



VILNIAUS UNIVERSITETAS
MATEMATIKOS IR INFORMATIKOS FAKULTETAS
MATEMATINĖS STATISTIKOS KATEDRA

Olga Šklier

**PAGREITINTŲJŲ GEDIMŲ PARAMETRINIS
MODELIS IR JO TAIKYMAI**

Magistro darbas

Vadovas
prof. V. Bagdonavičius

VILNIUS, 2006

RÉSUMÉ

On s'intéresse à la durée de vie T des montages pour arthrodèse lombaire (on les appelle unités dans la suite) quand ceux-ci sont soumis à des charges cycliques déterminées par une valeur minimale et une valeur maximale de charge en Newton. La durée de vie est exprimée en nombre de cycles avant la rupture de l'unité. Trois types de charge sont disponibles: 28-280N, 30-300N et 35-350N. Ces types de charges seront appelés stress dans la suite. Étant entendu que la charge maximale est toujours dix fois plus grande que la charge minimale, nous convenons de noter x la valeur minimale du stress. On a accumulé les données de plusieurs expériences pour des unités de types différents (Diapason et Xia). Pendant une expérience, une unité d'un certain type fonctionne sous un stress choisi et on observe la durée de vie de celle-ci (ou le moment de censure si l'unité n'est pas rompue pendant un temps choisi pour la durée de l'expérience). Le but principal est d'estimer la valeur du stress x_{cr} , pour lequel on peut garantir avec une probabilité donnée γ le fonctionnement sans rupture des unités d'un certain type pendant cinq millions de cycles.

La résolution statistique de ce problème nécessite des modèles décrivant la probabilité de panne $P(T \leq t | x, \text{type de produit})$ d'unités d'un certain type sous le stress x dans n'importe quel intervalle $[0, t]$. La difficulté principale dans le choix d'un modèle approprié réside dans le fait que les données sont accumulées sous des stress accélérés qui donnent les durées de vie extrêmement plus courtes que la durée de vie sous la valeur (inconnue) x_{cr} . Cette difficulté, qui n'est pas insurmontable, est renforcée par le fait que les variances observées des durées de vie sont grandes. Aussi, le nombre d'essais pour des unités de tel ou tel type concret est relativement petit et enfin le nombre de valeurs des stress différents appliqués ne dépasse pas trois. Par exemple, la figure, qui est obtenue après estimation en unifiant les données de deux types d'unités, utilise trois valeurs des stress (28, 30 et 35) et les durées de vie moyennes sont approximativement 18000, 450000 et 80000 cycles, donc il semble évident que l'extrapolation à cinq millions cycles (i.e. 625 fois plus que 80000) peut donner une très grande variance dans l'estimation de x_{cr} même dans le cas où le modèle est idéalement choisi. Une petite déviation du modèle idéal (qui est inévitable) peut donner des erreurs de prédiction dont il faut tenir compte.

Les calculs préliminaires ont été faits sur les données présentées dans la table 3.1. On a choisi cette table car il n'y a pas au vu des données une différence statistiquement significative entre les durées de vie des deux types d'unités. Nous disposons alors de 37 unités et de trois niveaux de stress. En effet l'extrapolation actuelle est très sensible aux données disponibles. Si on change une ou deux valeurs extrêmes des durées de vie sous le stress 28, nous nous rendons compte que la position de courbes est stable pour les valeurs de stress proches des stress étudiés mais il devient instable pour des valeurs de stress proche de x_{cr} . On ne peut donc pas espérer que l'estimateur de x_{cr} qui est donné par (3.7) soit très fiable si on utilise les données disponibles.

Finalement, on a obtenu que l'estimation du stress x_{cr} qui garantir avec la probabilité $\gamma = 0.95$ le fonctionnement sans pannes pendant cinq millions de cycles est 14,2 (soit approximativement une charge 14-140N). Mais comme il a déjà été souligné, nous manquons d'expériences sous les stress inférieurs à 28 pour extrapoler correctement.

TURINYS

RÉSUMÉ.....	2
TURINYS.....	3
1 ĮVADAS	5
2 TEORINĖ DALIS	7
2.1 PG modelio parametrizacija.....	7
2.1.1 Tolydžiosios kovariantės	7
2.1.2 Atskiros ir nominaliosios kovariantės	10
2.2 Regresijos koeficientų interpretacija	10
2.2.1 Modeliai be sąveikų.....	11
2.2.2 Modeliai su sąveikomis	11
2.2.3 Nuo laiko priklausantys regresijos koeficientai	12
2.3 GL duomenų analizė: pasiskirstymų šeimos, apibrėžiamos mastelio formos parametrais	13
2.3.1 Modelis ir duomenys	13
2.3.2 Regresijos parametrų maksimalaus tikėtimumo įvertis.....	14
2.3.3 Pagrindinių patikimumo charakteristikų įverčiai	15
2.3.4 Asimptotinis regresijos parametrų įverčių pasiskirstymas	17
2.3.5 Aproximatyvūs patikimumo intervalai išgyvenamumo funkcijoms.	18
2.4 Eksperimentų planai pagreitinto gyvenimo bandymuose (PGB)	19
2.4.1 Pirmasis eksperimentų planas.....	20
2.5 Parametrinis vertinimas PGB pagal PG modelį.....	20
2.5.1 Pagrindinių patikimumo charakteristikų su normaliaja apkrova įverčiai	21
3 TIRIAMOJI DALIS	23
3.1 Duomenys.....	23
3.2 Teorijos taikymas	24
3.2.1 Naudotas statistinis modelis. Tikėtimumo funkcija.....	24
3.2.2 Kritinės apkrovos reikšmės įvertis.....	25
3.3 Praktiniai skaičiavimai	26
3.3.1 Užduoties apibendrinimas.....	26
3.3.2 Programinė realizacija	26

3.3.3 Rezultatai	29
IŠVADOS.....	30
LITERATŪROS SAŖAŠAS.....	31
PRIEDAI	32
1 Priedas. SAS programos išdava	32
2 Priedas. Patikimumo funkcijos $G_x(t)$ grafikai	33

1 ĮVADAS

Šis darbas yra skirtas išnagrinėti Pagreitintųjų Gedimų (PG) parametrinį modelį ir jo taikymus. Gedimo Laiko Regresijos (GTR) duomenys gaunami stebint gedimų momentus junginių, funkcionuojančių esant kovariančių, tokių kaip temperatūra, įtampa, krūvis, spaudimas, drėgnumas, konstrukcija, gamyba ir t.t. įvairioms reikšmėms. GTR duomenų analizės tikslas yra įvertinti šių kintamųjų patikimumą, veikiant apibrėžtoms, mus dominančių kintamųjų, reikšmėms. Atskiru atveju, pagreitintojo gyvenimo tyrimų (PGT) duomenys renkami iš eksperimentų, atliktų didesnės nei įprasta apkrovos sąlygomis, ir vertinant patikimumą įprastos apkrovos sąlygomis.

Duomenys, naudojami skaičiavimams atlikti, yra prancūzų kompanijos „Stryker Spine“ eksperimentinių bandymų rezultatai. Ši kompanija dirbti tarptautiniu mastu pradėjo vėlyvais 1980, kaip Dimso korporacija Prancūzijoje, Bordo mieste. Nuo 1996 metų, po to kai ji buvo pristatyta JAV rinkoje, įmonė greitai tapo pagrindine stuburo implantų rinkos dalyve. Šiuo metu kompanija nori pradėti masinę gamybą implantų, naudojamų juosmens ankilozei. Dirbtinė ankilozė (arthrodesis) yra dirbtinis sąnario tarp dviejų kaulų sukaulinimas operacijos būdu. Pastaroji atliekama įvedant į sąnarį implantą, užpildytą aktyviu kaulu. Tai daroma tam, kad sumažinti sunkiai numalšinamą skausmą sąnaryje, kuris negali būti pasiektas vaistais nuo skausmo, įtvarais ir kitomis įprastai siūlomomis procedūromis. Dažniausiai ši operacija atliekama stuburo, rankos, kelio ir kulkšnio sąnariams.

Dirbtinė ankilozė gali būti atlikta dviem būdais:

- Kaulų tiltas gali būti sukurtas tarp dviejų kaulų, naudojant kaulą iš bet kurios žmogaus kūno vietos arba iš kaulų banko, kad paskatinti kaulo augimą.
- Metaliniai implantai gali būti prijungti prie dviejų kaulų, kad laikyti juos kartu pozicijoje, kuri yra palanki kaulo augimui.

Operacijos ir gydymo pabaigoje, kurie trunka nuo kelių mėnesių iki metų, du artimiausi kaulai yra sujungiami ir tarp jų nebūna jokio judėjimo. Tai gali paveikti faktiškai tvirtinant kaulus, kaip pirminis sprando sujungimas. Eksperimentiniai tyrimai rodo stuburo slankstelių stabilumo padidėjimą, atlikus dirbtinę ankilozę.

Mus domina implantų, naudojamų juosmens ankilozės metu darbo laikas T , kuomet juos cikliška veikia apkrovos, apibrėžtos minimalia ir maksimalia reikšme, išreikšta Niutonais. Gyvenimo trukmė yra išreikšta ciklų skaičiumi iki implanto gedimo. Galimi trys apkrovos tipai: 28-280N, 30-300N, 35-350N. Žinoma, kad maksimali apkrova yra visada dešimt kart didesnė nei minimali. Susitarkime žymėti mažiausią apkrovos reikšmę x . Buvo surinkti daugelio eksperimentų su įvairiais implantų tipais (Diapason ir Xia) duomenys. Eksperimento metu konkretaus tipo implantas dirba, veikiamas pasirinkta apkrova, ir stebima jo gyvenimo trukmė (arba cenzūravimo momentas, jei implantas nesugedo eksperimento metu). Pagrindinis tikslas yra įvertinti apkrovos x_{cr} reikšmę, kuriai su duota tikimybe γ galima garantuoti darbą be tam tikro tipo implantų gedimų 5 milijonus ciklų.

Šios problemos statistinis sprendimas reikalauja modelių, aprašančių gedimo tikimybę $P(T \leq t \mid x, \text{gaminio tipas})$ konkretaus tipo implantų, veikiamų x apkrova, nesvarbu kokiam intervale $[0, t]$. Pagrindinis sunkumas, renkantis tinkamą modelį, yra tas, kad turimi duomenys tikrai prie padidintų apkrovų, kurios duoda funkcionavimo trukmę trumpesnę nei prie nežinomos apkrovos x_{cr} . Taip pat kiekvieno konkretaus tipo implantų skaičius yra santykinai mažas ir galiausiai skirtingų pritaikytų apkrovų reikšmių skaičius neviršija trijų. Pavyzdžiui, diagramoje, gautoje po vertinimo, apjungus dviejų implantų tipų duomenis, naudojant tris apkrovos reikšmes (28, 30 ir 35) ir, kuomet vidutinės gyvenimo trukmės yra apytiksliai 18000, 45000 ir 80000 ciklų, taigi rodos akivaizdu, kad ekstrapoliacija iki 5000000 ciklų (625 kartų daugiau nei 80000) gali duoti labai didelę x_{cr} įverčio dispersiją, netgi tuo atveju, kai modelis yra idealiai parinktas. Vienas mažas

nukrypimas nuo idealaus modelio (kuris yra neįmanomas) gali sąlygoti prognozavimo klaidas, į kurias reikia atsižvelgti.

Pirminiai paskaičiavimai buvo atlikti, remiantis duomenimis, pateiktais 3.1 lentelėje. Pasirinkome šią lentelę, nes tarp dviejų implantų tipų gyvenimo trukmių nebuvo pastebėta statistiškai reikšmingo skirtumo. Tokiu atveju mes disponuojame 37 implantais ir trimis apkrovos lygiais. Duomenų dispersijos yra akivaizdžiai didelės. Kad teisingai ekstrapoliuoti, reikės būtinai gauti duomenis apie bandymus su mažesnėmis apkrovomis (pavyzdžiui su 26 ir 24). Išties, tikroji ekstrapoliacija yra labai jautri disponuojamiems duomenims. Jeigu pakeisti vieną ar dvi ekstremalias gyvenimo trukmių, su apkrova 28, reikšmes, gauname, kad kreivių padėtis yra stabili apkrovos reikšmėms, kurios yra artimos nagrinėtoms. Tačiau stebime kreivės nestabilumą, kuomet apkrovos reikšmės yra artimos x_{cr} . Taigi negalima tikėtis, kad gautas x_{cr} įvertis, bus labai patikimas, jei naudosime tik tai turimus duomenis.

