

Univerza v Ljubljani
Fakulteta za elektrotehniko

Ognjen Živić

Napovedovanje življenjske dobe varistorja

Magistrsko delo

Mentor: prof. dr. Gregor Dolinar

Ljubljana, 2015

Zahvala

Zahvaljujem se mentorju prof. dr. Gregorju Dolinarju za vsa priporočila in popravke vezana na magistrsko delo, Andjeli Živić za podeljen projekt, ki sem ga lahko uporabil za temo tega dela, mojemu sinu Roku za vse prespane noči v času študija, ter vsem ostalim družinskim članom za podporo.

Vsebina

Slike	vii
Tabele	ix
1 Uvod	5
2 Teoretični del	7
2.1 Varistor	7
2.2 Zanesljivost	7
2.3 Pospešeno testiranje	8
2.4 Uporaba Arrheniousove enačbe	10
2.5 Linearna regresija	11
2.6 Posplošeni linearni modeli	12
2.7 Analiza preživetja	13
2.7.1 Parametrični modeli	14
2.7.2 Coxov model	16
3 Praktični del	17
3.1 Potek poskusa	17
3.2 Podatki	18

3.3	MTTF pri 85 °C	19
3.3.1	Prilagoditev eksponentnega modela	19
3.3.2	Prilagoditev Weibullovega modela	25
3.4	Povezanost med začetnimi električnimi parametri in časom do odpovedi	29
4	Sklep	41
A	Rezultati meritev pospešenega testiranja	45
B	Rezultati modelov	49
C	Uporabljene funkcije v R	55
D	Literatura	63

Slike

3.1	Prileganje eksponentnega modela krivuljam preživetja ocenjenih s pomočjo metode KM.	24
3.2	Prileganje Weibullovega modela ocenam KM metode.	27
3.3	Povezanost osnovnih električnih parametrov.	30
3.4	Odvisnost $\log(I_{dc})$ od V_n	31
3.5	Porazdelitev ostankov modela <code>Idc.lm1</code>	32
3.6	Porazdelitev ostankov modela <code>Idc.lm2</code>	34
3.7	Prileganje modela <code>Idc.glm1</code> podatkom.	36
3.8	Povezanost toka puščanja z logaritmom relativnega tveganja . . .	39

Tabele

1	Veličine, oznake in simboli	xi
2.1	Splošni zapis podatkov za analizo preživetja.	14
3.1	Primer zapisa podatkov iz poskusa.	19
3.2	Ocenjeni koeficienti eksponentnega modela	20
3.3	Kratek izpis funkcije <code>survfit</code>	23
3.4	Ocenjeni koeficienti Weibullovega modela	25
3.5	Ocenjeni MTTF skupaj z intervali zaupanja pri stopnji zaupanja $\alpha = 0.05$. Ocene so podane v letih.	29
3.6	Testi za preverjanje modela <code>cox.f</code>	30
3.7	Ocene linearnega modela <code>Idc.lm1</code> ter posplošenega linearnega mo- dela <code>Idc.glm1</code>	35
3.8	Poenostavljena Coxova modela proporcionalnih tveganj <code>cox1</code> in <code>cox2</code>	37
3.9	Test Schoenfeldovih ostankov	37
3.10	Waldov test za preverjanje linearnega in nelinearnega dela modela <code>fit.cph</code>	38
A.1	Izmerjeni podatki.	45

Seznam uporabljenih simbolov

V pričujočem zaključnem delu so uporabljeni naslednje veličine in simboli:

Tabela 1: Veličine, oznake in simboli

Pomen simbolov	
E_a	aktivacijska energija v [eV]
β	regresijski koeficient
x_k	vektor vrednosti s k enotami
i	zaporedna številka enote
t	vektor časa
T	čas kot spremenljivka
d	binarna spremenljivka, ki označuje status krnjenja
n	število enot
$R(t)$	verjetnost preživetja ob času t
$h(t)$	tveganje ob času t
g	parameter oblike za Weibullovo porazdelitev
U	napetost
I	tok

Vektorji in matrike so napisani s poudarjeno pisavo. Natančnejši pomen simbolov in njihovih indeksov je razviden z ustreznih slik ali pa je pojasnjen v spremljajočem besedilu, kjer je simbol uporabljen.

Povzetek

V tem magistrskem delu je predstavljen eden izmed načinov določanja življenjske dobe varistorja pri normalnih delovnih pogojih. Pri nekaterih napravah in komponentah je nemogoče testirati življenjsko dobo pri normalnih obratovalnih pogojih, ker bi samo testiranje trajalo predolgo (na primer več kot 1 leto). Ta problem nastopi tudi pri testiranju varistorja.

Za rešitev tega problema lahko na primer uporabimo tako imenovano pospešeno testiranje. Varistor lahko odpove na več načinov. Zato se lahko tudi testiranje v tem primeru izvaja na več načinov. Sredstva, ki so bila na voljo, so omogočala testiranje v komori pri povišani temperaturi pri delovni napetosti varistorja. Spremljani so bili časi do odpovedi varistorja pri različnih temperaturah. Za izračun življenjske dobe varistorja pri povišanih temperaturah so bili uporabljeni modeli za analizo preživetja.

Iz rezultatov pri povišanih temperaturah je dobljena ocena koeficienta aktivacijske energije, ki je nato uporabljena za ekstrapolacijo življenjske dobe varistorja pri 85 °C. Ob tem je predpostavljeno, da je koeficient aktivacijske energije konstanten za dano keramiko.

Preverjali smo tudi povezanost med začetnimi električnimi parametri in časi do odpovedi.

Ključne besede: varistor, pospešeno testiranje, aktivacijska energija

Abstract

This thesis addresses one of the possible ways of calculating lifetime of a varistor at normal operating conditions. For some of the devices or components life test at normal operating conditions would take too much time (e.g. more than one year). This problem also arises with life test for a varistor.

To solve this problem, we can use accelerated testing. There are several different reasons for a failure of a varistor, therefore accelerated tests are also done in different ways. The available equipment allowed us to make accelerated testing in climatic chamber under operating voltage load. Varistor failure times were recorded at different temperature exposures. Later survival analysis models were used to determine lifetime of a varistor under increased temperature.

From results provided by survival analysis, activation energy was calculated, and then using extrapolation it was possible to estimate lifetime of a varistor at 85 °C. It was assumed that activation energy coefficient is constant for the given ceramic.

After mean time to failure was estimated it was tested whether starting varistor characteristics are related to varistor failure times or not.

Key words: varistor, accelerated testing, activation energy

1 Uvod

V podjetju je bila zastavljena zahteva določiti življenjsko dobo za elektronsko komponento, ki je pomemben proizvod podjetja. Namen naloge je dobiti oceno srednjega časa do odpovedi za delovanje varistorja pri 85 °C ter ugotoviti, kako na to vplivajo začetni električni parametri.

Za določitev življenjske dobe sta bila pospešeno testirana dva vzorca varistorjev pri dveh različnih temperaturah. Pred samim testiranjem je bilo definirano, kaj pomeni odpoved varistorja oziroma, kdaj je varistor neustrezen za nadaljnjo uporabo.

Med testiranjem je bil spremljan čas do odpovedi za vsak posamezen varistor. Poleg časa do odpovedi so bili za vsak varistor izmerjeni tudi osnovni električni parametri (nazivna napetost V_n , koeficient nelinearnosti α ter tok puščanja I_{dc}). Za te parametre je bila na koncu tudi preverjena povezanost s časi do odpovedi. Ocenjene vrednosti časov do odpovedi pri pospešenem testiranju so bile nato uporabljene za izračun aktivacijske energije E_a . S tem podatkom je bila nato ocenjena frekvenca odpovedi pri temperaturi 85 °C. Za obdelavo podatkov in statistično analizo je bilo uporabljeno programsko okolje R.

2 Teoretični del

2.1 Varistor

Polprevodniki imajo nekatere slabosti, ena izmed teh je občutljivost na prenapetostna nihanja. Že zelo majhna energijska nihanja lahko povzročijo motnje in škodo z zelo hudimi posledicami. Omejitev prehodnih pojavov in prenapetostnih nihanj je tako postal ključni dejavnik pri načrtovanju elektronskih naprav. Varistorji [1] so se izkazali kot odlična zaščitna komponenta zaradi njihove zmožnosti vgraditve v širok spekter aplikacij in zaradi njihove zanesljivosti. Glede na razmerje cena / zmogljivost je to ena bolj primernih komponent za omejitev impulznih tokovnih in napetostnih obremenitev ter za absorpcijo energije.

Varistor je napetostno odvisen upor s simetrično $U - I$ karakteristiko. Običajno ga priklopimo vzporedno z elektronskim vezjem, ki ga želimo zaščititi. Z večanjem inducirane napetosti se upornost varistorja zmanjšuje. Zaradi tega ob prehodnih pojavih (napetostne špice) upornost pade in tako ves tok preusmeri nase. Na ta način je vezje zaščiteno tudi, če se varistor ob tem uniči.

2.2 Zanesljivost

Funkcija zanesljivosti (2.1) oziroma funkcija preživetja $R(t)$ (ang. reliability ali survival function) je definirana kot verjetnost, da bo predmet deloval brezhibno pod delovnimi pogoji od časa 0 do časa t . V literaturi se uporablja tudi oznaka $S(t)$ (pogosto v medicini).

$$R(t) = 1 - F(t), \quad (2.1)$$

kjer je $F(t)$ verjetnost odpovedi. Gostota verjetnosti odpovedi $f(t)$ pa je definirana kot odvod verjetnosti odpovedi:

$$f(t) = \frac{dF(t)}{dt}. \quad (2.2)$$

Srednji življenjski čas $MTTF$ je definiran kot integral funkcije zanesljivosti po času (angleško mean time to failure):

$$MTTF = \int_0^{\infty} R(t)dt. \quad (2.3)$$

Pogostost odpovedi λ je eden najpogostejših parametrov vrednotenja zanesljivosti. Če je $R(t)$ eksponentno porazdeljena, je povezava med λ in $MTTF$ je sledeča:

$$MTTF = \frac{1}{\lambda}. \quad (2.4)$$

Več o zanesljivosti je na primer v [2].

2.3 Pospešeno testiranje

Za nekatere komponente bi bil čas testiranja pri normalnih delovnih pogojih lahko tudi zelo dolg. Takšna testiranja bi bila nepraktična in cenovno neugodna. Za rešitev tega problema se uporabljajo različni pristopi.

Prva možnost je povečanje števila proizvodov v testnem vzorcu, ki pa ne smejo v predvidenem obdobju testiranja doseči obdobja iztrošenosti. Takšna rešitev je primerna za majhne cenene predmete (npr. elektronske komponente).

Druga možnost je pospešeno testiranje (povzeto po [2]), ki je neizogibno za malo številčne zelo zanesljive komponente in sisteme. Pospešeno testiranje uvaža

težje delovne pogoje. Ob tem je potrebno poiskati odgovor na dve ključni vprašanji:

- Ali so odpovedi, do katerih je prišlo med pospešenim testiranjem, enake odpovedim pri normalnih delovnih pogojih?
- Kolikšen je ekvivalentni čas delovanja pri normalnih delovnih pogojih?

Mnogo elektronskih komponent, še posebej varistorji, je občutljivih na temperaturo. Temperatura povzroči proces kemične degradacije. Če se uporabi višja temperatura, se proces degradacije pohitri. Z uporabo Arrheniusove (povzeto po [2]) enačbe, se lahko podatki uporabijo za oblikovanje ustreznega modela, s pomočjo katerega se nato določi $MTTF$ za želeno temperaturo. Za to morata biti izpolnjena dva pogoja:

1. Največji stres za komponento mora biti temperatura.
2. Pričakovana življenjska doba je logaritemsko povezana z obratno vrednostjo temperature.

Spodaj je opisana metoda (povzeto po [3]), ki se jo uporablja za testiranje varistorjev z namenom določanja $MTTF$ pri normalnih delovnih pogojih:

1. Izbere se od 60 do 120 varistorjev iz istega lota¹.
2. Izmeri se nazivna napetost V_n pri toku 1 mA in tok puščanja I_{dc} pri delovni napetosti V_{dc}
3. Vzorec se razdeli na več enakih delov. Vsak del vzorca se vstavi v komoro pri drugačni temperaturi (npr. 140 °C, 150 °C).
4. Ko so vzorci v komori, se jih priključi na delovno napetost.

