

Úlohy:

10.1. Vedenie podniku zamýšľa investovať do nákupu najmodernejších atrakcií s cieľom zvýšiť svoje zisky. K rozhodnutiu však pristúpi až po vypracovaní analýzy, ktorej cieľom je zistiť či zavedenie nových atrakcií priláka postačujúci počet návštevníkov. Z 12 ročnej histórie zábavného parku sú známe údaje o počte atrakcií (X) a zodpovedajúcom priemernom týždennom počte návštevníkov (Y) (v tisícoch). Výsledky sú v nasledujúcej tabuľke:

x_i	13	15	17	17	19	21	23	25	28	32	39	40
y_i	8	10	11	13	13	16	18	19	19	20	21	22

Predpokladajme, že veličiny X a Y spĺňajú predpoklady lineárneho regresného modelu. Riešte nasledujúce úlohy:

- Odhadnite závislosť priemerného týždenného počtu návštevníkov od počtu atrakcií regresnou parabolou $f(x) = a_0 + a_1x + a_2x^2$.
- Regresnú parabolu spolu s bodmi (x_i, y_i) znázornite.
- Určte SSE , $RMSE$ a výberové smerodajné odchýlky odhadnutých regresných koeficientov.
- Určte 95 %-né intervaly spoľahlivosti pre regresné koeficienty.
- Na hladine významnosti $\alpha = 0,05$ testujte významnosť regresných koeficientov.
- Určte bodový odhad funkčnej hodnoty $y(41)$ a 95 %-ný interval spoľahlivosti pre túto funkčnú hodnotu.
- Charakterizujte vhodnosť modelu pomocou výberového koeficienta determinácie.
- Na hladine významnosti $\alpha = 0,05$ testujte významnosť regresného modelu ako celku.
- Overte predpoklady uvedeného lineárneho regresného modelu. Postupujte ako v riešenom príklade 10.3. Najprv vykonajte grafickú analýzu.

Výsledok: a) $\hat{y} = \hat{a}_0 + \hat{a}_1x + \hat{a}_2x^2 = -10,9194 + 1,7603x - 0,0239x^2$;

c) $SSE = 6,9434$; $RMSE = 0,8783$; $s(\hat{a}_0) = 2,5798$; $s(\hat{a}_1) = 0,2098$; $s(\hat{a}_2) = 0,0039$;

d) $a_0 \in \langle -16,7552; -5,0836 \rangle$, $a_1 \in \langle 1,2857; 2,2349 \rangle$, $a_2 \in \langle -0,0326; -0,0151 \rangle$;

e) $regstats(y, x, 'quadratic')$

$t = [-4.2327; 8.3902; -6.1701]$, $pval = [0.0022; 1.5100e-05; 1.6467e-04]$, pretože p -hodnota je vo všetkých prípadoch menšia ako $\alpha = 0,05$, tak regresné koeficienty považujeme za štatisticky významné. Ten istý výsledok vyplýva aj z IS, keďže žiaden z nich neobsahuje 0.

f) $\hat{y}(41) = 21,0959$; $y(41) \in \langle 19,4629; 22,7289 \rangle$; g) $R^2 = 0,9713$; $R^{*2} = 0,9649$;

h) $fitlm(x, y, 'quadratic')$

F-statistic: 152, p-value = 1.16e-07; $p < 0,05$, prijímame hypotézu H_1 o štatistickej významnosti výberového koeficienta determinácie R^2 .

i) Klasické a štandardizované rezíduá:

$e = 0.0727 \quad -0.1101 \quad -1.1018 \quad 0.8982 \quad -0.9025 \quad 0.4880$

$1.0696 \quad 0.8424 \quad -0.6402 \quad -0.9481 \quad -0.3975 \quad 0.7294$

$eS = 0.1117 \quad -0.1438 \quad -1.3553 \quad 1.1047 \quad -1.0957 \quad 0.5989$

$1.3395 \quad 1.0758 \quad -0.8294 \quad -1.2169 \quad -0.5921 \quad 1.2080$

V grafe (\hat{y}_i, e_{si}) sú všetky rezíduá náhodne rozmiestnené okolo nuly v intervale $(-2, 2)$.