Pavyzdžiui gavome, kad apkrovos x_{cr} įvertis, kuris su tikimybe $\gamma = 0,95$ garantuoja funkcionavimą be gedimų penkių milijonų ciklų metu, yra lygus 14,2 (bus apytiksliai 14.2-142N apkrova). Kaip jau buvo pabrėžta, tam, kad tinkamai ekstrapoliuoti, mums trūksta bandymų su žemiausia apkrova 28.

2 TEORINĖ DALIS

PAGREITINTŲJŲ GEDIMŲ PARAMETRINIAI MODELIAI

2.1 PG modelio parametrizacija

Tegul

$$x(\cdot) = (x_0(\cdot), \dots, x_m(\cdot))^T,$$

bus kintanti laike ir daugiamatė kovariantė; čia $x_0(t) \equiv 1$ ir $x_1(\cdot), \dots, x_m(\cdot)$ yra vienmatės kovariantės.

Pagal PG modelį išgyvenamumo funkcija pagal $x(\cdot)$ yra tokio pavidalo

$$S_{x(\cdot)}(t) = S_0 \left(\int_0^t r(\tau) d\tau \right). \quad (2.1)$$

Jeigu kovariantės yra pastovios laike, tuomet modelis (2.1) yra užrašomas kaip

$$S_{x(\cdot)}(t) = S_0(r(x)t). \quad (2.2)$$

Funkcija r yra parametrizuojama sekančiu būdu:

$$r(x) = e^{-\beta^T z}, \quad (2.3)$$

čia $\beta = (\beta_0, \dots, \beta_m)^T$ yra nežinomų parametrų vektorius ir

$$z = (z_0, \dots, z_m)^T = (\varphi_0(x), \dots, \varphi_m(x))^T$$

yra nurodytų funkcijų φ_i vektorius, su $\varphi_0(t) \equiv 1$.

Pagal parametrizuotą PG modelį išgyvenamumo funkcija pagal $x(\cdot)$ yra tokio pavidalo

$$S_{x(\cdot)}(t) = S_0 \left(\int_0^t e^{-\beta^T x(\tau)} d\tau \right), \quad (2.4)$$

ir $x_j(\cdot)$ ($j = 1, \dots, m$) yra nebūtinai stebimos kovariantės. Tai gali būti kai kurios nurodytos funkcijos $\varphi_j(x)$. Nepaisant to, mes naudojame toki patį x_j žymėjimą $\varphi_j(x)$.

Jeigu kovariantės yra pastovios laike, tuomet modelis (2.4) yra užrašomas šitaip

$$S_x(t) = S_0(e^{-\beta^T x t}), \quad (2.5)$$

ir gedimo laiko T_x logaritmas pagal x gali būti užrašytas, kaip

$$\ln\{T_x\} = \beta^T x + \varepsilon,$$

kur atsitiktinio kintamojo ε išgyvenamumo funkcija nepriklauso nuo x ir yra $S(t) = S_0(\ln t)$. Pastebėkime, kad *lognormalaus gedimo-laiko atveju ε dispersija yra normali ir mes turime standartinį dauginį tiesinės regresijos modelį.*

Laike besikeičiančioms kovariantėms atsitiktinio dydžio

$$R = \int_0^{T(x)} e^{-\beta^T x(\tau)} d\tau$$

skirstinys nepriklauso nuo nežinomų parametrų ir turi išgyvenamumo funkciją $S_0(t)$. Aptarkime funkcijos φ_i pasirinkimą.

2.1.1 Tolydžiosios kovariantės

Pirma, tarkime, kad kovariantės yra tolydžios (krūvis, temperatūra, slėgis, įtampa, spaudimas).

Jeigu modelis (2.2) laikosi E_0 , tuomet visiems $x_1, x_2 \in E_0$

$$S_{x_2}(t) = S_{x_1}(\rho(x_1, x_2)t), \quad (2.6)$$

kur funkcija $\rho(x_1, x_2) = r(x_2)/r(x_1)$ rodo mastelio svyravimo laipsnį. Akivaizdu, kad $\rho(x, x) = 1$.

Iš pradžių, tarkime, kad x yra vienmatis. Mastelio svyravimų norma yra nustatoma *be galo maža charakteristika* (žr. Viertl (1988)):

$$\delta(x) = \lim_{\Delta x \rightarrow 0} \frac{\rho(x, x + \Delta x) - \rho(x, x)}{\Delta x} = [\log r(x)]'. \quad (2.7)$$

Taigi visiems $x \in E_0$ funkcija $r(x)$ yra tokia:

$$r(x) = r(x_0) \exp \left\{ \int_{x_0}^x \delta(v) dv \right\}, \quad (2.8)$$

kur $x_0 \in E_0$ yra fiksuota kovariantė.

Tarkime, kad $\delta(x)$ yra proporcingas apibrėžtai funkcijai $u(x)$:

$$\delta(x) = \alpha u(x).$$

Šiuo atveju,

$$r(x) = e^{-\beta_0 - \beta_1 \varphi_1(x)}, \quad (2.9)$$

kur $\varphi_1(x)$ yra pirminis $u(x)$, o β_0, β_1 yra nežinomi parametrai.

2.1 PAVYZDYS

$\delta(x) = \alpha$, $\varphi_1(x) = x$, pavyzdžiui mastelio svyravimų laipsnis yra pastovus, tuomet

$$r(x) = e^{-\beta_0 - \beta_1 x}. \quad (2.10)$$

Tai yra *log-tiesinis modelis*.

2.2 PAVYZDYS

$\delta(x) = \alpha/x$, $\varphi_1(x) = \ln x$. Tuomet

$$r(x) = e^{-\beta_0 - \beta_1 \log x} = \alpha_1 x^{\beta_1}. \quad (2.11)$$

Tai yra *laipsninio dėsnio modelis*.

2.3 PAVYZDYS

$\delta(x) = \alpha/x^2$, $\varphi_1(x) = -1/x$. Tuomet

$$r(x) = e^{-\beta_0 - \beta_1/x} = \alpha_1 e^{-\beta_1/x}. \quad (2.12)$$

Tai yra *Arrhenius modelis*.

2.4 PAVYZDYS

$\delta(x) = \alpha/x(1-x)$, $\varphi_1(x) = \ln \frac{x}{1-x}$. Tuomet

$$r(x) = e^{-\beta_0 - \beta_1 \ln \frac{x}{1-x}} = \alpha_1 \left(\frac{x}{1-x} \right)^{-\beta_1}, 0 < x < 1. \quad (2.13)$$

Tai yra *Meeker-Luvalle modelis* (1995).

Arrhenius modelis naudojamas tam, kad modeliuoti gaminio išgyvenamumo laiką, kai kovariantė yra temperatūra, laipsninio dėsnio modeliui – kuomet kovariantė yra įtampa, mechaninis apkrovimas. Log-tiesinis modelis taikomas patvarumo ir nuovargio duomenų analizei, bandant

įvairias elektronines komponentes (žr. Nelson (1990)). Meeker-Luvalle modelis naudojamas, kai x yra drėgnumo santykis.

Jeigu nelabai aišku, kurį iš pirmųjų trijų modelių pasirinkti, tuomet galima paimti didesnę modelių klasę. Pavyzdžiui, visi šie modeliai yra atskiri atvejai modelių klasės, apibrėžtų $\delta(x) = \alpha x^\gamma$ su nežinomu γ ar funkcijos $r(x)$ sąlygomis, tokiu būdu

$$r(x) = \begin{cases} e^{-\beta_0 - \beta_1(x^\varepsilon - 1)/\varepsilon}, & \text{jei } \varepsilon \neq 0 \\ e^{-\beta_0 - \beta_1 \log x}, & \text{jei } \varepsilon = 0 \end{cases} \quad (2.14)$$

Šiuo atveju turi būti įvertintas parametras ε .

Modelis (2.6) gali būti apibendrintas. Galima tarti, kad $\delta(x)$ yra kelių kovariantės apibrėžtų funkcijų tiesinė kombinacija:

$$\delta(x) = \sum_{i=1}^k \alpha_i u_i(x).$$

Tokiu atveju,

$$r(x) = \exp\left\{-\beta_0 - \sum_{i=1}^k \beta_i z_i(x)\right\}, \quad (2.15)$$

kur $z_i(x)$ yra duotos kovariantės funkcijos, β_0, \dots, β_k yra nežinomi (galbūt ne visi iš jų) parametrai.

2.5 PAVYZDYS

$\delta(x) = 1/x + \alpha/x^2$. Tuomet

$$r(x) = e^{-\beta_0 - \beta_1 \log x - \beta_2/x} = \alpha_1 x e^{-\beta_2/x}, \quad (2.16)$$

Kur $\beta_1 = -1$. Tai *Eyring modelis*, taikomas kuomet kovariantė x yra temperatūra.

2.6 PAVYZDYS

$\delta(x) = \sum_{i=1}^k \alpha_i / x^i$. Tuomet

$$r(x) = \exp\left\{-\beta_0 - \beta_1 \log x - \sum_{i=1}^{k-1} \beta_i / x^i\right\}. \quad (2.17)$$

Tai *apibendrintas Eyring modelis*.

Dabar tarkime, kad kovariantė $x = (x_1, \dots, x_m)$ yra daugiamatė. Jeigu nėra jokių sąveikų tarp (x_1, \dots, x_m) tuomet gali būti panaudotas modelis

$$r(x) = \exp\left\{-\beta_0 - \sum_{i=1}^m \sum_{j=1}^{k_i} \beta_{ij} z_{ij}(x_i)\right\}, \quad (2.18)$$

čia $z_{ij}(x_i)$ yra apibrėžtos funkcijos, β_{ij} – nežinomi parametrai.

2.7 PAVYZDYS

Jeigu pirmosios kovariantės įtaka yra apibrėžta laipsninio dėsnio modeliu, o antroji – Arrhenius modeliu, tuomet turime tokį modelį

$$r(x_1, x_2) = \exp\{-\beta_0 - \beta_1 \log x_1 - \beta_2 / x_2\}. \quad (2.19)$$

Taigi čia $k_1 = k_2 = 1$.

Jeigu tarp kovariančių yra sąveika, tuomet turi būti įtrauktos papildomos sąlygos.

2.8 PAVYZDYS

Tarkime, kad tarp kovariančių x_1 ir x_2 , apibrėžtų 2.7 pavyzdyje, yra sąveika. Tuomet gali būti įvertintas modelis

$$r(x_1, x_2) = \exp\{-\beta_0 - \beta_1 \log x_1 - \beta_2 / x_2 - \beta_3 (\log x_1) / x_2\}. \quad (2.20)$$

2.1.2 Atskiros ir nominaliosios kovariantės

Jeigu kovariantės yra nominaliosios (vartotojų skaičius, besinaudojančių sistema vienu metu), tuomet funkcijų forma turi tokį pat pavidalą, kaip ir tolydžiųjų kovariančių atveju, pvz. φ_j gali būti $\varphi_j(x) = x$, $\ln x$ arba $1/x$.

