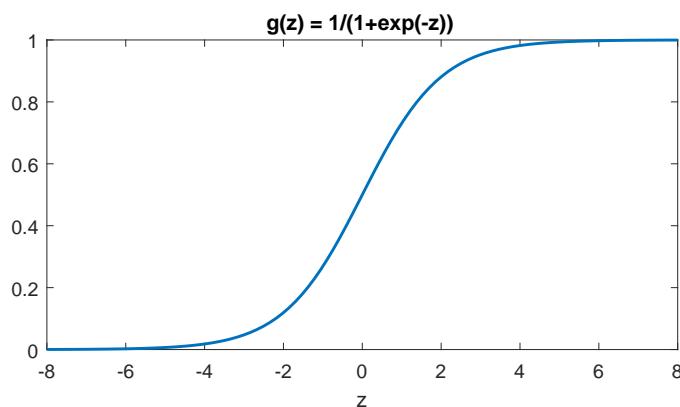
Logistická regresia

Na základe údajov o výške študenta (alebo študentky) chceme odhadnúť pravdepodobnosť toho, že je to muž. K dispozícii máme súbor *data.csv* s údajmi o $m = 241$ študentoch, pričom každý riadok zodpovedá jednému študentovi. Prvý stĺpec obsahuje binárnu premennú v určujúcu, či je to študent ($v = 1$) alebo študentka ($v = 0$). Druhý stĺpec obsahuje premennú u_1 , ktorá udáva výšku uvedenú v metrech.

Na modelovanie pravdepodobnosti použijeme logistickú regresiu. Logistická funkcia má tvar

$$g(z) = \frac{1}{1 + e^{-z}}$$

a vyzerá takto



Definujeme $u = (1, u_1)^T$ a logistickú funkciu budeme vyčísľovať v bodoch

$$x^T u = x_0 + x_1 u_1$$

pre nejaké parametre $x = (x_0, x_1)^T \in \mathbb{R}^2$. Hodnotu

$$g(x^T u) = g(x_0 + x_1 u_1) = \frac{1}{1 + e^{-x_0 - x_1 u_1}}$$

interpretujeme ako pravdepodobnosť toho, že študent s výškou u_1 je muž, teda $g(x^T u) = P(v = 1|u_1)$.

Vašou úlohou bude na základe údajov zo súboru *data.csv* odhadnúť parametre $x \in \mathbb{R}^2$ logistickej regresie. To vedie k optimalizačnej úlohe

$$\text{Min} \left\{ J(x) = - \sum_{i=1}^m v^i \ln \left(g \left(x^T u^i \right) \right) + (1 - v^i) \ln \left(1 - g \left(x^T u^i \right) \right) \mid x \in \mathbb{R}^2 \right\},$$

kde $u^i = (1, u_1^i)^T$. Tvar účelovej funkcie $J(x)$ je zvolený tak, aby bola penalizovaná nízka pravdepodobnosť $g(x^T u^i)$ toho, že študent je muž, ak je to naozaj muž ($v^i = 1$) a, naopak, vysoká pravdepodobnosť $g(x^T u^i)$ toho, že študent je muž, ak je to naozaj žena ($v^i = 0$).

Funkcia $J(x)$ sa dá po dosadení zjednodušiť a dostávame úlohu v tvare

$$\text{Min} \left\{ J(x) = \sum_{i=1}^m (1 - v^i) x^T u^i + \ln \left(1 + e^{-x^T u^i} \right) \mid x \in \mathbb{R}^2 \right\}.$$

Túto úlohu budete počas semestra riešiť rôznymi metódami, ktoré na nej porovnáte.