¹Iz ene serije se naredi več lotov.

5. V določenih časovnih intervalih se varistorje umakne iz komore. Izmerijo se osnovne karakteristike (nazivna napetost V_n , tok puščanja I_{dc}).
6. Če so izmerjene osnovne karakteristike varistorja takšne, da ustrezajo definiciji odpovedi, se varistor umakne s testiranja. Zabeleži se, koliko ur je bil umaknjeni varistor v komori.
7. S testiranjem preostalih varistorjev se nadaljuje, dokler vsi varistorji ne dosežejo definicije odpovedi ali pa dokler se ne doseže maksimalni čas, ki je na voljo za testiranje.

Več o pospešenem testiranju in možnih metodah je mogoče prebrati npr. v [4], [2] ter [3].

2.4 Uporaba Arrheniousove enačbe

Glavno vlogo pri izračunu življenjske dobe (ŽD) varistorjev pri normalnih delovnih pogojih ima aktivacijska energija E_a . To je najmanjša količina energije, ki je potrebna, da steče kemijska reakcija, ki povzroči odpoved varistorja. Arrheniousova enačba povezuje aktivacijsko energijo in hitrost kemijske reakcije. Več o aktivacijski energiji je v virih [2] in [5].

Aktivacijsko energijo E_a bomo izračunali s pomočjo naslednje enačbe

$$\nu = \nu_0 e^{\frac{E_a}{kT}}, \quad (2.5)$$

kjer je E_a aktivacijska energija, ν je frekvenca dogodkov, k je Boltzmannova konstanta izražena v eV/K, ν_0 je pred-eksponentni faktor izražen v s^{-1} , T pa je temperatura v Kelvinih. Pri dveh različnih temperaturah T_1 in T_2 potem dobimo sistem dveh enačb za neznanki E_a in ν_0 , od koder izrazimo E_a .

$$\nu_2 = \nu_0 e^{\frac{E_a}{kT_2}} \quad (2.6)$$

$$\nu_1 = \nu_0 e^{\frac{E_a}{kT_1}} \quad (2.7)$$

V tem primeru je ν_1 frekvenca dogodkov pri temperaturi T_1 , ν_2 pa je frekvenca dogodkov pri temperaturi T_2 .

$$E_a = -k \frac{\log(\nu_2/\nu_1)}{1/T_2 - 1/T_1} \quad (2.8)$$

Dobljena aktivacijska energija se nato vstavi v enačbo (2.6) ali (2.7), od koder se izrazi pred-eksponentni faktor ν_0 , na primer

$$\nu_0 = \frac{\nu_1}{e^{\frac{E_a}{kT_1}}}. \quad (2.9)$$

Ko je določen ν_0 , se v enačbo (2.5) vstavi temperatura, za katero se želi oceniti frekvenco dogodkov ν .

2.5 Linearna regresija

V statistiki se linearna regresija pogosto uporablja za modeliranje zveze med odvisno spremenljivko ter eno ali več neodvisnih spremenljivk. V primeru samo ene neodvisne spremenljivke, se metoda imenuje enostavna linearna regresija. Enačba (2.10) predstavlja najbolj pogost zapis za linearno regresijo.

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \epsilon, \quad (2.10)$$

kjer je y odvisna spremenljivka, ki mora biti intervalna, β_k so koeficienti, ki določajo povezanost med neodvisnimi spremenljivkami in odvisno spremenljivko, x_k pa so vektorji podatkov za vsako neodvisno spremenljivko posebej. Neodvisne spremenljivke so lahko številske ali opisne, ϵ pa je napaka. To je slučajna spremenljivka, ki mora zadoščati določenim pogojem, da je model sprejemljiv.

Predpostavke linearne regresije, ki se nanašajo na slučajno spremenljivko ϵ so:

- napake ϵ_i medseboj niso korelirane,
- normalna porazdelitev $\epsilon_i \sim \mathbb{N}(0, \sigma^2)$,
- konstantna varianca: $\text{Var}(\epsilon_i) = \sigma^2$.

V poglavju 3.4 je uporabljena linearna regresija za poskus modeliranja odvisnosti med osnovnimi električnimi parametri varistorja. V primeru izpolnjenih predpostavk se lahko izračuna standardno napako za vsak parameter, intervale zaupanja, testira domneve o parametrih modela ter izračuna napovedi in intervale zaupanja za povprečno napoved in za posamično napoved (povzeto po [6]).

Več o linearni regresiji in modeliranju se lahko najde npr. v [7], [8] in [9].

2.6 Posplošeni linearni modeli

V praksi predpostavke linearne regresije pogosto niso izpolnjene. Odzivne spremenljivke so redkokdaj porazdeljene normalno, prav tako varianca ni vedno konstantna. Težave je do neke mere možno odpraviti s pomočjo transformacij spremenljivk, s tem pa se pojavijo težave pri interpretaciji rezultatov.

Najbolj pogosta nadgradnja linearnih modelov so posplošeni linearni modeli. Posplošeni linearni model ne predpostavlja normalne porazdelitve ostankov, konstantne variance ter intervalne odzivne spremenljivke. Tri ključne lastnosti posplošenih linearnih modelov so:

- porazdelitev odzivne spremenljivke spada v družino eksponentnih porazdelitev,
- linearni prediktor η za neodvisne spremenljivke x_1, \dots, x_p se zapiše kot:

$$\eta = \beta'x = \beta_0x_0 + \beta_1x_1 + \dots + \beta_px_p, \quad (2.11)$$

kjer je x_0 natanko 1.

- vezna funkcija $g(\mu)$ povezuje linearni prediktor η s povprečjem μ :

$$\eta = g(\mu). \quad (2.12)$$

Prednosti posplošenega linearnega modela je tudi ta, da je odvisna spremenljivka lahko tudi opisna. Naslednja prednost v primerjavi z linearno regresijo je pri predpostavki glede variance. Varianca je v tem primeru funkcija, ki je odvisna od povprečja. V tej nalogi bo uporabljen posplošen linearni model v primeru, da predpostavke linearne regresije ne bodo izpolnjene. Več o posplošenih linearnih modelih je npr. v [6].

2.7 Analiza preživetja

Analizo preživetja (povzeto po [10]) se uporablja takrat, ko je odzivna spremenljivka čas do dogodka. Čas je lahko merjen v različnih enotah. To so lahko npr. leta, meseci, tedni, dnevi, v tem magistrskem delu so to ure. Dogodek pa je lahko odpoved, smrt, sprememba določenih lastnosti, ali katerakoli izkušnja, ki se lahko zgodi opazovancu (predmetu, pojavu, osebi).

Skupni analitični problem pri vseh metodah za analizo preživetja je krnenje. Krnenje se zgodi vsakič, ko imamo neko informacijo o opazovancu, nimamo pa točnega časa dogodka.

Krnenje ponavadi nastopi zaradi treh različnih razlogov:

- opazovanec ne doživi dogodka pred koncem opazovanja, kar bo glavni razlog krnenja v poskusu v tem magistrskem delu,
- opazovanec uide izpod nadzora med opazovanjem,
- opazovanec med opazovanjem doživi nek drugi dogodek, ki ni bil predhodno definiran.

Splošni zapis podatkov za analizo preživetja je predstavljen v tabeli 2.1. Zapis mora vsebovati stolpec, ki definira posameznega opazovanca. V tem magistrskem delu bodo to varistorji. Nato mora vsebovati čas konca opazovanja t , ter status o krnenju d . To so osnovni podatki, ki so potrebni za izris krivulje preživetja. Poleg tega se ponavadi uporabijo še dodatne spremenljivke, ki so predmet raziskave. V tem magistrskem delu bodo to začetni električni parametri in temperatura.

Tabela 2.1: Splošni zapis podatkov za analizo preživetja.

Opazovanec	t	d	X_1	X_2	\cdots	X_p
1	t_1	d_1	X_{11}	X_{12}	\cdots	X_{1p}
2	t_2	d_2	X_{21}	X_{22}	\cdots	X_{2p}
\vdots	\vdots	\vdots	\vdots			\vdots
n	t_n	d_n	X_{n1}	X_{n2}	\cdots	X_{np}

V nadaljevanju sta na kratko opisana dva modela, ki ju bomo uporabili za analizo preživetja, to sta Coxov model sorazmernih tveganj ter parametrični Weibullov model. Dodatne metode, ki bodo uporabljene v praktičnem delu (poglavje 3), bodo obrazložene sproti. Podrobnejši opis za analizo preživetja lahko najdemo npr. v [10]. Način uporabe analize preživetja za vrednotenje zanesljivosti v industriji pa lahko najdemo npr. v [8].

2.7.1 Parametrični modeli

Ena od metod za analizo preživetja so parametrični modeli. Osnovna predpostavka parametričnih modelov je, da časi dogodkov sledijo neki znani porazdelitvi. Najbolj pogoste porazdelitve, ki se uporabljajo za parametrične modele, so: Weibullova, eksponentna, posplošena Gamma porazdelitev.

Če je znana gostota verjetnosti $f(t)$, lahko izrazimo funkcijo preživetja $R(t)$ s pomočjo enačbe (2.13) ter funkcijo tveganja $h(t)$ s pomočjo enačbe (2.14). Funkcija preživetja je določena kot integral porazdelitvene funkcije od časa t do neskončno. Funkcijo tveganja pa se nato izrazi kot kvocient negativnega odvoda

funkcije preživetja $-d[R(t)]/dt$ in funkcijo preživetja $R(t)$.

$$R(t) = P(T > t) = 1 - F(t) = \int_t^{\infty} f(u)du \quad (2.13)$$

$$h(t) = \frac{-R'(t)}{R(t)} \quad (2.14)$$

Funkcijo preživetja $R(t)$ lahko izrazimo tudi s pomočjo funkcije tveganja kot eksponent negativne kumulativne funkcije tveganja:

$$R(t) = \exp\left(-\int_0^t h(u)du\right).$$

Gostoto verjetnosti je možno izraziti kot produkt funkcije preživetja $R(t)$ in funkcije tveganja $h(t)$.

$$f(t) = h(t)R(t)$$

S pomočjo zgornjih enačb lahko s katero koli od treh funkcij $f(t)$, $R(t)$ in $h(t)$ izrazimo preostali funkciji.

V tem magistrskem delu je čas preživetja modeliran z Weibullovo funkcijo preživetja, definirano z enačbo (2.15), kjer je λ koeficient, ki določa upadanje krivulje, koeficient g pa določa, ali tveganje s časom narašča, upada ali pa je konstantno. V primeru, da je $g = 1$, je Weibullova porazdelitev enaka eksponentni.

$$R(t) = \exp(-\lambda t^g) \quad (2.15)$$

Weibullov model ima dve pomembni lastnosti:

- če drži predpostavka o pospešenih časih do odpovedi², potem drži tudi pred-

²Predpostavka o pospešenih časih do odpovedi pomeni, da je učinek pospešenega testiranja sorazmeren.

postavka o sorazmernih tveganjih³,

- logaritem negativnega logaritma funkcije preživetja $\log(-\log(R(t)))$ je linearno odvisen od logaritma časa $\log(t)$. Ta lastnost omogoča grafično preverjanje primernosti Weibullovega modela.

2.7.2 Coxov model

Coxov model sorazmernih tveganj je običajno zapisan v obliki funkcije tveganja z enačbo (2.16). Ta model poda tveganje ob času t za posameznika z določenimi vrednostmi spremenljivk \mathbf{X} . V tem primeru \mathbf{X} predstavlja zbirko spremenljivk, ki se uporabljajo za modeliranje.

$$h(t, \mathbf{X}) = h_0(t)e^{\sum_{i=1}^p \beta_i X_i} \quad (2.16)$$

Coxov model (2.16) pove, da je tveganje ob času t produkt dveh vrednosti. Prvi del enačbe je osnovno tveganje $h_0(t)$. Drugi je eksponent vsote $\beta_i X_i$, p je število spremenljivk. Pomembna lastnost tega modela je, da osnovno tveganje $h_0(t)$ ob času t ni odvisno od spremenljivk \mathbf{X} , ki so vključene v model. Prav tako eksponentni del modela ne vsebuje časa t . Tak model torej predpostavlja, da so spremenljivke, ki so vključene v model, časovno neodvisne.