Jeigu j -oji kovariantė yra nominalioji (vietovė, apdirbamosios pramonės įmonė, dizainas), ir ji įgyja k_j reikšmių, tuomet x suprantamas kaip $(k_j - 1)$ -matis vektorius

$$x_j = (x_{j1}, \dots, x_{j,k-1})^T,$$

imant k_j įvairių dydžių

$$(0,0, \dots, 0)^T, (1,0, \dots, 0)^T, (0,1, \dots, 0)^T, \dots, (0,0, \dots, 1)^T,$$

ir β_j yra $(k_j - 1)$ -matis:

$$\beta_j = (\beta_{j1}, \dots, \beta_{j,k-1})^T.$$

Taigi, jeigu j -oji kovariantė yra nominalioji, o kitos yra tolydžiosios arba diskrečios, tuomet

$$\beta^T x = \beta_0 + \beta_1 x_1 + \dots + \beta_{j-1} x_{j-1} + \sum_{l=1}^{k_j-1} \beta_{jl} x_{jl} + \beta_{j+1} x_{j+1} + \dots + \beta_m x_m. \quad (2.21)$$

Gautas modelis yra ekvivalentus modeliui (2.5) su $m + k_j - 2$ vienmačių kovariančių. Jeigu $k_j = 2$, kovariantė x_j yra dichotominė, įgyjanti dvi reikšmes 0 arba 1.

2.2 Regresijos koeficientų interpretacija

Tarkime, kad kovariantės yra pastovios laike. Tuomet, pagal PG modelį (2.5), T_x gedimo laiko p -kvantilis yra

$$t_p(x) = e^{\beta^T x} S_0^{-1}(1-p), \quad (2.22)$$

taigi logaritmas

$$\ln\{t_p(x)\} = \beta^T x + c_p \quad (2.23)$$

yra tiesinė regresijos parametų funkcija; čia $c_p = \ln(S_0^{-1}(1-p))$.

Tegul

$$m(x) = \mathbf{E}\{T_x\}$$

yra vienetų vidutinis gyvenimas pagal x . Tuomet

$$m(x) = e^{\beta^T x} \int_0^{\infty} S_0(u) du \quad (2.24)$$

ir logaritmas

$$\ln\{m(x)\} = \beta^T x + c \quad (2.25)$$

yra taip pat regresijos parametų tiesinė funkcija; čia

$$c = \ln\left\{\int_0^{\infty} S_0(u) du\right\}.$$

Pažymėkime

$$MR(x, y) = \frac{m(y)}{m(x)} \text{ ir } QR(x, y) = \frac{t_p(y)}{t_p(x)} \quad (2.26)$$

atitinkamai vidurkių ir kvantilių santykius.

PG modeliui

$$MR(x, y) = QR(x, y) = e^{\beta^T (y-x)}. \quad (2.27)$$

Taigi $e^{\beta^T (y-x)}$ yra vidurkių santykis, atitinkantis kovariantes x ir y .

Manykime, kad parametru β_j interpretacija yra pagal modelį (2.5).

2.2.1 Modeliai be sąveikų

a) Tolydžiosios arba diskrečios kovariantės

Tarkime, kad j -oji kovariantė x_j yra tolydi arba diskreti. Tuomet

$$e^{\beta_j} = \frac{e(x_1, \dots, x_j + 1, \dots, x_m)}{e(x_1, \dots, x_j, \dots, x_m)} = MR_j, \quad (2.28)$$

yra vidurkių santykis atitinkantis x_j pasikeitimą per matavimo vienetą.

b) Nominaliosios kovariantės

Sakykime, kad $x_j = (x_{j1}, \dots, x_{j,k_{j-1}})^T$ yra nominalusis. Pirmoji jo reikšmė yra $(0, \dots, 0)^T$, ir $(i+1)$ -oji reikšmė yra $(0, \dots, 0, 1, 0, \dots, 0)^T$, kur vienetą yra i -oji koordinatė. Tuomet

$$e^{\beta_{ji}} = \frac{e(x_1, \dots, x_{j-1}, (0, 0, \dots, 0, 1, 0, \dots, 0), x_{j+1}, \dots, x_m)}{e(x_1, \dots, x_{j-1}, (0, 0, \dots, 0), x_{j+1}, \dots, x_m)} = MR_{ji} \quad (2.29)$$

yra vidurkių santykis atitinkantis x_j pasikeitimus nuo pirmosios iki $(i+1)$ -osios reikšmės.

2.2.2 Modeliai su sąveikomis

Jeigu j -osios kovariantės įtaka vidutiniam gyvenimui yra skirtinga įvairioms kitų kovariančių reikšmėms, tuomet tarp kovariančių yra sąveika ir modelis turi būti modifikuotas.

a) sąveika tarp tolydžiųjų arba diskrečiųjų kovariančių

Jeigu yra dvi tolydžios arba diskrečios kovariantės, ir tarp jų yra sąveika, tuomet

$$\beta^T x = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_1 x_2. \quad (2.30)$$

Trims kovariantėms

$$\beta^T x = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_1 x_2 + \beta_5 x_1 x_3 + \beta_6 x_2 x_3 + \beta_7 x_1 x_2 x_3 \quad (2.31)$$

ir taip toliau.

Tuo atveju, kai yra dvi kovariantės, vidurkių santykis

$$MR_2(x_1) = \frac{m(x_1, x_2 + 1)}{m(x_1, x_2)} = e^{\beta_1 + \beta_3 x_1} \quad (2.32)$$

priklauso nuo x_1 reikšmės. Taigi

$$e^{\beta_1 + \beta_3 x_1} \quad (2.33)$$

yra vidurkių santykis, atitinkantis x_2 pasikeitimą per matavimo vienetą, kita kovariantė yra fiksuojama ir lygi x_1 .

b) *Sąveika tarp tolydžiųjų ar diskrečių ir nominaliųjų kovariančių*

Tarkime, kad yra dvi kovariantės: x_1 yra tolydi arba diskreti, o x_2 yra nominalioji, su k galimų reikšmių.

Tuomet

$$\beta^T x = \beta_1 x_1 + \sum_{i=1}^{k_2-1} \beta_{2i} x_{2i} + \sum_{i=1}^{k_2-1} \beta_{12i} x_1 x_{2i}, \quad (2.34)$$

ir vidutinis santykis

$$MR_{2i}(x_1) = \frac{e(x_1, (0, \dots, 0, 1, 0, \dots, 0))}{e(x_1, (0, \dots, 0))} = e^{\beta_{2i} + \beta_{12i} x_1} \quad (2.35)$$

priklauso nuo x_1 reikšmės.

Taigi šiame pavyzdyje

$$e^{\beta_{2i} + \beta_{12i} x_1}$$

yra vidurkių santykis atitinkantis x_2 pasikeitimą nuo pirmosios iki $(i+1)$ reikšmės, kitos kovariantės yra fiksuojamos ir yra lygios x_1 .

c) *Sąveika tarp nominaliųjų kovariančių*

Tegul abu x_1 ir x_2 yra nominalieji kintamieji, turintys tris reikšmes kiekvienas. Tuomet

$$x_1 = (x_{11}, x_{12})^T, \quad x_2 = (x_{21}, x_{22})^T,$$

ir

$$\beta^T x = \beta_{11} x_{11} + \beta_{12} x_{12} + \beta_{21} x_{21} + \beta_{22} x_{22} + \beta_{1121} x_{11} x_{21} + \beta_{1122} x_{11} x_{22} + \beta_{1221} x_{12} x_{21} + \beta_{1222} x_{12} x_{22}.$$

Šiuo atveju santykis

$$MR_{22}(x_1) = \frac{e(x_1, (1, 0))}{e(x_1, (0, 0))} = e^{\beta_{21} + \beta_{1121} x_{11} + \beta_{1221} x_{12}}$$

priklauso nuo $x_1 = (x_{11}, x_{12})^T$ reikšmės.

Taigi

$$e^{\beta_{21} + \beta_{1121} x_{11} + \beta_{1221} x_{12}}$$

yra vidurkių santykis atitinkantis x_2 pasikeitimą nuo pirmos iki antros reikšmės, kita kovariantė yra fiksuojama ir lygi $x_1 = (x_{11}, x_{12})^T$.

Apibendrinimas yra akivaizdus, jeigu kovariantės įgyja tris ar daugiau reikšmes.

2.2.3 Nuo laiko priklausantys regresijos koeficientai

Nagrinėkime PG modelį su kovariantėmis priklausančiomis nuo laiko

$$S_{x(\cdot)} = G \left\{ \int_0^t e^{-\beta^T(u)x(u)} du \right\}. \quad (2.36)$$

Nagrinėsime koeficientus $\beta_i(t)$ modelyje $\beta_i(t) = \beta_i + \gamma_i g_i(t)$, ($i=1, 2, \dots, m$), kur $g_i(t)$ yra apibrėžtos deterministinės funkcijos arba spėjamų procesų realizacijos. Šiuo atveju PG modelis su nuo laiko priklausančiais koeficientais ir pastoviais ar nuo laiko priklausančiomis kovariantėmis gali būti užrašytas (2.4) pavidalu su įvairia kovariančių interpretacija. Iš tikrųjų, tegul

$$\theta = (\theta_0, \theta_1, \dots, \theta_{2m})^T = (\beta_0, \beta_1, \dots, \beta_m, \gamma_1, \dots, \gamma_m)^T, \\ z(\cdot) = (z_0(\cdot), z_1(\cdot), \dots, z_{2m}(\cdot))^T = (1, x_1(\cdot), \dots, x_m(\cdot), x_1(\cdot)g_1(\cdot), \dots, x_m(\cdot)g_m(\cdot))^T. \quad (2.37)$$

Tuomet

$$\beta^T(u)x(u) = \beta_0 + \sum_{i=1}^m (\beta_i + \gamma_i g_i(t))x_i(t) = \theta^T z(u).$$

Taigi PG modelis su nuo laiko priklausančiais regresijos koeficientais gali būti užrašytas taip

$$S_{z(\cdot)} = G \left\{ \int_0^t e^{-\theta^T z(u)} du \right\}. \quad (2.38)$$

Mes turime PG modelį, kuriame nežinomi parametrai ir kovariantės yra apibrėžtos (2.37).

2.3 GL duomenų analizė: pasiskirstymų šeimos, apibrėžiamos mastelio formos parametrais

2.3.1 Modelis ir duomenys

Tarkime, kad PG modelis:

$$S_{x(\cdot)}(t) = S_0 \left(\int_0^t e^{-\beta^T x(\tau)} d\tau \right), \quad (2.39)$$

arba PG modelis su nuo laiko priklausančiais regresijos koeficientais, ir tegul S_0 priklausys apibrėžtai išgyvenamumo funkcijų mastelio klasei:

$$S_0(t) = G_0 \{ (t/\eta)^\nu \} \quad (\eta, \nu > 0).$$

Pavyzdžiui, jeigu $t > 0$

$$G_0(t) = e^{-t}, \quad G_0(t) = (1+t)^{-1}, \quad G_0(t) = 1 - \Phi(\ln t),$$

tuomet atitinkamai gauname Veibulo, loglogistinių ir lognormaliųjų pasiskirstymų šeimas. Čia Φ yra standartinio normalaus pasiskirstymo funkcija.

Parametras η gali būti įtrauktas į koeficientą β_0 , taigi tarkime, kad

$$S_0(t; \sigma) = G_0(t^{1/\sigma}), \quad \sigma = 1/\nu.$$

Atkreipkite dėmesį į tai, kad vertinant PG modelį su nuo laiko priklausančiais regresijos koeficientais $\beta_i(t) = \beta_i + \gamma_i g_i(t)$, netgi pastovių kovariančių atveju modelis (2.36) yra suvedamas į PG modelį (2.38), kuris yra ekvivalentus modeliui (2.39) su nuo laiko priklausančiomis kovariantėmis $z(\cdot)$. Taigi visi rezultatai, gauti PG modeliui, su nuo laiko priklausančiomis kovariantėmis gali būti perrašyti PG modeliui su nuo laiko priklausančiais regresijos koeficientais ir pastoviomis arba nuo laiko priklausančiomis kovariantėmis. Visose formulėse

$$m, \beta = (\beta_1, \dots, \beta_m)^T, \quad x^{(i)}(\cdot) = (x_1^{(i)}(\cdot), \dots, x_m^{(i)}(\cdot))^T$$

gali būti pakeisti į

$$2m, \theta = (\beta_1, \dots, \beta_m, \gamma_1, \dots, \gamma_m)^T, \\ z^{(i)}(\cdot) = (x_1^{(i)}(\cdot), \dots, x_m^{(i)}(\cdot), x_1^{(i)}(\cdot)g_1(\cdot), \dots, x_m^{(i)}(\cdot)g_m(\cdot))^T$$

atitinkamai.