V grafe (i, e_i) spolu s 95 %-nými intervalmi spoľahlivosti pre náhodné chyby vidíme, že IS všetkých náhodných chýb obsahujú 0, čo svedčí v prospech hypotézy, že náhodné chyby sú normálne rozdelené s nulovou strednou hodnotou.

Aplikácia A-D testu na overenie normality náhodných chýb na hladine významnosti $\alpha = 0,05$: $p = 0,3305 > 0,05$, prijímame hypotézu H_0 o normálnom rozdelení náhodných chýb.

Test nulovej strednej hodnoty náhodných chýb pomocou t -testu na hladine významnosti $\alpha = 0,05$: $p = 1 > 0,05$, prijímame hypotézu H_0 o nulovej strednej hodnote náhodných chýb.

Test homoskedasticity na hladine významnosti $\alpha = 0,05$: $SSE_d = 0,5512$; $SSE_h = 2,708$;

$H_0: \sigma_d^2 = \sigma_h^2$, $H_1: \sigma_h^2 > \sigma_d^2$; $F = 2,708/0,5512 = 4,9129$; $F < F_{0,95; 4; 4} = 6,3882$; prijímame hypotézu o homoskedasticite náhodných chýb.

Test nekorelovanosti náhodných chýb pomocou DW štatistiky na hladine významnosti $\alpha = 0,05$: $dw = 2.0809$, $pval = 0.3985$; $p > \alpha$, prijímame hypotézu H_0 o nekorelovanosti náhodných chýb.

Test náhodnosti chýb na základe bodov zvratu na hladine významnosti $\alpha = 0,05$:

BodZ = -1.1018 0.8982 -0.9025 1.0696 -0.9481; Z = 5, q = 1.96, U = -1.2384, prijímame hypotézu H_0 o náhodnosti chýb.

Poznámka: Riešte všetky zadané úlohy aj pre prípad regresnej hyperboly $f(x) = a_0 + \frac{a_1}{x}$.

Niektoré výsledky:

General model: $f(x) = a_0 + a_1/x$

Coefficients (with 95% confidence bounds):

$a_0 = 28.98$ (27.14, 30.81)

$a_1 = -280.3$ (-317.4, -243.3)

Goodness of fit: SSE: 8.203, R-square: 0.9661, Adjusted R-square: 0.9627, RMSE: 0.9057

10.2. Tabuľka uvádza vek strojov (X) v rokoch a náklady na ich údržbu (Y) v eurách:

x_i	14	0,8	3	7,5	8,4	14,8	4,5	15,6	17,3	11,5	13,2	1,5
y_i	47,5	8	10	17	22	76,4	12,5	76	94,5	25	30,6	12

Riešte nasledujúce úlohy:

a) Odhadnite závislosť nákladov od veku stroja regresnou exponenciálnou funkciou

$$f(x) = a_0 \cdot a_1^x.$$

b) Regresnú exponenciálnu krivku spolu s bodmi (x_i, y_i) znázornite.

c) Vypočítajte výberový reziduálny rozptyl a výberovú reziduálnu smerodajnú odchýlku.

d) Posúďte súlad použitého modelu so skutočnosťou na základe indexu determinácie, resp. modifikovaného indexu determinácie.

Výsledok: Riešenie pomocou logaritmickej transformácie: a) $\hat{y} = \hat{a}_0 \cdot \hat{a}_1^x = 6,9473 \cdot 1,1511^x$; c)

$MSE = 116,609$; $RMSE = 10,7986$; d) $R^2 = 0,8843$; $R^{*2} = 0,8728$; modelom exponenciálnej regresie je vysvetlených približne 87 % variability znaku Y.