Prednost Coxovega modela je ta, da za oceno razmerja tveganj različnih posameznikov ne potrebuje podatka o osnovnem tveganju. V primeru, da je podatke možno modelirati z ustreznim parametričnim modelom, bo Coxov model dal zelo podobne rezultate. Če podatkov ni možno ustrezno modelirati s parametričnim modelom, pa se lahko vedno uporabi Coxov model. V tej nalogi je Coxov model uporabljen za preverjanje povezanosti začetnih električnih parametrov s časi do odpovedi (povzeto iz [10]).

³Predpostavka o sorazmernih tveganjih pomeni, da je razmerje tveganj med dvema skupinama v času konstantno.

3 Praktični del

V tem delu naloge so uporabljene različne metode za modeliranje in analizo podatkov. Najprej so, s pomočjo parametričnih modelov, izračunane ocene srednjega časa do odpovedi varistorja pri različnih temperaturah. Dobljene ocene so nato uporabljene za napoved srednjega časa do odpovedi pri temperaturi 85 °C. Za tem sledi preverjanje odvisnosti med začetnimi električnimi parametri varistorja (V_n , α , I_{dc}) in časi do odpovedi. Za preverjanje medsebojne odvisnosti električnih parametrov so uporabljeni linearni in posplošeni linearni modeli. Podatki so obdelani v programskem okolju R (glej npr. [11]).

3.1 Potek poskusa

Oprema uporabljena pri poskusu:

- varistorji - CH1 300 K 20 AE B,
- komora Vötsch VCL 0003,
- napajalnik izmenične napetosti (0-400 V_{AC}),
- multimeter Keithley 2410 za merjenje nazivne napetosti V_n , koeficienta nelinearnosti α in toka puščanja I_{dc} .

Za testiranje je bilo naključno izbranih 80 varistorjev, ki so bili razdeljeni v dve skupini velikosti $n = 40$. Skupini sta bili testirani pri različnih temperaturah in sicer pri 140 °C in 150 °C. Vzorcema so bili pred začetkom izmerjeni začetni

električni parametri (Vn , α , I_{dc}). Med testiranjem so bili varistorji izpostavljeni delovni napetosti $300 V_{AC}$. Vzorca sta bila v presledkih (vsaj 24 h) vzeta iz komore, da so se opravile meritve električnih parametrov. Če je nazivna napetost Vn pri posameznem varistorju padla za več kot 10 %, je bil varistor označen kot neustrezen in bil umaknjen s testiranja. Testiranje se je izvajalo tako dolgo, dokler pri obeh vzorcih ni odpovedala vsaj polovica varistorjev.

3.2 Podatki

V tabeli 3.1 je predstavljen del podatkov dobljenih na podlagi meritev, tako da je razvidno, kako so podatki urejeni. Za vsak varistor je zabeležen čas odpovedi v urah. Glavna podatka za risanje krivulj preživetja sta **dur**, ki označuje čas do dogodka, in **cen**, ki označuje, ali je bil varistor krnjen ali ne. Temperatura **temp** označuje, na kateri temperaturi je bil varistor testiran. Nazivna napetost **Vn** označuje nazivno napetost Vn izmerjeno pri toku 1 mA. Spremenljivka **Idc** označuje začetni tok puščanja I_{dc} izmerjen pri $385 V_{DC}$. Koeficient nelinearnosti α je v spodnji tabeli označen kot **alfa**. Ta parameter multimeter izračuna sam s pomočjo enačbe (3.1) (povzeto iz [12]).

$$\alpha = \frac{\log(I2/I1)}{\log(V2/V1)}, \quad (3.1)$$

kjer je $V2$ napetost izmerjena pri toku $I2 = 10\text{mA}$, $V1$ pa je nazivna napetost izmerjena pri toku $I1 = 1\text{mA}$. Vrednost $V1$ inštrument shrani in je enaka nazivni napetosti Vn , vrednosti $V2$ in $I2$ pa ne beleži, ampak ju samo uporabi za izračun.

Tabela 3.1: Primer zapisa podatkov iz poskusa.

id	Vn	Idc	alfa	cen	dur	temp
7	464	14.10	40.4	1	745	140
8	460	18.00	39.5	0	1076	140
9	450	30.40	38.0	1	672	140
41	467	9.70	44.0	1	580	150
42	464	17.30	39.4	1	148	150

3.3 MTTF pri 85 °C

V tem poglavju je s pomočjo Arrheniousove enačbe (2.5) izračunana ocena MTTF za delovanje pri 85 °C na podlagi dobljenih podatkov.

3.3.1 Prilagoditev eksponentnega modela

V elektronski industriji so za analizo preživetja pogosto uporabljeni parametrični modeli. Eksponentni model zanesljivosti je zapisan z enačbo (3.2). Tak model predpostavlja, da se tveganje s časom ne spreminja, kar pogosto ne drži.

$$R(t) = \exp(-\lambda t), \quad (3.2)$$

koeficient λ določa strmino krivulje, t pa predstavlja čas.

V programskem okolju R se ocene parametričnih modelov izračunajo s pomočjo funkcije `survreg` iz paketa `survival` [13]. Ta paket vsebuje tudi vse ostale funkcije za analizo preživetja, ki so uporabljene v tem magistrskem delu. Skrajšan izpis ocenjenih koeficientov dobljenih s pomočjo funkcije `survreg` je prikazan v tabeli 3.2. Pod ocenjenimi koeficienti so v oklepajih zapisane še standardne napake, z (***) je označena statistična značilnost rezultatov. Spodnja koda izračuna ocene parametrov eksponentnega parametričnega modela in jih shrani kot

spremenljivko `reg.exp`.

```
> reg.exp <- survreg(Surv(dur, cen) ~ temp, df, dist = "exp")
```

Tabela 3.2: Ocenjeni koeficienti eksponentnega modela

<i>Dependent variable:</i>	
dur	
(Intercept)	7.369*** (0.209)
temp150	-0.572** (0.292)
Observations	80
Log Likelihood	-379.598
χ^2	3.808* (df = 1)
<i>Note:</i>	*p<0.1; **p<0.05; ***p<0.01

V spodnjem delu tabele 3.2 je zapisan rezultat testa razmerja verjetij, ki preverja, ali se model brez spremenljivk statistično značilno razlikuje od modela, ki vsebuje spremenljivko `temp`. Koeficient `temp150` ima negativno vrednost (-0.572), kar pomeni, da v tej skupini hitreje pride do odpovedi varistorjev. Koeficient je mejno statistično značilen ($p=0.049$), kar pomeni, da temperatura ima vpliv na čase odpovedi varistorjev.

V programskem paketu R se v regresijskih modelih preživetja preverja ničelna domneva $H_0 : -\log \lambda = 0$, kar je enako preverjanju domneve $H_0 : \lambda = 1$ (povzeto po [14]). V tem primeru se preverjata dve ničelni domnevi:

- $H_0 : \lambda_{140} = 1$, ali je koeficient λ_{140} za temperaturo 140 °C enak 1.
- $H_0 : \lambda_{140} = \lambda_{150}$, ali se koeficienta λ_{140} in λ_{150} razlikujeta.

Prave parametre eksponentnega modela se potem dobi tako, da se uporabi inverzno vrednost koeficientov v tabeli 3.2. Tako dobimo $\lambda_{140} = \exp(-7.369) = 0.00063$, $\lambda_{150} = \exp(-(7.369 + (-0.572))) = 0.00112$. Eksponentni model je v tem primeru opisan z enačbama (3.3). Spodnja koda v R-u vzame koeficiente iz ocenjenega modela `reg.exp` in jih shrani v spremenljivki `la.140` in `la.150`.

```
> c <- coef(reg.exp)
> la.140 <- exp(-c[1])
> la.150 <- exp(-(c[1] + c[2]))
```

$$\begin{aligned}\hat{R}_{140}(t) &= \exp(-0.00063t) \\ \hat{R}_{150}(t) &= \exp(-0.00112t)\end{aligned}\tag{3.3}$$

Z ocenjenimi parametri je sedaj možno oceniti MTTF na podlagi eksponentnega modela. Najprej se oceni srednji čas odpovedi za posamezno skupino. To naredimo s pomočjo enačbe (2.3) in dobimo:

$$\begin{aligned}MTTF &= \int_0^{\infty} R(t)dt = \\ &= \int_0^{\infty} e^{-\lambda t} dt = \\ &= \frac{1}{\lambda}\end{aligned}$$

Spodnja R koda izračuna integral enačb (3.3) ter rezultat shrani v spremenljivki `MTTF.140.e` in `MTTF.150.e`.

```
> (MTTF.140.e <- integrate(function(x){exp(-la.140 * x)}, lower = 0, upper = Inf))
```

```
1585.565 with absolute error < 0.0093
```

```
> (MTTF.150.e <- integrate(function(x){exp(-la.150 * x)}, lower = 0, upper = Inf))
```

894.7917 with absolute error < 0.0039

Ocenjene $MTTF$ vrednosti so izražene v urah. Frekvenco dogodkov dobimo z $\nu = 1/MTTF$. Nato lahko s pomočjo enačbe (2.8) izračunamo aktivacijsko energijo. Spodnja R koda pretvori vrednosti spremenljivk `MTTF.140` in `MTTF.150.e` v frekvenci dogodkov `nu1.e` in `nu2.e`.

```
> nu1.e <- 1/MTTF.140.e$value
> nu2.e <- 1/MTTF.150.e$value
```

$$\begin{aligned} E_a &= -k \frac{\log(\nu_{150}/\nu_{140})}{1/T_{150} - 1/T_{140}} \\ &= -8.617 \cdot 10^{-5} \text{eV/K} \frac{\log(0.00112/0.00063)}{1/(423.15\text{K}) - 1/(413.15\text{K})} \\ &= 0.862 \text{ eV}. \end{aligned}$$

Ko je aktivacijska energija določena, sledi izračun ν_0 s pomočjo enačbe (2.9):

$$\begin{aligned} \nu_0 &= \frac{\nu_{140}}{e^{\frac{E_a}{kT_{140}}}} \\ &= 20582260. \end{aligned}$$

Naslednji korak je izračun frekvence dogodkov `nu` s pomočjo enačbe (2.5). Temperatura, za katero se računa ocena $MTTF$, se prav tako zapiše v Kelvinih.

$$\begin{aligned} \nu &= \nu_0 e^{\frac{E_a}{kT}} \\ &= 20582260 e^{\frac{0.862\text{eV}}{-8.617 \cdot 10^{-5} \text{eV/K} \cdot 358.15\text{K}}} \\ &= 0.000015 \end{aligned}$$

Frekvenco dogodkov nato pretvorimo nazaj v čas $MTTF = 1/\nu$, da dobimo oceno $MTTF$ pri 85 °C. Slednja znaša 65274 h, kar je približno 7.5 let. Vsi

zgornji izračuni se v R-u izvedejo s funkcijo `Ea3`, kot je zapisano v spodnji kodi. V funkcijo se vnese 5 parametrov in sicer: dve frekvenci dogodkov `nu1` in `nu2`, pripadajoči temperaturi `T1` in `T2`, na podlagi katerih sta bili ocenjeni frekvenci dogodkov, ter temperaturo `T0`, za katero želimo narediti ekstrapolacijo *MTTF* ocene.

```
> Ea3(nu1 = nu1.e, nu2 = nu2.e, T1 = 140, T2 = 150, T0 = 85)
```

```
      Ea      nu0      nu      est.MTTF
8.620000e-01 2.058226e+07 1.500000e-05 6.527400e+04
```

Ali je ta rezultat primeren za poročanje naročniku, je potrebno preveriti. To lahko preverimo tako, da narišemo krivulje preživetja s pomočjo metode Kaplan-Meier (KM) in nato zraven narišemo še ocenjeni eksponentni model. Splošna formula za KM funkcijo preživetja je zapisana z enačbo (3.4). Ta formula poda verjetnost preživetja ob času t_i tako, da pomnoži verjetnost preživetja ob času t_{i-1} s pogojno verjetnostjo preživetja ob času t_i tistih, ki so ob tem času še delujoči.

$$\hat{R}(t_i) = \hat{R}(t_{i-1}) \cdot \hat{P}(T > t_i | T \geq t_i) \quad (3.4)$$

V programskem okolju R se KM ocene preživetja izračunajo s pomočjo funkcije `survfit` iz paketa `survival` [13]. Skrajšan izpis funkcije `survfit` je prikazan v tabeli 3.3 (celoten izpis je podan v dodatku), kjer je `n.start` velikost skupine ob začetku, `events` je število dogodkov (odpovedi) v skupini, `median`, pa pove, ob katerem času je testirana skupina dosegla polovico odpovedi.