EKSPERIMENTŲ PLANAS:

Stebime n vienetų. Yra tikrinamas i -asis vienetas pagal reikšmę

$$x^{(i)}(\cdot) = (x_0^{(i)}(\cdot), \dots, x_m^{(i)}(\cdot))^T$$

galimų laike kintančių ir daugiamačių kovariančių

$$x(\cdot) = (x_0(\cdot), \dots, x_m(\cdot))^T.$$

Tariama, kad duomenys yra cenzūruojami nepriklausomai iš dešinės.

Tegul T_i ir C_i yra i -ojo vieneto gedimo ir cenzūravimo laikai,

$$X_i = T_i \wedge C_i, \quad \delta_i = \mathbf{1}_{\{T_i \leq C_i\}}.$$

Pažymėkime S_i išgyvenamumo funkciją $S_{x^{(i)}(\cdot)}$. Modelis (2.4) gali būti užrašyti tokiu pavidalu

$$S_i(t; \beta, \sigma) = G_0 \left\{ \left(\int_0^t e^{-\beta^T x^{(i)}(u)} du \right)^{1/\sigma} \right\}. \quad (2.40)$$

Jeigu $x^{(i)}$ yra pastovus, tuomet

$$S_i(t) = G \left(\frac{\ln t - \beta^T x^{(i)}}{\sigma} \right), \quad (2.41)$$

kur

$$G(u) = G_0(e^u), \quad u \in \mathbf{R}.$$

Pastebėkime, kad atsitiktinio kintamojo pasiskirstymas

$$R_i = \left\{ \int_0^{T_{x^{(i)}(\cdot)}} e^{-\beta^T x^{(i)}(\tau)} d\tau \right\}^{1/\sigma} \quad (2.42)$$

yra ne-parametrinis su išgyvenamumo funkcija G_0 . Pastoviam $x^{(i)}$:

$$R_i = \{T_{x^{(i)}} e^{-\beta^T x^{(i)}}\}^{1/\sigma}.$$

Nustatykime

$$g(u) = -G'(u), \quad h(u) = \frac{g(u)}{G(u)}. \quad (2.43)$$

Veibulo dėsniai:

$$G(u) = e^{-e^u}, \quad g(u) = e^u e^{-e^u}, \quad h(u) = e^u, \quad (\ln h)'(u) = 1; \quad (2.44)$$

loglogistiniam dėsniai:

$$G(u) = (1 + e^u)^{-1}, \quad g(u) = \frac{e^u}{(1 + e^u)^2}, \quad h(u) = e^u (1 + e^u)^{-1}, \quad (\ln h)'(u) = (1 + e^u)^{-1}; \quad (2.45)$$

Lognormaliajam dėsniai:

$$G(u) = 1 - \Phi(u), \quad g(u) = \varphi(u), \quad h(u) = \frac{\varphi(u)}{1 - \Phi(u)}, \quad (\ln h)'(u) = h(u) - u, \quad (2.46)$$

su

$$\varphi(t) = \frac{1}{\sqrt{2\pi}} e^{-t^2/2}.$$

2.3.2 Regresijos parametrų maksimalaus tikėtimumo įvertis

Tikėtimumo funkcija yra

$$L(\beta, \sigma) = \prod_{i=1}^n \left\{ \frac{1}{\sigma} e^{-\beta^T x^{(i)}(X_i)} \left(\int_0^{X_i} e^{-\beta^T x^{(i)}(u)} du \right)^{-1} \times \right. \\ \left. h \left(\frac{1}{\sigma} \ln \left(\int_0^{X_i} e^{-\beta^T x^{(i)}(u)} du \right) \right) \right\}^{\delta_i} G \left(\frac{1}{\sigma} \ln \left(\int_0^{X_i} e^{-\beta^T x^{(i)}(u)} du \right) \right). \quad (2.47)$$

Jeigu $x^{(i)}$ yra pastovūs, tuomet tikėtinumo funkcija yra

$$L(\beta, \sigma) = \prod_{i=1}^n \left\{ \frac{1}{\sigma X_i} h \left(\frac{\ln X_i - \beta^T x^{(i)}}{\sigma} \right) \right\}^{\delta_i} G \left(\frac{\ln X_i - \beta^T x^{(i)}}{\sigma} \right). \quad (2.48)$$

Rezultatyvios funkcijos yra

$$U_l(\beta; \sigma) = \frac{\partial \ln L(\beta, \sigma)}{\partial \beta_l} = \frac{1}{\sigma} \sum_{i=1}^n z_l^{(i)}(\beta) a_i(\beta, \sigma) + \sum_{i=1}^n \delta_i (z_l^{(i)}(\beta) - x_l^{(i)}(X_i)), \quad (l = 0, 1, \dots, m),$$

$$U_{m+1}(\beta; \sigma) = \frac{\partial \ln L(\beta, \sigma)}{\partial \sigma} = \frac{1}{\sigma} \sum_{i=1}^n \{v_i(\beta, \sigma) a_i(\beta, \sigma) - \delta_i\}; \quad (2.49)$$

čia

$$v_i(\beta, \sigma) = \frac{1}{\sigma} \ln \left(\int_0^{X_i} e^{-\beta^T x^{(i)}(u)} du \right), \quad a_i(\beta, \sigma) = h(v_i(\beta, \sigma)) - \delta_i (\ln h)'(v_i(\beta, \sigma)),$$

$$z_l^{(i)}(\beta) = \frac{\int_0^{X_i} x_l^{(i)}(u) e^{-\beta^T x^{(i)}(u)} du}{\int_0^{X_i} e^{-\beta^T x^{(i)}(u)} du}, \quad (2.50)$$

ir funkcija h pateikta (2.43). Pastovių kovariančių atveju rezultatyvios funkcijos yra

$$U_l(\beta; \sigma) = \frac{\partial \ln L(\beta, \sigma)}{\partial \beta_l} = \frac{1}{\sigma} \sum_{i=1}^n x_l^{(i)} a_i(\beta, \sigma), \quad (l = 0, 1, \dots, m),$$

$$U_{m+1}(\beta; \sigma) = \frac{\partial \ln L(\beta, \sigma)}{\partial \sigma} = \frac{1}{\sigma} \sum_{i=1}^n \{v_i(\beta, \sigma) a_i(\beta, \sigma) - \delta_i\}, \quad (2.51)$$

kur

$$v_i(\beta, \sigma) = \frac{\ln X_i - \beta^T x^{(i)}}{\sigma}, \quad a_i(\beta, \sigma) = h(v_i(\beta, \sigma)) - \delta_i (\ln h)'(v_i(\beta, \sigma)), \quad (2.52)$$

ir $(\ln h)'(u)$ yra pateikta (2.43).

Maksimalaus tikėtinumo įverčiai $\hat{\beta}_j, \hat{\sigma}$ gaunami sprendžiant lygčių sistemą $U_l(\beta, \sigma) = 0$ ($l = 0, 1, \dots, m+1$).

2.3.3 Pagrindinių patikimumo charakteristikų įverčiai

Tarkime, kad $x(\cdot) = (x_1(\cdot), \dots, x_m(\cdot))^T$ yra sutartinė kovariantė, kuri gali skirtis nuo $x^{(i)}(\cdot), (i = 1, \dots, n)$.

Išgyvenamumo funkcijos $S_{x(\cdot)}(t)$ įvertis:

$$\hat{S}_{x(\cdot)}(t) = G_0 \left\{ \left(\int_0^t e^{-\hat{\beta}^T x(u)} du \right)^{1/\hat{\sigma}} \right\}. \quad (2.53)$$

Tuo atveju, kai x yra pastovus, išgyvenamumo funkcijos $S_x(t)$ įvertis yra

$$\hat{S}_x(t) = G \left(\frac{\ln t - \hat{\beta}^T x}{\hat{\sigma}} \right). \quad (2.54)$$

PG modelyje su nuo laiko priklausančiais regresijos koeficientais manoma, kad

$$\hat{S}_{z(\cdot)}(t) = G_0 \left\{ \left(\int_0^t e^{-\hat{\theta}^T z(u)} du \right)^{1/\hat{\sigma}} \right\},$$

kur $\theta = (\beta_1, \dots, \beta_m, \gamma_1, \dots, \gamma_m)^T$, $z^{(i)}(\cdot) = (x_1^{(i)}(\cdot), \dots, x_m^{(i)}(\cdot), x_1^{(i)}(\cdot)g_1(\cdot), \dots, x_m^{(i)}(\cdot)g_m(\cdot))^T$.

p -kvantilio įvertis $t_p(x(\cdot))$:

Įvertis $\hat{t}_p(x(\cdot))$ tikrina lygtį:

$$G_0 \left\{ \left(\int_0^{\hat{t}_p(x(\cdot))} e^{-\hat{\beta}^T x(u)} du \right)^{1/\hat{\sigma}} \right\} = 1 - p. \quad (2.55)$$

Jeigu x yra pastovus, tuomet

$$\hat{t}_p(x) = e^{\hat{\beta}^T x} \left\{ G_0^{-1}(1-p) \right\}^{\hat{\sigma}}. \quad (2.56)$$

Vidutinio gedimo laiko $m(x(\cdot))$ įvertis:

$$\hat{m}(x(\cdot)) = \int_0^\infty \hat{S}_{x(\cdot)}(u) du. \quad (2.57)$$

Jeigu x yra pastovus, tuomet

$$\hat{m}(x) = \hat{\sigma} e^{\hat{\beta}^T x} \int_0^\infty u^{\hat{\sigma}-1} G_0(u) du. \quad (2.58)$$

Vidutinių santykių įverčiai:

Vidutinis santykis $MR(x, y)$ (žr. (2.27)) yra vertinamas

$$\hat{MR}(x, y) = e^{\hat{\beta}^T (y-x)}. \quad (2.59)$$

1) Modeliai be sąveikų.

a) Tolydi arba diskreti kovariantė x_j .

Vidutinis santykis MR_j (žr. (2.28)) yra vertinamas

$$\hat{MR} = e^{\hat{\beta}_j}. \quad (2.60)$$

b) Nominalioji kovariantė x_j .

Vidutinis santykis MR_{ji} , (žr. (2.29)), yra vertinamas

$$\hat{MR}_{ji} = e^{\hat{\beta}_{ji}}. \quad (2.61)$$

2) Modeliai su sąveikomis.

a) Tolydus (diskretus) \times tolydūs (diskretūs) kintamieji.

Jeigu dvi tolydžios (diskrečios) kovariantės, pavyzdžiui x_1 ir x_2 , sąveikauja, tuomet vidutinis santykis $MR_2(x_1)$, (žr. (2.32)), vertinamas

$$\hat{MR}_2(x_1) = e^{\hat{\beta}_1 + \hat{\beta}_3 x_1}. \quad (2.62)$$

b) Tolydi (diskreti) \times nominalioji.

Jeigu tolydi (diskreti) kovariantė x_1 sąveikauja su k_2 -vertinamąja nominaliąja kovariante x_2 , tuomet vidutinis santykis $MR_{2i}(x_1)$, (žr. modelį (2.35)), vertinamas

$$\hat{MR}_{2i}(x_1) = e^{\hat{\beta}_{2i} + \hat{\beta}_{12i} x_1}. \quad (2.63)$$

c) Nominalioji \times nominaliosios kovariantės.