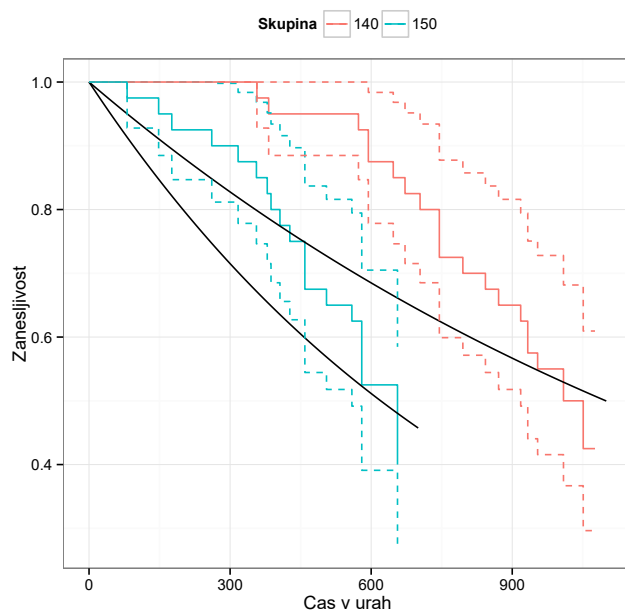
Tabela 3.3: Kratek izpis funkcije `survfit`

	<code>n.start</code>	<code>events</code>	<code>median</code>
<code>temp=140</code>	40	23	1030
<code>temp=150</code>	40	24	656

Spodnja R koda izračuna ocene preživetja po KM metodi za vsako skupino in vrednosti shrani v spremenljivko `fit.km`.

```
> fit.km <- survfit(Surv(dur, cen) ~ temp, df)
```

Slika 3.1 prikazuje prilaganje eksponentnega modela ocenam narejenih s pomočjo KM metode. Črtkane črte označujejo intervale zaupanja. Črne črte predstavljajo ocenjeni eksponentni model. Zgornja črna krivulja predstavlja oceno eksponentnega modela za skupino testirano pri 140 °C, spodnja črna črta pa predstavlja oceno eksponentnega modela za skupino testirano pri 150 °C. Obe krivulji sta večino časa izven intervalov zaupanja, kar pomeni da se model niti približno ne prilega podatkom, kar pomeni, da je tudi ocenjeni *MTTF* s pomočjo tega modela vprašljiv. Iz te slike je razvidno, da sta si krivulji kar precej blizu, zaradi česar so tudi ocenjeni koeficienti le mejno statistično značilni. Krivulji ocenjeni s KM metodo sta na začetku položni, nato pa začneta strmo padati. Slednje je znak, da tveganje v času ni konstantno. Eksponentni model za podatke tega poskusa ni primeren.



Slika 3.1: Prilaganje eksponentnega modela krivuljam preživetja ocenjenih s pomočjo metode KM.

3.3.2 Prilagoditev Weibullovega modela

Pri obravnavi elektronskih komponent, kot so varistorji, se časi do odpovedi praviloma porazdeljujejo po Weibullovi porazdelitvi. Iz tega razloga je ta porazdelitev tudi najbolj pogosto uporabljena v ocenjevanju zanesljivosti elektronskih naprav. Za razliko od eksponentne porazdelitve vsebuje dodaten parameter g , ki pove kako se tveganje spreminja s časom.

Spodnja R koda s funkcijo `survreg` oceni koeficiente Weibullovega parametričnega modela ter rezultate shrani v spremenljivko `reg.wei`.

```
> reg.wei <- survreg(Surv(dur, cen) ~ temp, df, dist = "wei")
```

Tabela 3.4: Ocenjeni koeficienti Weibullovega modela

	<i>Odvisna spremenljivka:</i>
	dur
Intercept	7.046*** (0.073)
temp150	-0.517*** (0.099)
Log(scale)	-1.081*** (0.134)
Observations	80
Loglik(model)	-357.118
Loglik(intercept only)	-366.8
χ^2	19.440*** (df = 1)

Note: *p<0.1; **p<0.05; ***p<0.01

V tabeli 3.4 (polni R-ov izpis je prikazan v dodatku) so zapisane ocene koeficientov Weibullovega modela. Za razliko od eksponentnega modela je sedaj koeficient temp150 močno statistično značilen ($p < 0.001$). Prav tako je močno

statistično značilen test razmerja verjetij ($p < 0.001$). Pri Weibullovem modelu se dodatno preverja še ena ničelna domneva glede na eksponentni model:

- $H_0 : g = 1$, ali je tveganje v času konstantno.


Parameter $\text{Log}(\text{scale})$ je močno statistično značilen, kar pomeni da tveganje v času ni konstantno. To je tudi eden glavnih razlogov zakaj se eksponentni model tako slabo prilega KM ocenam preživetja.

S spodnjo kodo podobno kot pri eksponentnem modelu izračunamo parametra λ_{140} in λ_{150} , zapisana kot spremenljivki `1a.140` in `1a.150`. Poleg tega izračunamo še parameter oblike g in ga shranimo v spremenljivko `g`.

```
> c <- coef(reg.wei)
> 1a.140 <- exp(-c[1])
> 1a.150 <- exp(-(c[1] + c[2]))
> g <- 1/reg.wei$scale
```

Tako dobimo $\lambda_{140} = \exp(-7.046) = 0.00087$, $\lambda_{150} = \exp(-(7.046 + (-0.517))) = 0.00146$. Parameter g pa se izračuna kot $g = 1/\exp(-1.081) = 2.946$. Funkcija `survreg` za oceno parametrov uporablja metodo največjega verjetja (povzeto iz vira [13]).

Slika 3.2 prikazuje prileganje Weibullovega modela KM ocenam preživetja na desni in preverjanje predpostavke o pospešenih časih do odpovedi ter prileganje podatkov Weibullovi premici na levi. Črni krivulji na desni predstavljata ocenjeni Weibullovi krivulji. Obe krivulji sta večino časa znotraj intervalov zaupanja. V zgornjem delu prihaja do odstopanj. Leva stran prikazuje odvisnost med $\log(-\log(R(t)))$ in $\log(t)$. Razvidno je, da se nekatere točke ne prilegajo Weibullovi premici. V primeru skupine testirane pri 150 °C so 3 točke kar precej oddaljene od premice. Premici sta vzporedni, ker model v tem primeru predpostavlja, da se tveganje spreminja enako hitro za obe skupini.



Slika 3.2: Prileganje Weibullovega modela ocenam KM metode.

Weibullov model `reg.wei` je v tem primeru opisan z enačbama (3.5).

$$\begin{aligned}\hat{R}_{140}(t) &= \exp(-0.00087 \cdot t^{2.946}) \\ \hat{R}_{150}(t) &= \exp(-0.00146 \cdot t^{2.946})\end{aligned}\quad (3.5)$$

Z ocenjenimi parametri Weibullove porazdelitve lahko sedaj izračunamo *MTTF* za obe skupini, tako da integriramo funkciji zanesljivosti iz enačbe (3.5). Frekvenco dogodkov nato zopet izračunamo kot $\nu = 1/MTTF$ in jo uporabimo za izračun aktivacijske energije ter frekvenco dogodkov za želeno temperaturo.

$$\begin{aligned}MTTF &= \int_0^{\infty} R(t) dt = \\ &= \int_0^{\infty} e^{(-\lambda \cdot t)^g} dt \\ &= \frac{1}{\lambda} \Gamma\left(1 + \frac{1}{g}\right)\end{aligned}$$

S spodnjo R kodo najprej integriramo funkciji zanesljivosti iz enačbe (3.5), da dobimo oceni *MTTF* za vsako skupino. Rezultat se shrani v spremenljivki

`MTTF.140.w` in `MTTF.150.w`. Nato sledi pretvorba *MTTF* ocen v frekvenci dogodkov `nu1.w` ter `nu2.w` in ekstrapolacija za temperaturo 85 °C.

```
> MTTF.140.w <- integrate(function(x){exp(-(1a.140 * x)^g)}, lower = 0, upper = Inf)
> MTTF.150.w <- integrate(function(x){exp(-(1a.150 * x)^g)}, lower = 0, upper = Inf)
> nu1.w <- 1/MTTF.140.w$value
> nu2.w <- 1/MTTF.150.w$value
> Ea3(nu1 = nu1.w, nu2 = nu2.w, T1 = 140, T2 = 150, T0 = 85)
```

```
      Ea          nu0          nu    est.MTTF
7.790000e-01 3.143982e+06 3.400000e-05 2.957400e+04
```

Na podlagi parametrov Weibullovega modela znaša aktivacijska energija $E_a = 0.779$ eV. Pri taki aktivacijski energiji je potem ocenjeni *MTTF* za delovanje pri 85 °C enak $MTTF_{85C} = 29574$ h, kar znaša približno 3.4 leta. Veliko odstopanje je posledica relativno dobrega prileganja Weibullovega modela ter že ugotovljenega zelo slabega prileganja eksponentnega modela. Ker se eksponentni model podatkom ne prilega dobro, so ocene lahko zelo daleč od realnosti.

Intervali zaupanja za *MTTF* se izračunajo po spodnji formuli (povzeto po [15]):

$$e^{\log(MTTF) \pm z_{\alpha/2} \cdot SE}, \quad (3.6)$$

kjer je *MTTF* srednji čas do odpovedi, α je stopnja zaupanja, *SE* pa je standardna napaka koeficienta λ . Enačba (3.6) velja samo za *MTTF* izračunan za Weibullovo porazdelitev. V tabeli 3.5 so prikazane ocene in intervali zaupanja dobljeni na podlagi Weibullovega modela `reg.wei`. Oznaka SM je spodnja meja zaupanja, ZM je zgornja meja zaupanja. Intervali zaupanja, ki so izračunani za temperaturo 85 °C so dobljeni na podlagi ekstrapolacije in niso zanesljivi. Prave intervale zaupanja za 85 °C bi dobili, če bi naredili oceno življenjske dobe pri 85 °C.

Naročniku se v tem primeru sporoči oceno 3.37 leta skupaj z intervalom zaupanja. Hkrati pa se začne izvajati tudi daljši test življenjske dobe, s katerim lahko potrdimo ali ovržemo to napoved.

Tabela 3.5: Ocenjeni MTTF skupaj z intervali zaupanja pri stopnji zaupanja $\alpha = 0.05$. Ocene so podane v letih.

T[°C]	SM	MTTF	ZM
140	0.10	0.12	0.14
150	0.06	0.07	0.08
85	2.78	3.37	4.07

3.4 Povezanost med začetnimi električnimi parametri in časom do odpovedi

V tem delu praktičnega dela smo preverjali ali imajo začetni električni parametri nazivna napetost V_n , koeficient nelinearnosti α ter tok puščanja I_{dc} kakršnokoli povezanost s časi do odpovedi.

V tem primeru uporaba Kaplan-Meierjeve ocene preživetja in parametričnih modelov odpade, ker je s temi modeli možno preverjati samo kategorične spremenljivke. V tem primeru je možna samo uporaba Coxovega modela sorazmernih tveganj. Spodnja koda izračuna ocene koeficientov Coxovega modela, ki vsebuje vse možne spremenljivke in rezultate shrani v spremenljivko `cox.f`.

```
> cox.f <- coxph(Surv(dur, cen) ~ temp * Vn * alfa * Idc, df)
```

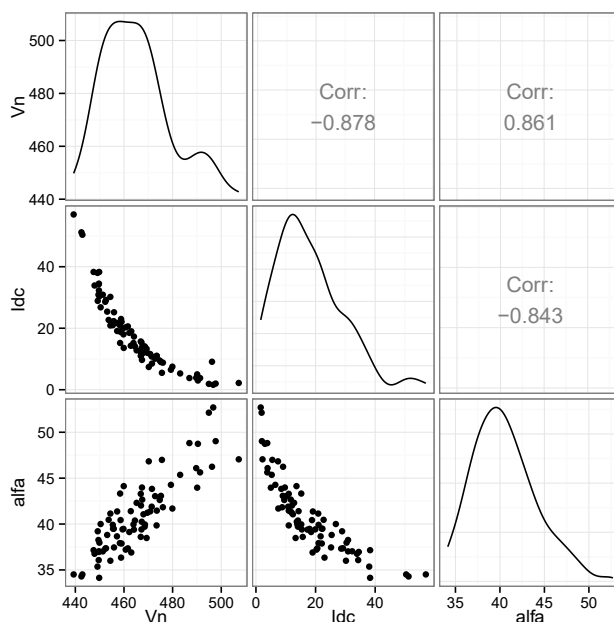
Rezultati testov za preverjanje modela so zapisani v tabeli 3.6, od koder je razvidno, da Waldov test in test razmerja verjetij (LR) podata povsem različne rezultate. V takih primerih je vedno bolje upoštevati LR test, ker uporablja manj predpostavk in je zaradi tega bolj zanesljiv. LR test ne zavrne ničelne domneve ($p = 0.899$), da se osnovni model (brez spremenljivk) razlikuje od polnega modela. Za to preverjanje je porabljenih 15 prostostnih stopenj (**df**). Če bi nekatere spremenljivke odstrani bi imeli na voljo več prostostnih stopenj in posledično bi imel LR test večjo moč.

Spremenljivka **alfa** (tabela 3.1) predstavlja koeficient nelinearnosti α , ki je iz-

Tabela 3.6: Testi za preverjanje modela `cox.f`


test	χ^2	df	p
Wald Test	31.937	15	0.007
LR Test	8.576	15	0.899

računan parameter po enačbi (3.1) in se ga zaradi tega lahko izključi iz Coxovega modela. Iz slike 3.3 je razvidno, da med vsemi električnimi parametri obstaja močna medsebojna odvisnost. Če je poskus izdelave modela, ki opisuje povezanost med nazivno napetostjo V_n in tokom puščanja I_{dc} , uspešen, se lahko Coxov model, ki preverja povezanost med začetnimi električnimi parametri s časom do odpovedi, precej poenostavi.



Slika 3.3: Povezanost osnovnih električnih parametrov.

Iz slike 3.3 je razvidno, da povezanost med V_n in I_{dc} ni povsem linearna. V tem primeru je smiselno uporabiti logaritemsko transformacijo spremenljivke I_{dc} .

Slika 3.4: Odvisnost $\log(I_{dc})$ od V_n .

Rezultat transformacije je razviden na sliki 3.4. Spodnja koda z ukazom `lm()`, podatkom **Vn** in **Idc** prilagodi linearni model in ocene koeficientov shrani v spremenljivko `Idc.lm1`.

```
> Idc.lm1 <- lm(log(Idc) ~ Vn, df)
```

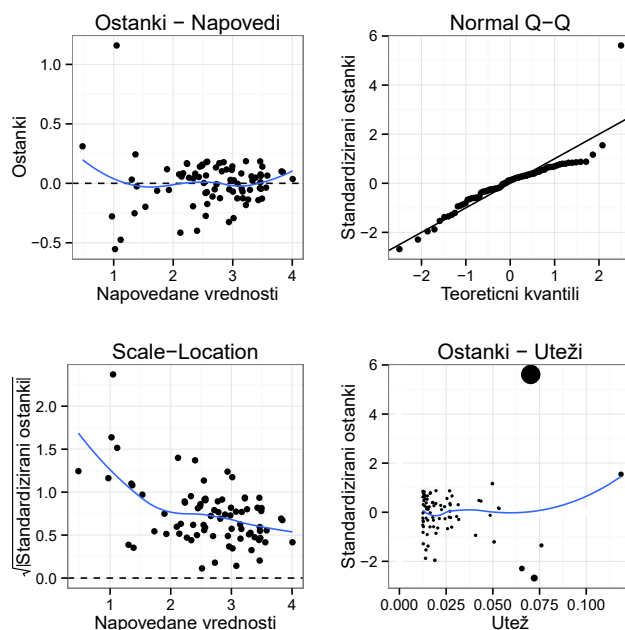
Linearni model `Idc.lm1` je predstavljen v tabeli 3.7 (polni R-ov izpis je podan v dodatku). Model se lahko zapiše v obliki enačbe $\log(I_{dc}) = 26.84 + (-0.05 \cdot V_n)$. Podatek R^2 pove, da model pojasni približno 92 % variabilnosti $\log(I_{dc})$. Standardne napake so glede na koeficiente precej majhne. Porazdelitev ostankov na sliki 3.5 kaže na to, da je kršena predpostavka o konstantni varianci. Slednje se lahko potrdi tudi s testom, ki preverja konstantnost variance. V R-u se za ta test uporablja funkcija `ncvTest` iz paketa `car` [7]. Slednje dosežemo s spodnjo kodo.

```
> ncvTest(Idc.lm1)
```

Non-constant Variance Score Test

Variance formula: \sim fitted.values

Chisquare = 68.62284 Df = 1 p = 1.192151e-16



Slika 3.5: Porazdelitev ostankov modela `Idc.lm1`.

Test nekonsistentne variance je močno statistično značilen, kar tudi sovпада s sliko 3.5. Test, ki preverja, ali je kakšna enota regresijski osamelec, se naredi s pomočjo funkcije `outlierTest` iz paketa `car` [7]. Spodnja koda izračuna ta test, ki prav tako vrne močno statistično značilen rezultat.

```
> outlierTest(Idc.lm1)
```

```
      rstudent unadjusted p-value Bonferonni p
551 7.225781      3.0976e-10  2.4781e-08
```

Ali je točka vplivna ali ne se v R-u preveri s funkcijo `influencePlot` iz paketa `car` [7]. Če je parameter `CookD` > 1 , je točka vplivna ¹. Spodnja koda prikazuje

¹Ta definicija je vzeta iz vira [9], poglavje: Posebne točke v regresiji, multipla regresija, robustna regresija

uporabo navedene funkcije. V tem primeru imamo eno vplivno točko. To je enota, ki ima `id=55`.

```
> influencePlot(Idc.lm1)

      StudRes      Hat      CookD
10  1.562003  0.11862435  0.4015146
551 7.225781  0.07028314  1.0914807

> df[55, ]

      id  Vn Idc  alfa  cen  dur  temp
551 55 496.2  9.1 46.24   1   81   150
```


Spodnja koda oceni nov model brez enote, ki je vplivna točka.

```
> df1 <- df[-55,]
> Idc.lm2 <- lm(log(Idc) ~ Vn, df1)
```

Stanje se ne popravi. Še vedno ostane kršena predpostavka o konstantni varianci (slika 3.6).

Zaradi kršenih predpostavk ni možno izdelati ustreznega linearnega modela. Druga opcija je uporaba posplošenega linearnega modela, kjer je varianca funkcija, ki je odvisna od povprečja in ne predpostavlja konstantnosti. Za izdelavo posplošenega modela je potrebno predpostaviti porazdelitev odzivne spremenljivke **Idc**. Iz slike 3.3 je razvidno, da vrednost toka puščanja ne pade pod 0 in da je celotna porazdelitev zamaknjena v levo. Iz tega se lahko predvideva, da se **Idc** porazdeljuje po Gamma porazdelitvi. Spodnja R koda naredi ocene posplošenega linearnega modela, ki predpostavlja Gamma porazdelitev odvisne spremenljivke ter uporablja log za vezno funkcijo. Ocene nato shrani v spremenljivko `Idc.glm1`.

```
> Idc.glm1 <- glm(formula = Idc ~ Vn,
+               data = df,
+               family = Gamma(link = "log"))
```



Slika 3.6: Porazdelitev ostankov modela `Idc.lm2`.

V tabeli 3.7 so prikazane ocene linearnega modela `Idc.lm1` in posplošenega linearnega modela `Idc.glm1`. Koeficienti enega in drugega modela so si precej podobni. Razlika je sedaj v tem, da je sproščena predpostavka o konstantni varianci. Model `Idc.glm1` ima negativen koeficient za nazivno napetost. Slednje pomeni, da se z večanjem nazivne napetosti zmanjšuje tok puščanja. Ta trditev se ujema s sliko 3.7. Prav tako je iz te slike razvidno, da se model zelo dobro prilega podatkom. S sivo barvo so označeni intervali zaupanja, ki se zmanjšujejo, ker je varianca funkcija, ki je odvisna od povprečja. Povezanost med tokom puščanja in nazivno napetostjo je pojasnjena z enačbo (3.7).

$$Idc = \exp(25.754 + (-0.05)Vn) \quad (3.7)$$

Ker je povezanost med tokom puščanja Idc in nazivno napetostjo Vn , določena z enačbo, se lahko Coxov model sorazmernih tveganj precej poenostavi. Dovolj je, če se od začetnih električnih parametrov vključi le tok puščanja Idc . Spodnja R koda izdelava dva Coxova modela in sicer, spremenljivka `cox1` predstavlja ocene

Tabela 3.7: Ocene linearnega modela `Idc.lm1` ter posplošenega linearnega modela `Idc.glm1`


	<i>Odvisna spremenljivka:</i>	
	<i>log</i> (Idc)	Idc
	<i>OLS</i>	<i>glm: Gamma</i> <i>link = log</i>
	Idc.lm1	Idc.glm1
Constant	26.843*** (0.774)	25.754*** (0.962)
Vn	-0.052*** (0.002)	-0.050*** (0.002)
Observations	80	80
R ²	0.926	
Null deviance		39.467
Residual deviance		4.004
Residual Std. Error	0.214 (df = 78)	
F Statistic	977.999*** (df = 1; 78)	

Note: *p<0.1; **p<0.05; ***p<0.01

Coxovega modela, ki vsebuje interakcijo med temperaturo in tokom puščanja. Spremenljivka `cox2` predstavlja Coxov model, ki ne vsebuje interakcije.

```
> cox1 <- coxph(Surv(dur, cen) ~ temp * Idc, df)
> cox2 <- coxph(Surv(dur, cen) ~ temp + Idc, df)
```

Tabela 3.8 prikazuje ocene koeficientov poenostavljenih Coxovih modelov `cox1` in `cox2`. V poenostavljenem modelu interakcija med tokom puščanja `Idc` in temperaturo ni statistično značilna in se jo lahko odstrani iz modela. Coxov model predpostavlja, da so razmerja tveganj v času konstantna. V primeru temperature to pomeni, da se v času ta koeficient ne spreminja. V primeru toka puščanja `Idc`



Slika 3.7: Prileganje modela `Idc.glm1` podatkom.

pa to pomeni, da tveganje s tokom puščanja narašča ali pada linearno. Konstantnost koeficienta v času se preverja s Schoenfeldovimi ostanki, linearno povezanost pa se preverja z zleпки ².

Schoenfeldovi ostanki se, v primeru uporabe več spremenljivk, računajo za vsako spremenljivko posebej (povzeto iz [10]). V primeru, da ima varistor i odpoved pri času t . Potem je njegov Schoenfeldov ostanek za temperaturo enak razliki njegovega dejanskega časa odpovedi in uteženega povprečja odpovedi tistih varistorjev, ki so ob času t še delujoči.

Ideja samega testa je v tem, da če predpostavka o sorazmernih tveganjih drži, potem Schoenfeldovi ostanki niso povezani s časi preživetja.

Spodnja R koda izračuna test Schoenfeldovih ostankov, rezultati pa so podani v tabeli 3.9. Test Schoenfeldovih ostankov ne zavrne ničelne domneve, da so koeficienti v času konstantni.