Jeigu dvi nominaliosios kovariantės x_1 ir x_2 (su, tarkime, trimis galimomis reikšmėmis) sąveikauja, tuomet vidutinis santykis MR_{22} vertinamas

$$e^{\hat{\beta}_{21} + \hat{\beta}_{1121} x_{11} + \hat{\beta}_{1221} x_{12}}. \quad (2.64)$$

2.3.4 Asimptotinis regresijos parametru įverčių pasiskirstymas

Pagal reguliavimo sąlygas maksimalaus tikėtimumo įverčių $(\hat{\beta}, \hat{\sigma})^T$ pasiskirstymas dideliems n yra aproksimuojamas pagal normalųjį dėsnį:

$$(\hat{\beta}, \hat{\sigma})^T \approx N_{m+2}((\beta, \sigma)^T, \sum^{-1}(\beta, \sigma)).$$

Kovariacijų matrica $\sum^{-1}(\beta, \sigma)$ yra vertinama pagal

$$\mathbf{I}^{-1}(\hat{\beta}, \hat{\sigma}) = (I^{ls}(\hat{\beta}, \hat{\sigma}))_{(m+2) \times (m+2)}, \quad (2.65)$$

kur

$$\mathbf{I}(\beta, \sigma) = (I_{lk}(\beta, \sigma))_{(m+2) \times (m+2)} \quad (2.66)$$

yra matrica su sekančiais elementais:

$$I_{ls}(\beta, \sigma) = -\frac{\partial^2 \ln L(\beta, \sigma)}{\partial \beta_l \partial \beta_s}, \quad I_{l,m+1}(\beta, \sigma) = -\frac{\partial^2 \ln L(\beta, \sigma)}{\partial \beta_l \partial \sigma},$$

$$I_{m+1,m+1}(\beta, \sigma) = -\frac{\partial^2 \ln L(\beta, \sigma)}{\partial \sigma^2} \quad (l, s = 0, \dots, m).$$

Detaliau, įverčio $\hat{\beta}_j$ dispersija yra vertinama pagal

$$\mathbf{Var}\{\hat{\beta}_j\} = I^{jj}(\hat{\beta}, \hat{\sigma}) \quad (2.67)$$

ir

$$\frac{\hat{\beta}_j - \beta_j}{(\mathbf{Var}\hat{\beta}_j)^{1/2}} \approx N(0,1), \quad (j=0, \dots, m). \quad (2.68)$$

Matricos $\mathbf{I}(\beta, \sigma)$ elementų išraiškos yra (žr. užrašymus (2.50)):

$$I_{ls}(\beta, \sigma) = \frac{1}{\sigma^2} \sum_{i=1}^n y_l^{(i)}(\beta) y_s^{(i)}(\beta) c_i(\beta, \sigma) - \frac{1}{\sigma} \sum_{i=1}^n y_{ls}^{(i)}(\beta) (a_i(\beta, \sigma) + \sigma \delta_i),$$

$$I_{l,m+1}(\beta, \sigma) = \frac{1}{\sigma^2} \sum_{i=1}^n y_l^{(i)}(\beta) (v_i(\beta, \sigma) c_i(\beta, \sigma) + a_i(\beta, \sigma)), \quad l, s = 0, \dots, m$$

$$I_{m+1,m+1}(\beta, \sigma) = \frac{1}{\sigma} U_{m+1}(\beta, \sigma) + \frac{1}{\sigma^2} \sum_{i=1}^n v_i(\beta, \sigma) (v_i(\beta, \sigma) c_i(\beta, \sigma) + a_i(\beta, \sigma)), \quad (2.69)$$

kur

$$c_i(\beta, \sigma) = h'(v_i(\beta, \sigma)) - \delta_i (\ln h)''(v_i(\beta, \sigma)),$$

$$y_{ls}^{(i)}(\beta) = \frac{\int_0^{X_i} x_l^{(i)}(u) e^{-\beta^T x^{(i)}(u)} du \int_0^{X_i} x_s^{(i)}(u) e^{-\beta^T x^{(i)}(u)} du - \int_0^{X_i} x_l^{(i)}(u) x_s^{(i)}(u) e^{-\beta^T x^{(i)}(u)} du}{\left(\int_0^{X_i} e^{-\beta^T x^{(i)}(u)} du \right)^2} \cdot \int_0^{X_i} e^{-\beta^T x^{(i)}(u)} du. \quad (2.70)$$

Jeigu $x^{(i)}$ yra pastovūs laike, tuomet

$$I_{ls}(\beta, \sigma) = \frac{1}{\sigma^2} \sum_{i=1}^n x_l^{(i)} x_s^{(i)} c_i(\beta, \sigma),$$

$$I_{l,m+1}(\beta, \sigma) = \frac{1}{\sigma} U_l(\beta, \sigma) + \frac{1}{\sigma^2} \sum_{i=1}^n x_l^{(i)} v_i(\beta, \sigma) c_i(\beta, \sigma),$$

$$I_{m+1,m+1}(\beta, \sigma) = \frac{1}{\sigma} U_{m+1}(\beta, \sigma) + \frac{1}{\sigma^2} \sum_{i=1}^n v_i(\beta, \sigma) (v_i(\beta, \sigma) c_i(\beta, \sigma) + a_i(\beta, \sigma)). \quad (2.71)$$

Pastebėkime, kad nuo laiko priklausančių regresijos koeficientų $m, \beta, x^{(i)}$ atveju, jie yra pakeičiami $2m, \theta, z^{(i)}$.

2.3.5 Aproximatyvūs patikimumo intervalai išgyvenamumo funkcijoms

Išgyvenamumo funkcijos, kvantiliai, vidutinės gyvenimo trukmės ir vidutiniai santykiai yra β ir σ parametrų funkcijos. Taigi asimptotiniai pasiskirstymai ir aproksimaciniai patikimumo intervalai jiems gaunami naudojant delta metodą.

Aproksimaciniai patikimumo intervalai išgyvenamumo funkcijoms

Formulė

$$\left(\left(1 + \frac{1 - S(t, \hat{\theta})}{S(t, \hat{\theta})} e^{\sigma_Q(\hat{\theta})\omega_{1-\alpha/2}} \right)^{-1}, \left(1 + \frac{1 - S(t, \hat{\theta})}{S(t, \hat{\theta})} e^{-\sigma_Q(\hat{\theta})\omega_{1-\alpha/2}} \right)^{-1} \right)$$

reiškia, kad bet kuriam $x(\cdot) = (x_0(\cdot), x_1(\cdot), \dots, x_m(\cdot)) \in E_0$, $x_0(\cdot) = 1$, aproksimacinis $(1 - \alpha)$ -patikimumo intervalas išgyvenamumo funkcijai $S_{x(\cdot)}(t)$ apibrėžiamas formule

$$\left(1 + \frac{1 - \hat{S}_{x(\cdot)}(t)}{\hat{S}_{x(\cdot)}(t)} \exp\left\{ \pm \hat{\sigma}_{Q_{x(\cdot)}}(t) \omega_{1-\alpha/2} \right\} \right)^{-1}, \quad (2.72)$$

kur ω_α yra normalaus dėsnio $N(0,1)$ α -kvantilis ir

$$\hat{\sigma}_{Q_{x(\cdot)}}^2(t) = \frac{J_{S_{x(\cdot)}(t)}^T \mathbf{I}^{-1}(\hat{\beta}, \hat{\sigma}) J_{S_{x(\cdot)}(t)}}{\hat{S}_{x(\cdot)}^2(t) (1 - \hat{S}_{x(\cdot)}(t))^2}, \quad (2.73)$$

$$J_{S_{x(\cdot)}(t)}^T = -\frac{G'(G^{-1}(\hat{S}_{x(\cdot)}(t)))}{\hat{\sigma}_{Q_{x(\cdot)}}^2(t)} \times \left(\hat{\sigma}_{Q_{x(\cdot)}}(t) \frac{\int_0^t x^T(u) e^{-\hat{\beta}^T x(u)} du}{\int_0^t e^{-\hat{\beta}^T x(u)} du}, \ln \left\{ \int_0^t e^{-\hat{\beta}^T x(u)} du \right\} \right).$$

Jeigu x yra pastovus laike, tuomet

$$J_{S_x(t)}^T = -\frac{G'(G^{-1}(\hat{S}_x(t)))}{\hat{\sigma}_{Q_x}^2(t)} \times \left(\hat{\sigma}_{Q_x}(t) x^T, \ln t - \hat{\beta}^T x \right).$$

Aproksimaciniai patikimumo intervalai kvantiliams

Formulė

$$\left(g(\hat{\theta}) \exp\{-\sigma_K(\hat{\theta})\omega_{1-\alpha/2}\}, g(\hat{\theta}) \exp\{\sigma_K(\hat{\theta})\omega_{1-\alpha/2}\} \right)$$

reiškia, kad aproksimacinis $(1 - \alpha)$ – patikimumo intervalas p -kvantiliui $t_p(x(\cdot))$ yra

$$\hat{t}_p(x(\cdot)) \exp\left\{ \pm \hat{\sigma}_{K_p(x(\cdot))} \omega_{1-\alpha/2} \right\}, \quad (2.74)$$

kur

$$\hat{\sigma}_{K_p(x(\cdot))}^2 = \frac{1}{\hat{t}_p^2(x(\cdot))} J_{t_p(x(\cdot))}^T \mathbf{I}^{-1}(\hat{\beta}, \hat{\sigma}) J_{t_p(x(\cdot))},$$

kur

$$J_{t_p(x(\cdot))}^T = e^{\hat{\beta}^T x(\hat{t}_p(x(\cdot)))} \left(\int_0^{\hat{t}_p(x(\cdot))} x(u) e^{-\hat{\beta}^T x(u)} du, (G_0^{-1}(1-p))^{\hat{\sigma}} \ln G_0^{-1}(1-p) \right).$$

Pastoviam laike x mes turime

$$J_{t_p(x)}^T = \hat{t}_p(x) (x, \ln G_0^{-1}(1-p)).$$

Aproksimacinis patikimumo intervalas vidutinei gyvenimo trukmei

Formulė

$$\left(g(\hat{\theta}) \exp\{-\sigma_K(\hat{\theta})\omega_{1-\alpha/2}\}, g(\hat{\theta}) \exp\{\sigma_K(\hat{\theta})\omega_{1-\alpha/2}\} \right)$$

reiškia, kad aproksimacinis $(1-\alpha)$ – patikimumo intervalas vidutinei gyvenimo trukmei $m(x(\cdot))$ yra

$$\hat{m}(x(\cdot)) \exp\left\{ \pm \frac{\hat{\sigma}_{m(x(\cdot))}(\hat{\beta}, \hat{\sigma})}{\hat{m}(x(\cdot))} \omega_{1-\alpha/2} \right\}, \quad (2.75)$$

kur

$$\hat{\sigma}_{m(x(\cdot))}^2 = J_{m(x(\cdot))}^T \mathbf{I}^{-1}(\hat{\beta}, \hat{\sigma}) J_{m(x(\cdot))},$$

$$J_{m(x(\cdot))} = \int_0^\infty J_{S_{x(\cdot)}(t)} dt.$$

Jeigu $x=const$, tuomet

$$\hat{\sigma}_{m(x)}^2(\hat{\beta}, \hat{\sigma}) = \sum_{l=0}^{m+1} \sum_{s=0}^{m+1} b_l(\hat{\beta}, \hat{\sigma}) I^{ls}(\hat{\beta}, \hat{\sigma}) b_s(\hat{\beta}, \hat{\sigma})$$

ir

$$b_i(\hat{\beta}, \hat{\sigma}) = \frac{\partial}{\partial \hat{\beta}_i} \hat{m}(x) = \hat{m}(x) x_i \quad (i = 0, 1, \dots, m),$$

$$b_{m+1}(\hat{\beta}, \hat{\sigma}) = \frac{\partial}{\partial \hat{\sigma}} \hat{m}(x) = \frac{\hat{m}(x)}{\hat{\sigma}} + \hat{\sigma} e^{\hat{\beta}^T x} \int_0^\infty u^{\hat{\sigma}-1} G_0(u) \ln u du.$$

Aproksimuoti patikimumo intervalai vidutiniams santykiams

Formulė

$$\left(g(\hat{\theta}) \exp\{-\sigma_K(\hat{\theta})\omega_{1-\alpha/2}\}, g(\hat{\theta}) \exp\{\sigma_K(\hat{\theta})\omega_{1-\alpha/2}\} \right)$$

reiškia, kad aproksimacinis $(1-\alpha)$ – patikimumo intervalas vidutiniam santykiui $MR(x, y)$ yra

$$\left(\exp\left\{ \hat{\beta}^T (y - x) - \hat{\sigma}_{MR} \right\} \omega_{1-\alpha/2}, \exp\left\{ \hat{\beta}^T (y - x) + \hat{\sigma}_{MR} \right\} \omega_{1-\alpha/2} \right), \quad (2.76)$$

kur

$$\hat{\sigma}_{MR}^2 = \sum_{l=0}^m \sum_{s=0}^m (y_l - x_l) I^{ls}(\hat{\beta}, \hat{\sigma}) (y_s - x_s). \quad (2.77)$$

2.4 Eksperimentų planai pagreitinto gyvenimo bandymuose (PGB)

PGB tikslas yra pateikti įverčius pagrindinėms patikimumo charakteristikoms prie normaliosios apkrovos, naudojant pagreitintų eksperimentų duomenis, kuomet gaminiai yra bandomi didesnės nei normaliosios apkrovos sąlygomis.