²Zleпки so splošna metoda, ki ni vezana na analizo preživetja. Uporablja se z namenom, da sprostimo predpostavko o linearnosti, če je to potrebno. Vzeto iz vira [14]

Tabela 3.8: Poenostavljena Coxova modela proporcionalnih tveganj `cox1` in `cox2`

	Odvisne spremenljivke:	
	S	
	cox1	cox2
temp150	1.679** (0.677)	2.175*** (0.490)
Idc	0.027* (0.014)	0.035*** (0.012)
temp150:Idc	0.027 (0.025)	
Observations	80	80
Wald Test	25.060*** (df = 3)	22.070*** (df = 2)
LR Test	27.549*** (df = 3)	26.423*** (df = 2)
Score (Logrank) Test	32.930*** (df = 3)	25.842*** (df = 2)
<i>Note:</i>	*p<0.1; **p<0.05; ***p<0.01	

```
> cox.zph(cox2)
```

Tabela 3.9: Test Schoenfeldovih ostankov

	ρ	χ^2	p
temp150	-0.067	0.199	0.655
Idc	-0.125	0.559	0.455
GLOBAL		0.598	0.742

Spodnja R koda z uporabo funkcije `cph` iz paketa `rms` [16] izračuna Coxov model s tem, da spremenljivko **Idc** razdeli na tri zlepke. Funkcija `anova` nato naredi Waldov test, ki preverja statistično značilnost koeficientov.

```
> fit.cph <- cph(Surv(dur, cen) ~ temp + rcs(Idc, 3), df)
> anova(fit.cph)
```


Tabela 3.10: Waldov test za preverjanje linearnega in nelinearnega dela modela `fit.cph`

	χ^2	df	p
temp	22.344	1.000	<0.000
Idc	10.808	4.000	0.005
Nonlinear	4.341	3.000	0.057
TOTAL	26.829	5.000	<0.000

Tabela 3.10 prikazuje rezultat funkcije `anova` iz zgornje kode. V tem primeru dobimo mejno statistično značilnost nelinearnega dela ($p = 0.057$). To se na sliki 3.8 vidi po tem, da z večanjem toka logaritem tveganja ne narašča povsem linearno. Intervali zaupanja so dovolj široki, da bi lahko vsebovali premico. Zato upoštevamo statistično značilnost linearnega dela ($p = 0.005$).

Končni model je torej `cox2`. Ocenjena koeficienta na vzorcu sta enaka $\beta_{temp} = 2.175$ za temperaturo, ter $\beta_{Idc} = 0.035$ za tok puščanja. Pozitiven predznak pri koeficientu za tok pomeni, da večji tok puščanja, kot ga ima varistor večje je njegovo tveganje za odpoved. Waldov test za koeficient `Idc` ($z = \hat{\beta}/\widehat{SE}$) da statistično značilen rezultat, $p = 0.003$. Enačba 3.8 predstavlja funkcijo tveganja, ki jo dobimo iz modela `cox2`.

$$\hat{h}(t, \mathbf{X}) = \hat{h}_0(t)e^{2.175 \cdot \text{temp} + 0.035 \cdot \text{Idc}} \quad (3.8)$$



Slika 3.8: Povezanost toka puščanja z logaritmom relativnega tveganja

4 Sklep

V prvem delu praktičnega dela je narejen poskus izračuna ocene srednjega časa do odpovedi, če bi varistorji delovali pri temperaturi 85 °C. S pomočjo parametričnih modelov so bile izdelane funkcije zanesljivosti. Ocena *MTTF* pri povišanih temperaturah je bila izračunana kot integral funkcije zanesljivosti. Te ocene so bile nato pretvorjene v frekvence dogodkov ν , s pomočjo katerih je bila nato izračunana aktivacijska energija E_a ter ekstrapolacija *MTTF* na 85 °C.

Enkrat je bil za oceno *MTTF* pri povišanih temperaturah uporabljen eksponentni model, drugič pa Weibullov model. Razlika v končni oceni je precej velika (4 leta). Do razlike pride zaradi zelo slabega prileganja eksponentnega modela ter zelo dobrega prileganja Weibullovega modela.

V drugem delu praktičnega dela je bilo pokazano, da je z življenjsko dobo varistorja povezan tudi začetni tok puščanja *Idc*. Za to potrditev je uporabljen Coxov model sorazmernih tveganj, v katerega pa niso bili vključeni preostali začetni električni parametri, ki so bili na voljo. Z izdelavo posplošenega linearne modela je bilo pokazano, da obstaja zelo močna povezava med tokom puščanja *Idc* in nazivno napetostjo V_n . Parameter α je bil izključen iz modela, ker je izračunan na podlagi nazivne napetosti.

V tej nalogi sem se naučil, kako narediti pripravo in izvedbo poskusa za pridobitev ocene življenjske dobe varistorja. Prav tako sem poglobil svoje znanje o metodah za analizo preživetja, o statističnem programskem jeziku R ter urejanju besedila v LaTeX-u.

Zaradi zahtev naročnika sem se odločil, da bom v prihodnosti izvedel tudi testiranje pri 130 °C. Ko bom dobil podatke iz testiranj na več različnih temperaturah, imam namen izdelati linearni ali posplošeni linearni model za modeliranje temperature in *MTTF*. S tem bom tudi lahko preveril ali se koeficient aktivacijske energije ujema z izračunom v poglavju 3.3.

Za izdelavo LaTeX tabel sem uporabljal funkcije `xtable` [17] ter `stargazer` [18]. Za izdelavo grafov sem uporabljal knjižnico `ggplot2` [19]. Funkciji `lm` in `glm` sta del knjižnice `stats` [20]. Za izdelavo svojih funkcij sem za delo z znakovnimi nizi uporabil knjižnico `stringr` [21]. Slika 3.3 je izdelana s pomočjo knjižnice `GGally` [22].

Dodatek

A Rezultati meritev pospešenega testiranja

V tabeli A.1 so rezultati meritev pospešenega testiranja, ki so uporabljeni v tej magistrski nalogi. V spodnji tabeli id predstavlja številko varistorja, V_n je začetna nazivna napetost, I_{dc} je tok puščanja, cen označuje status krnenja, dur označuje čas do dogodka, $temp$ označuje temperaturo na kateri je skupina bila testirana.

Tabela A.1: Izmerjeni podatki.

id	V_n	I_{dc}	alfa	cen	dur	temp
1	442.5	51.20	34.3	1	1051	140
2	442.9	50.40	34.5	1	382	140
3	479.9	7.50	41.7	0	1076	140
4	447.9	33.90	36.8	0	1076	140
5	507.2	2.20	47.0	0	1076	140
6	461.6	20.60	37.4	1	745	140
7	464.5	14.10	40.4	1	745	140
8	459.8	18.00	39.5	0	1076	140
9	449.9	30.40	38.0	1	672	140
10	471.5	8.50	43.8	0	1076	140
11	473.4	11.00	39.9	1	1051	140
12	469.6	12.00	41.2	0	1076	140
13	453.1	25.40	38.8	1	594	140

14	463.0	19.00	36.9	0	1076	140
15	466.9	15.70	38.6	1	573	140
16	439.3	57.00	34.5	1	1051	140
17	447.5	38.30	37.1	1	745	140
18	455.5	22.10	39.5	0	1076	140
19	457.1	21.70	38.7	1	795	140
20	455.4	21.00	39.9	0	1076	140
21	451.3	30.90	37.0	1	1009	140
22	467.0	12.10	42.0	0	1076	140
23	449.6	34.30	36.1	0	1076	140
24	469.3	13.30	38.5	0	1076	140
25	463.9	15.20	40.0	0	1076	140
26	479.3	6.50	44.3	1	933	140
27	459.4	19.90	39.4	1	704	140
28	450.4	26.80	40.0	1	843	140
29	452.6	29.20	37.4	1	594	140
30	449.8	38.30	34.1	0	1076	140
31	459.0	22.10	37.9	0	1076	140
32	455.9	25.20	37.5	0	1076	140
33	460.7	20.30	37.2	1	933	140
34	462.8	14.30	41.4	1	1009	140
35	465.2	12.80	42.3	0	1076	140
36	454.4	30.20	36.0	1	647	140
37	449.7	32.30	37.0	1	357	140
38	452.3	28.60	37.3	1	954	140
39	458.8	23.00	36.3	1	918	140
40	458.3	21.00	37.9	1	871	140
41	467.4	9.70	44.0	1	580	150
42	464.1	17.30	39.4	1	148	150
43	475.2	9.00	43.1	1	261	150

44	462.2	18.50	39.1	1	656	150
45	468.0	12.40	41.1	0	656	150
46	489.7	3.90	46.1	1	656	150
47	476.0	8.80	41.8	0	656	150
48	449.2	28.90	39.2	1	505	150
49	483.1	5.30	45.4	0	656	150
50	449.5	30.90	38.3	1	580	150
51	475.6	5.50	47.0	0	656	150
52	459.9	13.60	44.1	1	459	150
53	468.5	14.10	39.7	1	356	150
54	486.9	3.80	48.8	0	656	150
55	496.2	9.10	46.2	1	81	150
56	466.9	11.00	43.3	0	656	150
57	458.4	15.20	43.3	0	656	150
58	467.3	13.70	40.2	1	580	150
59	449.7	34.50	37.0	1	580	150
60	491.3	3.80	45.6	0	656	150
61	494.9	1.90	52.1	0	656	150
62	467.2	15.40	39.4	0	656	150
63	454.4	20.90	41.1	1	559	150
64	458.6	18.80	40.4	0	656	150
65	470.8	11.60	41.4	1	459	150
66	455.8	22.30	39.5	1	427	150
67	496.7	1.60	52.7	0	656	150
68	467.5	11.70	42.7	1	406	150
69	474.7	9.50	42.6	0	656	150
70	471.4	10.80	41.9	1	656	150
71	468.6	13.90	40.0	1	176	150
72	449.1	38.00	35.4	1	387	150
73	497.7	2.00	49.0	1	656	150

74	490.1	5.00	44.0	0	656	150
75	490.4	3.00	48.7	0	656	150
76	457.2	19.10	41.4	1	379	150
77	473.5	11.00	41.5	1	656	150
78	472.8	10.10	43.0	1	459	150
79	453.7	22.70	40.5	0	656	150
80	470.2	7.40	46.8	1	317	150

B Rezultati modelov

V nadaljevanju so podani podatki, ki smo jih dobili kot rezultat različnih modelov. Dobljeni so bili s pomočjo R funkcij za izdelavo modelov. Razširjen izpis je podan s funkcijo `summary` v R-u.

Razširjen izpis KM ocen preživetja:

```
Call: survfit(formula = Surv(dur, cen) ~ temp, data = df)
```

```
temp=140
time n.risk n.event survival std.err lower 95% CI upper 95% CI
357 40 1 0.975 0.0247 0.928 1.000
382 39 1 0.950 0.0345 0.885 1.000
573 38 1 0.925 0.0416 0.847 1.000
594 37 2 0.875 0.0523 0.778 0.984
647 35 1 0.850 0.0565 0.746 0.968
672 34 1 0.825 0.0601 0.715 0.952
704 33 1 0.800 0.0632 0.685 0.934
745 32 3 0.725 0.0706 0.599 0.877
795 29 1 0.700 0.0725 0.571 0.857
843 28 1 0.675 0.0741 0.544 0.837
871 27 1 0.650 0.0754 0.518 0.816
918 26 1 0.625 0.0765 0.492 0.795
933 25 2 0.575 0.0782 0.441 0.751
954 23 1 0.550 0.0787 0.416 0.728
1009 22 2 0.500 0.0791 0.367 0.682
1051 20 3 0.425 0.0782 0.296 0.609
```

```
temp=150
time n.risk n.event survival std.err lower 95% CI upper 95% CI
81 40 1 0.975 0.0247 0.928 1.000
148 39 1 0.950 0.0345 0.885 1.000
176 38 1 0.925 0.0416 0.847 1.000
261 37 1 0.900 0.0474 0.812 0.998
```

317	36	1	0.875	0.0523	0.778	0.984
356	35	1	0.850	0.0565	0.746	0.968
379	34	1	0.825	0.0601	0.715	0.952
387	33	1	0.800	0.0632	0.685	0.934
406	32	1	0.775	0.0660	0.656	0.916
427	31	1	0.750	0.0685	0.627	0.897
459	30	3	0.675	0.0741	0.544	0.837
505	27	1	0.650	0.0754	0.518	0.816
559	26	1	0.625	0.0765	0.492	0.795
580	25	4	0.525	0.0790	0.391	0.705
656	21	5	0.400	0.0775	0.274	0.585