Apkrova x_2 yra didesnė nei apkrova $x_1(\cdot), x_2(\cdot) > x_1(\cdot)$, jei bet kokiam $t \geq 0$ nelygybė $S_{x_1(\cdot)}(t) \geq S_{x_2(\cdot)}(t)$ išlieka, ir egzistuoja $t_0 > 0$ toks, kad $S_{x_1(\cdot)}(t_0) > S_{x_2(\cdot)}(t_0)$.

Pažymėkime normaliąją apkrovą $x_0 = (x_{00}, x_{01}, \dots, x_{0m}), x_{00} = 1$. Tegu PG modelis galioja apkrovų aibėje E , tuomet bet kokiam $x(\cdot) \in E$:

$$S_{x(\cdot)}(t) = S_0 \left(\int_0^t r\{x(\tau)\} d\tau \right). \quad (2.78)$$

Jeigu $x(\tau) \equiv x = const$, tuomet

$$S_x(t) = S_0(r(x)t). \quad (2.79)$$

Dažniausiai pagreitinti eksperimentai yra atliekami su vienmate apkrova ($m = 1$), kartais su dimate ($m = 2$).

Pagreitintuose bandymuose gali būti naudojami keli eksperimentų planai. Mus domina *pirmasis planas*.

2.4.1 Pirmasis eksperimentų planas

Tegul x_1, \dots, x_k yra pastovios laike pagreitinotos apkrovos:

$$x_0 < x_1 < \dots < x_k;$$

čia $x_i = (x_{i0}, x_{i1}, \dots, x_{im}), x_{i0} = 1$. Normalioji apkrova x_0 nėra naudojama eksperimento metu.

Yra bandomos k -grupių. i -toji grupė iš n_i vienetų, $\sum_{i=1}^k n_i = n$, yra testuojama su x_i apkrova. Duomenys gali būti pilni arba cenzūruoti nepriklausomai iš dešinės.

Jeigu funkcijos r pavidalas yra visiškai nežinomas ir naudojamas šis eksperimentų planas, funkcija S_{x_0} niekada negali būti vertinama, kai tariama, kad yra žinoma parametrinė šeima, kuriai priklauso $S_{x_0}(t)$ pasiskirstymas.

Pavyzdžiui, jeigu $S_0(t) = e^{-(t/\theta)^\alpha}$, tuomet pastovioms apkrovoms

$$S_x(t) = \exp\left\{-\left(\frac{r(x)}{\theta}t\right)^\alpha\right\}.$$

Pagal pateiktą eksperimentų planą gali būti įvertinti parametrai

$$\alpha, \frac{r(x_1)}{\theta}, \dots, \frac{r(x_k)}{\theta}$$

ir funkcijos

$$S_{x_1}(t), \dots, S_{x_k}(t).$$

Vis dėlto, funkcija $r(x)$ yra visiškai nežinoma, parametras $r(x_0)$ negali būti užrašytas kaip žinoma šių įvertintų parametrų funkcija. Taigi $r(x_0)$ ir, vadinasi, $S_{x_0}(t)$ negali būti įvertinti.

Taigi, funkcija r turi būti pasirinkta iš funkcijų klasės. Dažnai yra naudojamas modelis

$$S_x(t) = S_0(e^{-\beta^T x} t), \quad (2.80)$$

su $x = (x_0, \dots, x_m)^T$, $\beta = (\beta_0, \dots, \beta_m)^T$, kur x_j gali būti ne apkrovos komponentės, bet kai kurios funkcijos $\varphi_j(x)$ iš jų.

Funkcijų $\varphi_j(x)$ pasirinkimas yra labai svarbus pagreitinto gyvenimo bandymuose, nes *normalioji apkrova nėra eksperimente panaudotų apkrovų srityje*, ir netinkamas modelio pasirinkimas gali duoti netinkamus patikimumo charakteristikų su normaliąja apkrova įverčius.

2.5 Parametrinis vertinimas PGB pagal PG modelį

Tarkime, kad pradinė išgyvenamumo funkcija S_0 PG modelyje (2.1) priklauso apibrėžtai pasiskirstymų klasei.

Kiekvienas iš PGB eksperimentų planų yra atskiras atvejis eksperimentų plano, aprašyto dalyje (2.3.1).

Pirmasis planas yra atskiras atvejis to bendrojo plano, imant

$$x^{(i)} = \begin{cases} x_1, & i = 1, \dots, n_1, \\ x_2, & i = n_1 + 1, \dots, n_1 + n_2, \\ \dots & \dots \\ x_k, & i = \sum_{j=1}^{k-1} n_j + 1, \dots, n \end{cases}, \quad (2.81)$$

kur $x_j = (x_{j0}, \dots, x_{jm})$ ($j = 1, \dots, k$).

Antrasis planas: $x^{(i)}(\cdot) = x(\cdot)$ bet kokiam $i = 1, \dots, n$, kur

$$x(\tau) = \begin{cases} x_1, & 0 \leq \tau < t_1, \\ x_2, & t_1 \leq \tau < t_2, \\ \dots & \dots \\ x_k, & t_{m-1} \leq \tau < t_k \end{cases}, \quad (2.82)$$

ir $x_j = (x_{j0}, \dots, x_{jm})$ ($j = 1, \dots, k$).

Pastebėkime skirtumą. Pirmojo plano atveju, pastovioji apkrova x_j naudojama *visą laiką j-ajai vienetų grupei*. Antrojo plano atveju, pastovioji apkrova x_j naudojama *visiems vienetams intervale $[t_{j-1}, t_j)$* .

Trečiasis planas: $x^{(i)}(\tau) = x_1, \tau \geq 0$ ($i = 1, \dots, n_1$);

$$x^{(i)}(\tau) = \begin{cases} x_1, & \tau < t_1, \\ x_0, & \tau \in [t_1, t_2], \end{cases} (i = n_1 + 1, \dots, n), \quad (2.83)$$

kur $x_j = (x_{j0}, \dots, x_{jm})$ ($i = 1, 2$).

2.5.1 Pagrindinių patikimumo charakteristikų su normaliaja apkrova įverčiai

Pirmasis ir antrasis planai

Įverčiai patikimumo funkcijos $S_{x_0}(t)$, p -kvantilio $t_p(x_0)$ ir vidutinio laiko $m(x_0)$ su normaliaja apkrova x_0 yra apskaičiuojami, naudojant formules (2.54), (2.56) ir (2.58) (mastelio pasiskirstymų šeimos), taip pat apibendrinto Veibulo bei eksponentinio pasiskirstymo, ir visose formulėse tariama, kad $x = x_0$.

Pasirenkant apibrėžtą mastelio pasiskirstymų šeimą ir $r(x)$ parametrizacijos, gaunamos konkrečios įverčių formulės.

2.9 PAVYZDYS

Jeigu T_{x_0} turi Veibulo pasiskirstymą, pvz.

$$S_{x_0}(t) = e^{-(t/\theta)^v}, \quad t \geq 0,$$

ir pasirinkta Arrhenius parametrizacija (pavyzdžiui, apkrova yra temperatūra), pvz.

$$r(x) = e^{-\beta_0 - \beta_1/x},$$

tuomet

$$G(t) = \exp\{\exp(-t)\}, \quad \hat{S}_{x_0(t)} = \exp\left\{-\exp\left\{\frac{\ln t - \hat{\beta}_0 - \hat{\beta}_1/x_0}{\hat{\sigma}}\right\}\right\}, \quad \hat{t}_p(x_0) = e^{\hat{\beta}_0 + \hat{\beta}_1/x_0} (-\ln(1-p))^{\hat{\sigma}}.$$

2.10 PAVYZDYS

Jeigu T_{x_0} turi loglogistinį pasiskirstymą, pvz.

$$S_{x_0}(t) = (1 + (t/\theta)^v)^{-1}, \quad t \geq 0,$$

ir laipsninio dėsnio parametrizacija yra pasirinkta (pavyzdžiui, apkrova yra įtampa), pvz.

$$r(x) = e^{-\beta_0 - \beta_1 \ln x},$$

tuomet

$$G(t) = (1 + e^t)^{-1}, \hat{S}_{x_0}(t) = \left[1 + \exp\left(\frac{\ln t - \hat{\beta}_0 - \hat{\beta}_1 \ln x_0}{\hat{\sigma}}\right) \right]^{-1}, \hat{t}_p(x_0) = e^{\hat{\beta}_0 + \hat{\beta}_1 \ln x_0} \left(\frac{p}{1-p}\right)^{\hat{\sigma}}.$$

2.11 PAVYZDYS

Jeigu T_{x_0} turi lognormalųjį pasiskirstymą ir pasirinkta Eyring parametrizacija, pvz.

$$r(x) = e^{-\beta_0 - \beta_1 \ln x - \beta_2 / x},$$

tuomet

$$G(t) = 1 - \Phi(t), \hat{S}_{x_0}(t) = 1 - \Phi\left(\frac{\ln t - \hat{\beta}_0 - \hat{\beta}_1 \ln x_0 - \hat{\beta}_2 / x_0}{\hat{\sigma}}\right), \hat{t}_p(x_0) = e^{\hat{\beta}_0 + \hat{\beta}_1 \ln x_0 + \hat{\beta}_2 / x_0 + \hat{\sigma} \Phi^{-1}(p)}.$$

2.12 PAVYZDYS

Tegul gedimo laikas T_{x_0} turi Veibulo pasiskirstymą ir apkrova $x = (x_1, x_2)^T$ yra dvimatė (pavyzdžiui, įtampa ir temperatūra), bei pasirinkta parametrizacija (2.19),

tuomet

$$\hat{S}_{x_0}(t) = \exp\left\{-\exp\left[\frac{\ln t - \hat{\beta}_0 - \hat{\beta}_1 \ln x_{10} - \hat{\beta}_2 / x_{20}}{\hat{\sigma}}\right]\right\}, \hat{t}_p(x_0) = e^{\hat{\beta}_0 + \hat{\beta}_1 \ln x_{10} + \hat{\beta}_2 / x_{20}} \{-\ln(1-p)\}^{\hat{\sigma}}.$$

3 TIRIAMOJI DALIS

3.1 Duomenys

Duomenys, naudojami skaičiavimams atlikti, yra prancūzų kompanijos „Stryker Spine“ eksperimentinių bandymų su implantais rezultatai. Mus domina implantų, naudojamų juosmens ankilozės metu, darbo laikas T , kuomet juos cikliškai veikia apkrovos, apibrėžtos minimalia ir maksimalia reikšme, išreikšta Niutonais. Gyvenimo trukmė yra išreikšta ciklų skaičiumi iki implanto gedimo. Galimi trys apkrovos tipai: 28-280N, 30-300N, 35-350N. Žinoma, kad maksimali apkrova yra visada dešimt kart didesnė nei minimali. Susitarkime žymėti mažiausią apkrovos reikšmę x . Buvo surinkti daugelio eksperimentų su įvairiais implantų tipais (Diapason ir Xia) duomenys. Eksperimento metu konkretaus tipo implantas dirba, veikiamas pasirinkta apkrova, ir stebima jo gyvenimo trukmė (arba cenzūravimo momentas, jei implantas nesugedo eksperimento metu). Pagrindinis tikslas yra įvertinti x_{cr} – kritinę apkrovos reikšmę, kuriai su duota tikimybe γ galima garantuoti darbą be tam tikro tipo implantų gedimų 5 milijonus ciklų.