Razširjen izpis parametričnega eksponentnega modela `reg.exp`

Call:

```
survreg(formula = Surv(dur, cen) ~ temp, data = df, dist = "exp")
```

	Value	Std. Error	z	p
(Intercept)	7.369	0.209	35.34	1.48e-273
temp150	-0.572	0.292	-1.96	4.99e-02

Scale fixed at 1

Exponential distribution

Loglik(model)= -379.6 Loglik(intercept only)= -381.5

Chisq= 3.81 on 1 degrees of freedom, p= 0.051

Number of Newton-Raphson Iterations: 4

n= 80

Razširjen izpis parametričnega Weibull modela `reg.wei`:

Call:

```
survreg(formula = Surv(dur, cen) ~ temp, data = df, dist = "wei")
```

	Value	Std. Error	z	p
(Intercept)	7.046	0.0731	96.33	0.0e+00
temp150	-0.517	0.0991	-5.22	1.8e-07
Log(scale)	-1.081	0.1339	-8.07	7.0e-16

Scale= 0.339

Weibull distribution

Loglik(model)= -357.1 Loglik(intercept only)= -366.8

Chisq= 19.44 on 1 degrees of freedom, p= 1e-05

Number of Newton-Raphson Iterations: 5

n= 80

Razširjen izpis polnega Coxovega modela `cox.f`:

Call:

```
coxph(formula = Surv(dur, cen) ~ temp * Vn * alfa * Idc, data = df)
```

```
n= 80, number of events= 47
```

	coef	exp(coef)	se(coef)	z	Pr(> z)
temp150	8.549e+02	Inf	1.296e+03	0.660	0.5096
Vn	8.952e-01	2.448e+00	8.742e-01	1.024	0.3058
alfa	8.440e+00	4.627e+03	9.845e+00	0.857	0.3913
Idc	-6.849e+00	1.061e-03	2.772e+01	-0.247	0.8049
temp150:Vn	-1.861e+00	1.554e-01	2.610e+00	-0.713	0.4758
temp150:alfa	-2.196e+01	2.903e-10	2.880e+01	-0.762	0.4458
Vn:alfa	-1.744e-02	9.827e-01	1.992e-02	-0.875	0.3813
temp150:Idc	1.494e+02	7.739e+64	7.786e+01	1.919	0.0550 .
Vn:Idc	1.532e-02	1.015e+00	6.365e-02	0.241	0.8098
alfa:Idc	1.229e-01	1.131e+00	7.981e-01	0.154	0.8776
temp150:Vn:alfa	4.634e-02	1.047e+00	5.788e-02	0.801	0.4234
temp150:Vn:Idc	-3.362e-01	7.145e-01	1.783e-01	-1.885	0.0594 .
temp150:alfa:Idc	-4.313e+00	1.340e-02	1.994e+00	-2.163	0.0305 *
Vn:alfa:Idc	-2.527e-04	9.997e-01	1.828e-03	-0.138	0.8901
temp150:Vn:alfa:Idc	9.742e-03	1.010e+00	4.547e-03	2.142	0.0322 *

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

	exp(coef)	exp(-coef)	lower .95	upper .95
temp150	Inf	0.000e+00	0.000e+00	Inf
Vn	2.448e+00	4.085e-01	4.413e-01	1.358e+01
alfa	4.627e+03	2.161e-04	1.929e-05	1.110e+12
Idc	1.061e-03	9.428e+02	2.689e-27	4.184e+20
temp150:Vn	1.554e-01	6.433e+00	9.323e-04	2.592e+01
temp150:alfa	2.903e-10	3.445e+09	8.789e-35	9.587e+14
Vn:alfa	9.827e-01	1.018e+00	9.451e-01	1.022e+00
temp150:Idc	7.739e+64	1.292e-65	4.126e-02	1.452e+131
Vn:Idc	1.015e+00	9.848e-01	8.963e-01	1.150e+00
alfa:Idc	1.131e+00	8.844e-01	2.366e-01	5.404e+00
temp150:Vn:alfa	1.047e+00	9.547e-01	9.351e-01	1.173e+00
temp150:Vn:Idc	7.145e-01	1.400e+00	5.037e-01	1.013e+00
temp150:alfa:Idc	1.340e-02	7.464e+01	2.691e-04	6.672e-01
Vn:alfa:Idc	9.997e-01	1.000e+00	9.962e-01	1.003e+00
temp150:Vn:alfa:Idc	1.010e+00	9.903e-01	1.001e+00	1.019e+00

```
Concordance= 0.651 (se = 0.047 )
```

```
Rsquare= 0.102 (max possible= 0.989 )
```

```
Likelihood ratio test= 8.58 on 15 df, p=0.8986
```

Wald test = 31.94 on 15 df, p=0.006567
 Score (logrank) test = 87.67 on 15 df, p=2.697e-12

Razširjen izpis linearnega modela Idc.lm1:

Call:

```
lm(formula = log(Idc) ~ Vn, data = df)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.55311	-0.08883	0.02698	0.10414	1.15917

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	26.842689	0.773684	34.70	<2e-16 ***
Vn	-0.051982	0.001662	-31.27	<2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.2141 on 78 degrees of freedom

Multiple R-squared: 0.9261, Adjusted R-squared: 0.9252

F-statistic: 978 on 1 and 78 DF, p-value: < 2.2e-16

Razširjen izpis linearnega modela Idc.lm2:

Call:

```
lm(formula = log(Idc) ~ Vn, data = df1)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.46432	-0.08593	0.02475	0.11503	0.42438

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	27.909439	0.618981	45.09	<2e-16 ***
Vn	-0.054309	0.001331	-40.80	<2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.1664 on 77 degrees of freedom

Multiple R-squared: 0.9558, Adjusted R-squared: 0.9552

F-statistic: 1665 on 1 and 77 DF, p-value: < 2.2e-16

Razširjen izpis posplošenega linearnega modela Idc.glm1:

Call:
 glm(formula = Idc ~ Vn, family = Gamma(link = "log"), data = df)

Deviance Residuals:

Min	1Q	Median	3Q	Max
-0.58941	-0.11576	0.00576	0.10391	1.28561

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	25.754007	0.962007	26.77	<2e-16 ***
Vn	-0.049588	0.002067	-23.99	<2e-16 ***

 Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for Gamma family taken to be 0.07089425)

Null deviance: 39.467 on 79 degrees of freedom
 Residual deviance: 4.004 on 78 degrees of freedom
 AIC: 419.54

Number of Fisher Scoring iterations: 5

Razširjen izpis coxovih modelov cox1 in cox2:

Call:
 coxph(formula = Surv(dur, cen) ~ temp * Idc, data = df)

n= 80, number of events= 47

	coef	exp(coef)	se(coef)	z	Pr(> z)
temp150	1.67944	5.36258	0.67664	2.482	0.0131 *
Idc	0.02684	1.02720	0.01422	1.887	0.0592 .
temp150:Idc	0.02689	1.02725	0.02519	1.067	0.2858

 Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

	exp(coef)	exp(-coef)	lower .95	upper .95
temp150	5.363	0.1865	1.4237	20.199
Idc	1.027	0.9735	0.9990	1.056
temp150:Idc	1.027	0.9735	0.9778	1.079

Concordance= 0.736 (se = 0.047)

Rsquare= 0.291 (max possible= 0.989)

Likelihood ratio test= 27.55 on 3 df, p=4.517e-06

Wald test = 25.06 on 3 df, p=1.502e-05

Score (logrank) test = 32.93 on 3 df, p=3.331e-07

Call:

```
coxph(formula = Surv(dur, cen) ~ temp + Idc, data = df)
```

n= 80, number of events= 47

	coef	exp(coef)	se(coef)	z	Pr(> z)	
temp150	2.17468	8.79937	0.49006	4.438	9.1e-06	***
Idc	0.03493	1.03554	0.01163	3.002	0.00268	**

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

	exp(coef)	exp(-coef)	lower .95	upper .95
temp150	8.799	0.1136	3.368	22.993
Idc	1.036	0.9657	1.012	1.059

Concordance= 0.736 (se = 0.047)

Rsquare= 0.281 (max possible= 0.989)

Likelihood ratio test= 26.42 on 2 df, p=1.829e-06

Wald test = 22.07 on 2 df, p=1.611e-05

Score (logrank) test = 25.84 on 2 df, p=2.447e-06

C Uporabljene funkcije v R

V tem poglavju so izpisane funkcije, ki sem jih sprogramiral sam na podlagi znanja, ki sem ga pridobil med študijem. Uporabil sem jih za obdelavo podatkov, izris slik, izračun MTTF ocen, za spremljanje samega testiranja ter za preverjanje nekaterih predpostavk.

Spodnja funkcija `prepareData` pretvori izmerjene podatke tako, da vzame slabšo stran meritev. Za Vn vzame nižjo vrednost, za Idc vzame višjo vrednost ter za α vzame nižjo vrednost.

```
> prepareData <- function(data, time){
+   param <- c("pV", "mV", "pI", "mI", "pA", "mA")
+   names(data) <- param
+
+   data$Vn <- round(pmin(data$pV, data$mV), 1)
+   data$Idc <- round(pmax(data$pI, data$mI), 1)
+   data$alfa <- round(pmin(data$pA, data$mA), 2)
+   data$id <- 1 : nrow(data)
+   data$time <- time
+   return(data[, c("id", "time", "Vn", "Idc", "alfa")])
+ }
```

Funkcija `deltaChange` vrne relativno vrednost spremembe. Uporabljal sem jo za spremljanje spremembe glede na začetno Vn .

```
> deltaChange <- function(before, after){
+   d <- round(abs(before - after) / before * 100, 2)
+   l <- length(d)
+   for(i in 1 : l){
+     if(after[i] < before[i]){
+       d[i] <- -d[i]
+     }
+   }
+ }
```

```
+   }
+ }
+ return(round(d, 2))
+ }
```

Funkcija `absChange` vrne absolutno razliko spremembe. Uporabljal sem jo za spremljanje spremembe Idc in α .

```
> absChange <- function(before, after){
+   abs <- abs(before - after)
+   return(round(abs, 2))
+ }
```

Funkcija `insertRow` vstavi novo vrstico v objekt tipa `data.frame`, ne da bi pri tem povozil preostale zapise.

```
> insertRow <- function(existingDF, newrow, r) {
+   existingDF[seq(r+1,nrow(existingDF)+1),] <- existingDF[seq(r,nrow(existingDF)),]
+   existingDF[r,] <- newrow
+   existingDF
+ }
```

Funkcija `prepare` pretvori podatke tako, da so primerni za risanje s knjižnico `ggplot2`.

```
> prepare <- function(data){
+   if("strata" %in% names(data)){
+     strata <- data$strata
+     nStrata <- length(strata)
+     group <- vector()
+     strataNames <- names(data$strata)
+     loc <- regexpr(pattern = "=", text = strataNames)
+     facNames <- str_sub(string = strataNames, start = loc[1] + 1)
+
+     for(i in 1 : nStrata){
+       group <- c(group, rep(i, times = strata[i]))
+     }
+
+     df <- data.frame(time = data$time,
+                     surv = data$surv,
+                     cen = data$n.censor,
```

```

+         ul = data$upper,
+         ll = data$lower,
+         group,
+         stringsAsFactors = FALSE)
+
+   for(i in 1 : nStrata){
+     row <- c(0, 1, 0, 1, 1, i)
+     df <- insertRow(existingDF = df, newrow = row, match(x = i, table = df$group))
+   }
+
+   df$group <- factor(df$group, labels = facNames)
+   return(df)
+ } else {
+   time <- c(0, data$time)
+   surv <- c(1, data$surv)
+   krnji <- c(0, data$n.censor)
+   ul <- c(1, data$upper)
+   ll <- c(1, data$lower)
+   df <- data.frame(time, surv, cen =krnji, ul, ll)
+   return((df))
+ }
+ }