Duomenys pateikiami 3.1 lentelėje ir yra suskirstyti pagal apkrovos tipus. Be to, yra nurodytas jų darbo laikas, išreikštas ciklų iki implanto sugedimo skaičiumi.

3.1LENTELĖ

Apkrovos grupė	Ciklų skaičius	Apkrovos dydis
1	69952	28
1	80204	28
1	72322	28
1	54940	28
1	163868	28
1	52351	28
1	44586	28
1	96290	28
1	49984	28
1	194560	28
2	59851	30
2	24245	30
2	35742	30
2	29827	30
2	26944	30
2	56671	30
2	23237	30
2	34568	30
2	37800	30
2	27118	30
2	27784	30

2	47184	30
2	37681	30
2	26489	30
2	23975	30
2	23253	30
2	44875	30
3	12506	35
3	9070	35
3	21410	35
3	14887	35
3	9193	35
3	15168	35
3	14165	35
3	14836	35
3	11195	35
3	11093	35

3.2 Teorijos taikymas

3.2.1 Naudotas statistinis modelis. Tikėtinumo funkcija

Kritinė apkrovos reikšmė x_{cr} tenkina lygtį

$$G_{x_{cr}}(t_g) = P\{T > t_g | x_{cr}\} = \gamma, \quad (3.1)$$

kur $\gamma = 0,95$.

Naudosime tokį modelį:

patikimumo funkcija $G_x(t)$ yra tokio pavidalo

$$G_x(t) = \exp\{- (e^{-\beta_0 - \beta_1 \ln x} t)^\delta \}, \quad (3.2)$$

t.y. imame Veibulo skirstinių šeimą ir laipsninių modelį.

Eksperimento duomenys yra tokio pavidalo:

turime k -gaminių grupių; i -jai grupei maksimali eksperimento trukmė yra t_i (i -je grupėje yra n_i -gaminių), o apkrova – x_i .

Užrašome $G_x(t)$ tokiu pavidalu:

$$\begin{aligned} G_x(t) &= e^{-(e^{-\beta_0 - \beta_1 \ln x} t)^\delta} = e^{-e^{\delta \ln(e^{-\beta_0 - \beta_1 \ln x} t)}} = e^{-e^{\delta(-\beta_0 - \beta_1 \ln x + \ln t)}} = \\ &= G(\delta(-\beta_0 - \beta_1 \ln x + \ln t)) = G\left(\frac{\ln t - \beta_0 - \beta_1 \ln x}{b}\right), \end{aligned}$$

kur

$$G_x(t) = e^{-e^t}, \quad b = 1/\delta.$$

Pažymėkime $\theta = (\beta_0, \beta_1, b)$ tikėtinumo funkciją

$$L(\theta) = \prod_{i=1}^k \prod_{j=1}^{n_i} \lambda_i^{\delta_{ij}}(X_{ij}; \theta) G_i(X_{ij}; \theta);$$

čia

$$X_{ij} = \min\{T_{ij}, t_i\}, \delta_i = \mathbf{1}\{T_{ij} \leq t_i\} = \begin{cases} 1, & \text{jei } T_{ij} \leq t_i; \\ 0, & \text{jei } T_{ij} > t_i; \end{cases}$$

$$\lambda_i(t; \theta) = -\frac{G'_i(t; \theta)}{G_i(t; \theta)}, G_i = G_{x_i}.$$

Turėsime

$$G'_x(t) = G' \left(\frac{\ln t - \beta_0 - \beta_1 \ln x}{b} \right) \frac{1}{bt};$$

$$\lambda_x(t) = -\frac{G' \left(\frac{\ln t - \beta_0 - \beta_1 \ln x}{b} \right)}{G \left(\frac{\ln t - \beta_0 - \beta_1 \ln x}{b} \right)} \frac{1}{bt} = h \left(\frac{\ln t - \beta_0 - \beta_1 \ln x}{b} \right),$$

kur

$$h(u) = -\frac{G'(u)}{G(u)},$$

o Veibulo dėsniai

$$-G'(u) = e^u e^{-e^u}, h(u) = e^u.$$

Vadinasi,

$$L(\beta_0, \beta_1, b) = \prod_{i=1}^k \prod_{j=1}^{n_i} e^{\delta_{ij} \left(\frac{\ln X_{ij} - \beta_0 - \beta_1 \ln x_i}{b} \right)} e^{-e^{\frac{\ln X_{ij} - \beta_0 - \beta_1 \ln x_i}{b}}} \left(\frac{1}{b X_{ij}} \right)^{\delta_{ij}},$$

ir, logaritmavus, gauname

$$\ln L(\beta_0, \beta_1, b) = \sum_{i=1}^k \sum_{j=1}^{n_i} \delta_{ij} \left(\frac{\ln X_{ij} - \beta_0 - \beta_1 \ln x_i}{b} \right) -$$

$$- \sum_{i=1}^k \sum_{j=1}^{n_i} e^{\frac{\ln X_{ij} - \beta_0 - \beta_1 \ln x_i}{b}} - \sum_{i=1}^k \sum_{j=1}^{n_i} \delta_{ij} \ln b + \text{const} \quad (3.3)$$

3.2.2 Kritinės apkrovos reikšmės įvertis

Mums reikia įvertinti kritinę apkrovos reikšmę x_{cr} . Prie šios apkrovos implantas funkcionuoja be gedimų ne mažiau kaip penkis milijonus ciklų su didele tikimybe $\gamma = 0,95$.

Iš (3.2) išplaukia, kad apkrovos reikšmė x_{cr} apskaičiuojama pagal formulę

$$x_{cr} = \exp \left\{ -\frac{b \ln(-\ln \gamma) - \ln t_g + \beta_0}{\beta_1} \right\}, \quad (3.4)$$

čia $\gamma = 0,95$ ir $t_g = 5000000$.

O jos įvertis yra

$$\hat{x}_{cr} = \exp\left\{-\frac{\hat{b} \ln(-\ln \gamma) - \ln t_g + \hat{\beta}_0}{\hat{\beta}_1}\right\}. \quad (3.5)$$

Kad gauti b , β_0 , β_1 įverčius $\hat{\beta}_0, \hat{\beta}_1, \hat{b}$, reikia maksimizuoti pagal β_0, β_1, b funkciją (žr. (3.3))

$$g(\beta_0, \beta_1, b) = \sum_{i=1}^k \sum_{j=1}^{n_i} \delta_{ij} \frac{\ln X_{ij} - \beta_0 - \beta_1 \ln x_i}{b} - \sum_{i=1}^k \sum_{j=1}^{n_i} e^{\frac{\ln X_{ij} - \beta_0 - \beta_1 \ln x_i}{b}} - \sum_{i=1}^k \sum_{j=1}^{n_i} \delta_{ij} \ln b. \quad (3.6)$$

3.3 Praktiniai skaičiavimai

3.3.1 Užduoties apibendrinimas

Turime duomenis, pateiktus lentelėje 3.1, kur yra trys apkrovos tipai: $x_1 = 28$, $x_2 = 30$ ir $x_3 = 35$. Taip pat žinome, kad $\gamma = 0.95$, o $t_g = 5000000$.

Taigi mums reikia įvertinti kritinę apkrovos reikšmę x_{cr} , o tiksliau apskaičiuoti jos įvertį \hat{x}_{cr} , kuris su tikimybe $\gamma = 0,95$ garantuoja implanto funkcionavimą be gedimų penkis milijonus ciklų. Tam tikslui pasiekti naudosime formulę (3.5). Bet prieš tai mums reikės gauti β_0, β_1, b įverčius $\hat{\beta}_0, \hat{\beta}_1, \hat{b}$, maksimizuojant funkciją (3.6). Gavus šiuos įverčius, galėsime apskaičiuoti mus dominančios kritinės apkrovos reikšmę.

3.3.2 Programinė realizacija

Visiems skaičiavimams atlikti buvo naudojama SAS programinė įranga. Lentelėje 3.2 pateikiama programa, kurios pagalba buvo gauti ne tik reikalingi įverčiai, bet ir, kaip pagalbinė medžiaga, grafikai. Reikia pastebėti, kad pradinio artinio paėmėme: $b = 1; \beta_0 = 97.1527; \beta_1 = -25.7676$. Šis artinys išplaukia iš to, kad

$$g(\beta_0, \beta_1, b) = \sum_{i=1}^n \frac{\ln T_i - \beta_0 - \beta_1 \ln x_i}{b} - \sum_{i=1}^n e^{\frac{\ln T_i - \beta_0 - \beta_1 \ln x_i}{b}},$$

kur

$$\beta_0 > 0, \beta_1 < 0, b > 0.$$

Mes turime, kad

$$x_{cr} = \exp\left\{-\frac{b \ln(-\ln 0.95) - \ln(5 \cdot 10^6) + \beta_0}{\beta_1}\right\} = \exp\left\{-\frac{b \ln(-\ln 0.95) - \ln 5 - 6 \ln 10 + \beta_0}{\beta_1}\right\}$$

Tegul $b = 1$. Iš bandymų rezultatų matome, kad prie apkrovos lygios 28 vidutinė gyvenimo trukmė yra lygi 80000 ciklų, o prie 30 ir 35 – 45000 ir 18000 atitinkamai.

$$T \sim e^{-(t/\theta)^\delta}, \quad ET = \theta \Gamma\left(1 + \frac{1}{\delta}\right).$$

Prie $x = 28$ turime, kad

$$\theta_{28} = e^{\beta_0 + \beta_1 \ln 28} \text{ ir } e^{\beta_0 + \beta_1 \ln 28} \Gamma(1 + b) \approx 80000;$$

prie $x = 30$ turime, kad

$$\theta_{30} = e^{\beta_0 + \beta_1 \ln 30} \text{ ir } e^{\beta_0 + \beta_1 \ln 30} \Gamma(1+b) \approx 45000;$$

prie $x = 35$ turime, kad

$$\theta_{35} = e^{\beta_0 + \beta_1 \ln 35} \text{ ir } e^{\beta_0 + \beta_1 \ln 35} \Gamma(1+b) \approx 18000.$$

Taigi

$$\frac{ET_{28}}{ET_{30}} = \frac{\theta_{28}}{\theta_{30}} \approx e^{\beta_1 (\ln 28 - \ln 30)} \Rightarrow \beta_1 (\ln 28 - \ln 30) \approx \frac{80000}{45000} \Rightarrow \beta_1 \approx \frac{16}{9} \cdot \frac{1}{\ln 28 - \ln 30} = -25.7676$$

$$e^{\beta_0} = \frac{80000}{e^{\beta_1 \ln 28} \Gamma(1+b)} \Rightarrow \beta_0 = \ln 80000 - \beta_1 \ln 28 - \underbrace{\ln \Gamma(2)}_0 \Rightarrow \beta_0 = \ln 80000 - \beta_1 \ln 28 = 97.1527$$

3.2 LENTELE

```

Data duomenys;
input gr T_ij t_i apkrova;
X_ij = min (T_ij, t_i);
If T_ij <= t_i then Delta_ij=1;
else Delta_ij=0;
cards;
1 69952 100000 28
1 80204 100000 28
1 72322 100000 28
1 54940 100000 28
1 163868 100000 28
1 52351 100000 28
1 44586 100000 28
1 96290 100000 28
1 49984 100000 28
1 194560 100000 28
2 59851 100000 30
2 24245 100000 30
2 35742 100000 30
2 29827 100000 30
2 26944 100000 30
2 56671 100000 30
2 23237 100000 30
2 34568 100000 30
2 37800 100000 30
2 27118 100000 30
2 27784 100000 30
2 47184 100000 30
2 37681 100000 30
2 26489 100000 30
2 23975 100000 30
2 23253 100000 30
2 44875 100000 30
3 12506 100000 35
3 9070 100000 35
3 21410 100000 35
3 14887 100000 35
3 9193 100000 35