```

Funkcija `prepareCox` pretvori vrednosti izračunane po Coxovem modelu, tako da so primerne za lepo risanje s knjižnico `ggplot2`.

```

> prepareCox <- function(model, group = NULL){
+   if("strata" %in% names(model)){
+     groups <- length(model$strata)
+     strata <- rep(1 : groups, times = as.numeric(model$strata))
+     time <- model$time
+     surv <- model$surv
+     ul <- model$upper
+     ll <- model$lower
+     cen <- model$n.censor
+     df <- data.frame(time, surv, cen, ul, ll, group = strata)
+     for(i in 1 : groups){
+       row <- c(0, 1, 0, 1, 1, i)
+       df <- insertRow(df, row, match(i, df$group))
+     }
+     df$group <- factor(df$group, labels = group)
+     return(df)
+   } else {
+     if(is.null(group)){

```

```

+   return("Rabim skupine")
+ }
+ if(length(group) != ncol(model$surv)){
+   return("? tevilno skupin se ne ujema z številom skupin modela.")
+ }
+ groups <- ncol(model$surv)
+ time <- rep(x = c(model$time), times = groups)
+ cen <- rep(x = c(model$n.censor), times = groups)
+ strata <- rep(x = c(1 : groups), each = nrow(model$surv))
+ surv <- as.numeric(model$surv)
+ ul <- as.numeric(model$upper)
+ ll <- as.numeric(model$lower)
+ df <- data.frame(time, surv, cen, ul, ll, group = strata)
+ for(i in 1 : groups){
+   row <- c(0, 1, 0, 1, 1, i)
+   df <- insertRow(existingDF = df, newrow = row,
+                   r = match(x = i, table = df$group))
+ }
+ df$group <- factor(df$group, labels = group)
+ return(df)
+ }
+ }

```

Spremenljivko **kb** sem uporabil za Boltzmannovo konstanto izraženo v eV/K.

```
> kb <- 8.6173324 * 10^-5
```

Funkcija **Ea3** izračuna aktivacijsko energijo, frekvenco dogodkov, pred-eksponentni faktor ter srednji čas do odpovedi pri izbrani temperaturi **T0**.

```

> Ea3 <- function(nu1, nu2, T1, T2, T0) {
+   Ea <- -kb * (log(nu2/nu1)) / (1/ctk(T2) - 1/ctk(T1))
+   nu0 <- nu2 / exp(-Ea / (kb * ctk(T2)))
+   nu <- nu0 * exp(-Ea / (kb * ctk(T0)))
+   est.MTTF <- 1 / nu
+   rez <- c(Ea, nu0, nu, est.MTTF)
+   names(rez) <- c("Ea", "nu0", "nu", "est.MTTF")
+   return(round(rez, c(3, 0, 6, 0)))
+ }

```

Funkcija **ctk** pretvori stopinje Celzija v Kelvine, **ktc** pa Kelvine v stopinje Celzija.

```

> ctk <- function(TC){
+   return(TC + 273.15)
+ }
> ktc <- function(TK){
+   return(TK - 273.15)
+ }

```

Funkcija `setStatus` določi status varistorju: ali je odpovedal ali ne. Tvorijo tudi zapis podatkov v tabeli A.1.

```

> setStatus <- function(data){
+   data$dVn.over <- FALSE
+
+   if(!("dur.h" %in% names(data))){
+     data <- transform(data, dur.h = round(dur / 3600))
+   }
+
+   for(i in 1 : nrow(data)){
+     iData <- data[i, ]
+     data[i, "dVn.over"] <- iData$dVn <= -9
+   }
+
+   df <- data.frame()
+
+   vars <- c("id", "dur.h", "dVn.over")
+
+   for(i in 1 : 40){
+     iData <- subset(data, id == i, vars)
+
+     # Varistor Vn drops for over 10%
+     idx <- which(iData$dVn.over == TRUE)[1]
+
+     if(!is.na(idx)){
+       dVnOver <- iData[idx, vars]
+       dVnOver$cen <- 1
+       dVnOver$dur <- dVnOver$dur.h
+
+       df <- rbind(df, dVnOver)
+     } else {
+       cen <- iData[nrow(iData), vars]
+       cen$cen <- 0
+       cen$dur <- max(iData$dur.h)
+
+       df <- rbind(df, cen)
+     }
+   }
+ }

```

```
+ }
+ df <- cbind(subset(data, dur == 0, c("Vn", "Idc", "alfa")), df)
+ return(df[, c("id", "Vn", "Idc", "alfa", "cen", "dur")])
+ }
```

Funkcija `plotLine` nariše trenutno stanje vzorca pri izbranem parametru. Možnosti so "dVn" ali "Idc". S to funkcijo je bila narejena hitra ocena, kdaj bo kakšen varistor odpovedal.

```
> plotLine <- function(data, mode = "Idc"){
+   require(ggplot2)
+
+   data$idc.over <- FALSE
+   data$idc.over100 <- FALSE
+   data$dVn.over <- FALSE
+   data[which(data$dVn <= -15), "dVn"] <- -15
+
+   for(i in 1 : nrow(data)){
+     idata <- data[i, ]
+
+     data[i, "idc.over"] <- idata$Idc > data[which(data$id == idata$id), ][1, "Idc"]
+     data[i, "idc.over100"] <- idata$Idc >= 100
+     data[i, "dVn.over"] <- idata$dVn <= -9
+   }
+
+   dVnOver <- subset(data, dVn.over == TRUE)
+   idcOver <- subset(data, idc.over == TRUE)
+   idcOver100 <- subset(data, idc.over100 == TRUE)
+
+   cols <- gg_color_hue(3)
+
+   switch (mode,
+     Idc = {
+       # line chart for Idc
+       ggplot(data, aes(x = dur.h, y = Idc)) +
+         geom_point() + geom_line() +
+         facet_wrap(~id, nrow = 4) + theme_bw() +
+         geom_point(data = idcOver, col = cols[3], size = 2) +
+         geom_point(data = idcOver100, col = cols[2], size = 3) +
+         geom_point(data = dVnOver, col = cols[1], size = 4)
+     },
+     dVn = {
+       # line chart for dVn
+       ggplot(data, aes(x = dur.h, y = dVn)) +
```



```

+     geom_point() + geom_line() +
+     facet_wrap(~id, ncol = 10) +
+     geom_hline(aes(yintercept = -10), linetype = "dashed", col = "red") +
+     theme_bw() + geom_point(data = idcOver, col = cols[3], size = 2) +
+     geom_point(data = idcOver100, col = cols[2], size = 3)
+   },
+   Vn_Idc = {
+     # Vn ~ Idc
+     ggplot(data, aes(Idc, Vn)) +
+       theme_bw() + geom_point() +
+       geom_hline(aes(yintercept = df$Vn[1] * 0.9), linetype = "dashed", col = "red") +
+       geom_hline(aes(yintercept = df$Vn[1] * 1.1), linetype = "dashed", col = "red") +
+       scale_x_log10(limits = c(0.01, 1000), breaks = c(1, 10, 100, 1000)) +
+       facet_wrap(~id, ncol = 10)
+   },
+   {print("default")}
+ )
+ }

```

Funkcija $S.W$ izračuna verjetnost preživetja ob času t , če sta znana parametra la in parameter oblike g . Funkcija $f.w$ predstavlja gostoto Weibullove porazdelitve.

```

> S.W <- function(t, la, g){
+   S <- exp( - (la * t)^g)
+   return(S)
+ }
> f.w <- function(x, b, n){
+   return(x * (b / n * (x / n)^(b - 1) * exp( - (x / n)^b)))
+ }

```

Funkcija `plotResiduals` nariše ostanke linearnih in posplošenih linearnih modelov s paketom `ggplot2`.

```

> plotResiduals <- function(object) {
+   require(ggplot2)
+   require(gridExtra)
+
+   dfg <- fortify(object)
+   g1 <- ggplot(dfg, aes(.fitted, .resid)) + theme_bw() +
+     geom_point() + geom_hline(yintercept = 0, linetype = "dashed") +
+     geom_smooth(se = FALSE) + ylab("Residuals") + xlab("Fitted values") +

```

```
+ ggtitle("Residuals vs Fitted")
+
+ g2 <- ggplot(dfg, aes(.fitted, sqrt(abs(.stdresid)))) + theme_bw() +
+   geom_point() + geom_hline(yintercept = 0, linetype = "dashed") +
+   geom_smooth(se = FALSE) +
+   ylab(expression(sqrt(abs("Standardized residuals")))) +
+   xlab("Fitted values") + ggtitle("Scale-Location")
+
+ g3 <- qplot(sample = .stdresid, data = dfg, stat = "qq") + geom_abline() +
+   theme_bw() + ylab("Standardized residuals") + xlab("Theoretical Quantiles") +
+   ggtitle("Normal Q-Q")
+
+ g4 <- ggplot(dfg, aes(.hat, .stdresid)) +
+   geom_vline(size = 2, colour = "white", xintercept = 0) +
+   geom_hline(size = 2, colour = "white", yintercept = 0) +
+   geom_point(aes(size = .cooks) + geom_smooth(se = FALSE) +
+   theme_bw() + theme(legend.position = "none") +
+   ylab("Standardized residuals") + xlab("Leverage") +
+   ggtitle("Residuals vs Leverage")
+
+ grid.arrange(g1, g3, g2, g4)
+ }
```

D Literatura

- [1] PowerGuru, "Introduction to metal oxide varistors." Dosegljivo: <http://www.powerguru.org/introduction-to-metal-oxide-varistors/>. [Dostopano: 29. 6. 2015].
- [2] M. Topič, *Zanesljivost in vzdrževanje komponent in sistemov*. Založba FE in FRI, 5. dopolnjena izd., 2009.
- [3] K. J. Brown, "Metal oxide varistor degradation," *IAEI NEWS*, 2004.
- [4] T. M. Bajenescu in M. I. Bazu, *Reliability of electronic components: a practical guide to electronic systems manufacturing*. Springer, 1999.
- [5] Wikipedija, "Aktivacijska energija." Dosegljivo: https://sl.wikipedia.org/wiki/Aktivacijska_energija. Dostopano: 18. 9. 2015.
- [6] M. A. Aitkin, B. Francis, J. Hinde in R. Darnell, *Statistical modelling in R*. Oxford University Press Oxford, 2009.
- [7] J. Fox in S. Weisberg, *An R Companion to Applied Regression*. Thousand Oaks CA: Sage, druga izd., 2011.
- [8] R. S. Kenett in S. Zacks, *Modern Industrial Statistics*. Wiley, 2. izd., 2014.
- [9] K. Košmelj in D. Kastelec, "Linearni regresijski modeli." Neobjavljeno delo, 2014.
- [10] D. G. Kleinbaum in M. Klein, *Survival Analysis, A self-Learning Text*. Springer, 3. izd., 2012.

-
- [11] M. J. Crawley, *The R Book*. Wiley, 2007.
- [12] Keithley Instruments, Inc., *Series 2400 SourceMeter, Quick Start Guide*, 2400s-903-01 izd., October 2007.
- [13] T. M. Therneau, *A Package for Survival Analysis in S*, 2015. version 2.38.
- [14] M. P. Perne, "Analiza zgodovine dogodkov." Neobjavljeno delo, 2014.
- [15] E. Santiago, "How to compute the confidence intervals for mean time to failure." Dosegljivo: <http://it.minitab.com/support/documentation/Answers/MTTF.pdf>. Dostopano: 23. 10. 2015.
- [16] F. E. H. Jr, *rms: Regression Modeling Strategies*, 2015. R package version 4.3-1.
- [17] D. B. Dahl, *xtable: Export tables to LaTeX or HTML*, 2014. R package version 1.7-4.
- [18] M. Hlavac, *stargazer: Well-Formatted Regression and Summary Statistics Tables*. Harvard University, Cambridge, USA, 2015. R package version 5.2.
- [19] H. Wickham, *ggplot2: elegant graphics for data analysis*. Springer New York, 2009.
- [20] R Core Team, *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2015.
- [21] H. Wickham, *stringr: Simple, Consistent Wrappers for Common String Operations*, 2015. R package version 1.0.0.
- [22] B. Schloerke, J. Crowley, D. Cook, H. Hofmann, H. Wickham, F. Briatte, M. Marbach in E. Thoen, *GGally: Extension to ggplot2.*, 2014. R package version 0.5.0.
- [23] P. Macdonald in with contributions from Juan Du, *mixdist: Finite Mixture Distribution Models*, 2012. R package version 0.5-4.