```

3	15168	100000	35
3	14165	100000	35
3	14836	100000	35
3	11195	100000	35
3	11093	100000	35

```

;
run;

ods rtf body = 'NLP.rtf';
title 'Maksimizavimo rezultatas';
PROC NLP DATA=duomenys;
  MAX lnL;
  PARMS Beta0 = 97.1527, Beta1 = -25.7676, b = 1;
  BOUNDS Beta0 > 0, Beta1 < 0, b > 0;
  lnL = Delta_ij*(log(X_ij)-Beta0-Beta1*log(apkrova))/b -
        exp((log(X_ij)-Beta0-Beta1*log(apkrova))/b)-
        Delta_ij*log(b)
;
run;
%let Beta0 = 36.412;
%let Beta1 = -7.562888;
%let b = 0.306276;
%let xcr = 14.2;
data Graf1;
  do t = 0 to 150000 by 500;
    G = exp(-(exp(-&Beta0-&Beta1*log(28))*t)**(1/&b));
    G2 = exp(-(exp(-&Beta0-&Beta1*log(30))*t)**(1/&b));
    G3 = exp(-(exp(-&Beta0-&Beta1*log(35))*t)**(1/&b));
  output;
end;
goptions reset = (axis, legend, pattern, symbol, title, footnote)
interpol = join;
symbol1 height = 1 cv = red value = none;
symbol2 height = 1 cv = green value = none;
symbol3 height = 1 cv = gold value = none;
proc gplot data = Graf1;
plot (G G2 G3)*t / overlay Frame;
run;
quit;
data Graf2;
  do t = 0 to 1000000 by 1000;
    Gcr = exp(-(exp(-&Beta0-&Beta1*log(&xcr))*t)**(1/&b));
  output;
end;
goptions reset = (axis, legend, pattern, symbol, title, footnote)
interpol = join;
symbol1 height = 1 cv = cyan value = none;
proc gplot data = Graf2;
plot (Gcr)*t / overlay Frame;
run;
quit;
ods rtf close;

```

3.3.3 Rezultatai

Gavome tokius nežinomų parametru įverčius (žr. 1 priedą, 1.1 pav.):

$$\hat{b} = 0.306276; \hat{\beta}_0 = 36.412001; \hat{\beta}_1 = -7.563888.$$

Atitinkamai, įstačius juos į formulę (3.5), apskaičiuojame \hat{x}_{cr} :

$$\hat{x}_{cr} = \exp\left\{-\frac{0.306276 \ln(-\ln 0.95) - \ln(5 \cdot 10^6) + 36.412001}{-7.563888}\right\} = 14.2. \quad (3.7)$$

Taigi implanto kritinės apkrovos x_{cr} įvertis, kuris su tikimybe $\gamma = 0,95$ garantuoja funkcionavimą be gedimų penkis milijonus ciklų, yra lygus 14,2 (bus apytiksliai 14.2-142N apkrova).

Piešinyje 2.1 pavaizduotos patikimumo funkcijos $G_x(t)$ prie skirtingų apkrovos x reikšmių (kai $x = 28$, $x = 30$ ir $x = 35$) kreivės. Reikia pastebėti, kad mažėjant apkrovai implanto gyvenimo trukmė ilgėja. Taip pavyzdžiui prie apkrovos $x = 35$ pusė visų gaminių suges apytiksliai po 12000 – 14000 ciklų, kai veiks $x = 30$ apkrova tokios pat implantų dalies gedimą stebėsime tik po 40000, o stebint funkciją $G_x(t)$ apkrovai $x = 28$, stebime pailgėjusią iki 66000 – 68000 ciklų pusės visų implantų gyvenimo trukmę.

Piešinyje 2.2 pavaizduota patikimumo funkcijos $G_x(t)$ kreivė, veikiant apskaičiuotai kritinei apkrovai $x = 14.2$. Matome, kad netgi po penkių milijonų ciklų 95% visų implantų vis dar veiktų be gedimų, o po dešimties milijonų ciklų – apie 60% visų gaminių.

IŠVADOS

Pasiūlytas Pagreitintųjų gedimų parametrinis modelis yra pavyzdys, kuris, panaudojus programinės įrangos SAS priemones, leidžia įvertinti implanto kritinės apkrovos x_{cr} reikšmę, kuriai su duota tikimybe γ galima garantuoti darbą be tam tikro tipo gedimų nustatytą ciklų skaičių. Pagrindinis sunkumas buvo tame, kad atliktų bandymų duomenų buvo mažai, o pastarųjų dispersijos buvo akivaizdžiai didelės. Taip pat truko rezultatų bandymų, atliktų su mažesnėmis apkrovomis (artimesnėmis ieškomai kritinei reikšmei). Taigi, norint gauti labiau patikimą x_{cr} įvertį, reikėtų atlikti pakartotinius skaičiavimus su išplėstu duomenų rinkiniu.

Situacija, išnagrinėta šiame darbe, yra vienas iš daugelio galimų Pagreitintųjų gedimų parametrinio modelio taikymo atvejų pavyzdžių. Įvairiose kompanijose, užsiimančiose pavyzdžiui produkcijos gamyba, dažnai iškyla klausimas, kaip per trumpiausią laiką galima išskaičiuoti optimalius gaminio parametrus, kad kuo greičiau pradėti jo gamybą. Štai tokiais atvejais, kuomet yra įmanoma atlikti bandymus prie padidintų apkrovų, (jos duoda funkcionavimo trukmę trumpesnę nei prie nežinomos apkrovos x_{cr}), šio modelio taikymas yra ypač naudingas. O taip pat tuomet, kai kiekvieno konkretaus tipo vienetų skaičius yra santykinai mažas (mūsų atveju, skirtingų pritaikytų apkrovų reikšmių skaičius neviršija trijų).

Ateityje, mūsų nagrinėtiems duomenims, galima būtų įvertinti išgyvenamumą ne tik kaip apkrovos funkciją bet ir kaip implanto tipo funkciją. Šiuo atveju, mes turėtume apjungti visus duomenis, kurie atitinka kelis implantų tipus, ir įvertinti regresijos parametrus. Įvertinta išgyvenamumo funkcija priklausytų nuo apkrovos ir nuo visų kovariančių. Ją galima būtų naudoti kritiniai disponuojamų implantų apkrovai įvertinti, be to ji leistų puikiai prognozuoti įvairių implantų išgyvenamumą, keičiant kovariančių, aprašančių naujus implantus, reikšmes.

Įvairių gedimų priežastys yra dar viena svarbi problema, kurią taip pat galima būtų bandyti išspręsti. Kadangi kiekvienas implantas potencialiai turi kelias gedimo priežastis, kurias ir reikėtų stebėti karu su gyvenimo trukme. Mes žinome, kad egzistuoja modeliai, naudojančys visumą duomenų, kurie gali įvertinti išgyvenamumo funkciją kiekvienai priežasčiai. Todėl prognozės tokiu būdu turi būti daromos apibendrintai arba atskirai gedimo priežasčiai. Kovariančių poveikis taip pat gali būti analizuojamas giliau.

LITERATŪROS SĄRAŠAS

Bagdonavičius, V. and Nikulin, M. (2002) *Accelerated Life Models. Modelling and Statistical Analysis*.

Mann, N.R., Schafer, R.E. and Singpurwalla, N.D. (1974) *Methods for Statistical Analysis of Reliability and Life Data*. New York: John Wiley and Sons.

Nelson, W. and Macarthur, E. (1992) *Accelerated Testing: Statistical models, test plans, and data analysis*.

Lawless, J.F. (2004) *Statistical Models and Methods for Lifetime Data*. New York: John Wiley and Sons.

Singpurwalla, N.D. (1971) *Inference from Accelerated Life Test When Observations are Obtained from Censored Samples*, Technometrics.

Thernau, T.M. and Grambsch, P.M. (2000) *Modeling Survival Data. Extending the Cox Model*. New York: Springer.

Viertl, R. (1988) *Statistical Methods in Accelerated Life Testing*. Göttingen: Vandenhoeck and Ruprecht.

PRIEDAI

1 Priedas. SAS programos išdava

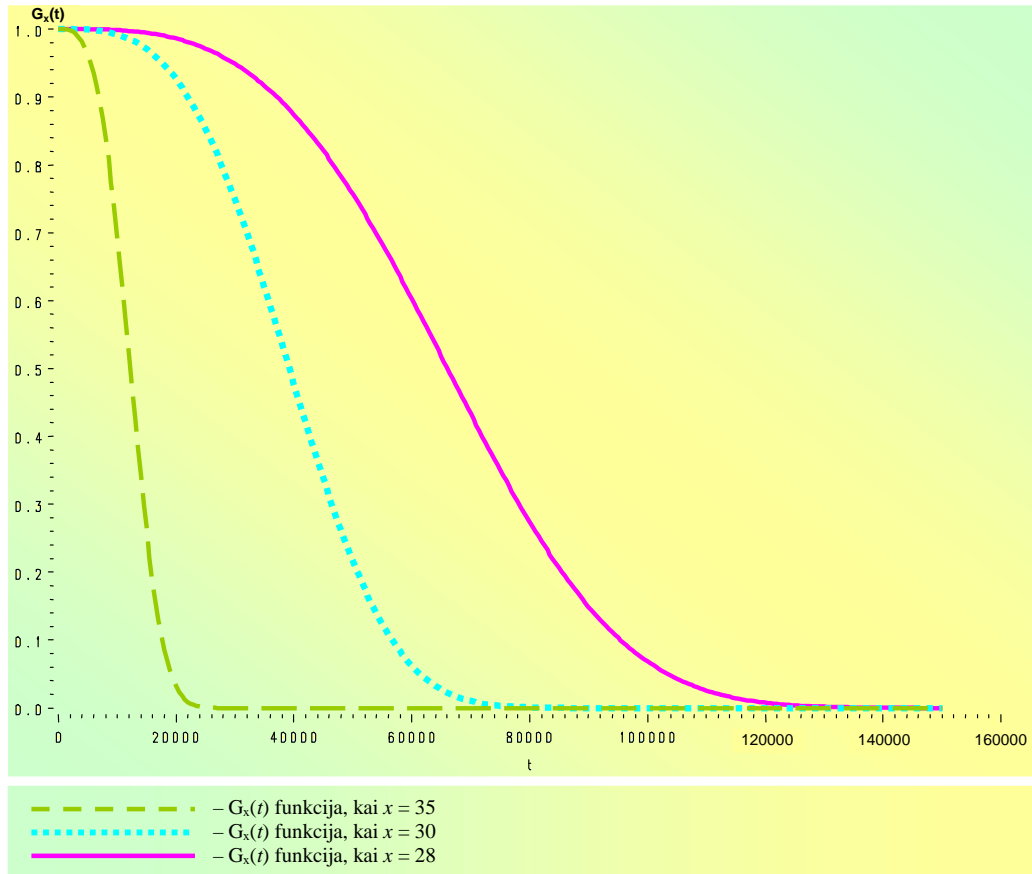
Optimization Start					
Parameter Estimates					
N	Parameter	Estimate	Gradient Objective Function	Lower Bound Constraint	Upper Bound Constraint
1	Beta0	97.150000	548.260735	0	.
2	Beta1	-25.770000	1944.863648	.	0
3	b	1.000000	2077.901325	0	.

1.1 pav. Pradinis parametru β_0, β_1, b artinys

Optimization Results			
Parameter Estimates			
N	Parameter	Estimate	Gradient Objective Function
1	Beta0	36.412001	6.3754224E-9
2	Beta1	-7.562888	2.1615787E-8
3	b	0.306276	1.7657014E-8

1.2 pav. Gauti parametru β_0, β_1, b įverčiai

2 Priedas. Patikimumo funkcijos $G_x(t)$ grafikai



2.1 pav. Patikimumo funkcijos $G_x(t)$ veikiant skirtingoms apkrovoms kreivės

2 Priedas (tęsinys). Patikimumo funkcijos $G_x(t)$ grafikai



2.2 pav. Patikimumo funkcijos $G_x(t)$ veikiant $x_{cr} = 14.2$ apkrovai kreivė