Modeliranje rasta poduzeća u Hrvatskoj: analiza panel podataka

Blažević, Andrijana

Master's thesis / Diplomski rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Department of Mathematics / Sveučilište Josipa Jurja Strossmayera u Osijeku, Odjel za matematiku**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:126:245630

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**



Repository / Repozitorij:

Repository of School of Applied Mathematics and Computer Science







Sveučilište J.J. Strossmayera u Osijeku
Odjel za matematiku

Andrijana Blažević

Modeliranje rasta poduzeća u Hrvatskoj: analiza panel podataka

Diplomski rad

Osijek, 2020.

Sveučilište J.J. Strossmayera u Osijeku
Odjel za matematiku

Andrijana Blažević

Modeliranje rasta poduzeća u Hrvatskoj: analiza panel podataka

Diplomski rad

Mentor: prof.dr.sc. Nataša Šarlija
Komentor: prof.dr.sc. Mirta Benšić

Osijek, 2020.

Sadržaj

Uvod **1**

1 Linearna regresija **2**

2 Analiza i modeliranje panel podataka **4**
2.1 Panel podaci 4
2.2 Vrste modela 5
2.2.1 Združeni model 6
2.2.2 Model fiksnih efekata 7
2.2.3 Model slučajnih efekata 7
2.3 Statistički testovi za odabir modela 8
2.3.1 Lagrangeov multiplikacijski test 8
2.3.2 F test 9
2.3.3 Hausmanov test 10

3 Emprijsko istraživanje: Modeliranje rasta poduzeća u Hrvatskoj **11**
3.1 Čimbenici rasta poduzeća 11
3.2 Opis varijabli i podataka za modeliranje rasta poduzeća u Hrvatskoj 13
3.3 Analiza čimbenika rasta poduzeća u Hrvatskoj 21
3.4 Model logističke regresije za procjenu insolventnosti poduzeća u Hrvatskoj 22
3.5 Panel modeli rasta poduzeća u Hrvatskoj 27

4 Zaključak **33**

Sažetak **36**

Title and summary **37**

Životopis **38**

Uvod

U ovom radu bavit ćemo se posebnom strukturom podataka, tzv. panel podacima. Možemo ju smatrati relativno novom strukturom. U članku *Analiza panel podataka-prednosti i izazovi* (2007.) [10] autor C.Hsiao[1] navodi da je se tek nakon objave objave rada P.Balestre[2] i M.Nerlovea[3] pod nazivom *Podaci poprečnog presjeka i vremenski nizovi u procjeni dinamičkog modela: potražnja za prirodnim plinom*[1] iz 1966., dogodio nevjerojatan rast primijenjenih studija i metodološki razvoj novih ekonometrijskih alata panel podataka.

Kako bismo proučili teorijsku pozadinu modela za ovaj tip podataka i pokazali primjenu razvijenih metoda za njihovu analizu, naš rad će se sastojati od dva dijela.

Za početak ćemo definirati linearnu regresiju koja je osnova za daljnji razvoj panel modela. U trećem poglavlju dorađujemo linearnu regresiju i obrađujemo tri vrste modela: model konstantnih koeficijenata, model fiksnih efekata i model slučajnih efekata. Nakon toga analizirat ćemo statističke testove za odabir modela, odnosno postojanje individualnih efekata, te ćemo njihovu ulogu pokazati u empirijskom dijelu.

Cilj emprijskog dijela rada je istražiti vezu između insolventnosti i rasta poduzeća. Istraživanje ćemo provesti na reprezentativnom uzorku poduzeća koja posluju u Hrvatskoj. Insolventnost, odnosno nemogućnost plaćanja, je zabilježena kao binomna varijabla čiju vjerojatnost ćemo modelirati logističkom regresijom i definirati kao novu varijablu.
Za definiciju rasta poduzeća uzet ćemo veličinu EBIT koja mjeri razliku između poslovnih prihoda i rashoda.
Objasnit ćemo financijske pokazatelje sadržane u našoj bazi te ćemo među njima tražiti one koje najbolji opisuju rast i insolventnost. Za dobivene modele analizirat ćemo jesu li odabrane varijable i njihovi efekti teorijski podržani.
Sumirat ćemo dobivene rezultate te ćemo opravdati naš odabir.

[1] Cheng Hsiao-Odjel za ekonomiju, Sveučilište u Južnoj Kaliforniji, SAD, Wang Yanan institut za studije ekonomije, Sveučilište Xiamen, Kina. Autor knjige Analysis of Panel Data

[2] Pietro Balestra-švicarski ekonomist specijaliziran za ekonometriju

[3] Marc Nerlove-američki je ekonomist specijaliziran za poljoprivrednu ekonomiju i ekonometriju

1 Linearna regresija

Veliki dio primijenjene ekonometrijske analize započinje sljedećom pretpostavkom: neka su varijabla Y i jedna ili više varijabli označene sa X varijable neke populacije. Zanima nas kako objasniti Y u terminima X, odnosno, kako Y varira s promjenama u X. Najjednostavnija veza bi bila linearna te se upravo taj koncept naziva linearnom regresijom.

Definicija 1.1 *Neka su $X_1, \ldots, X_K$ neovisne varijable i Y zavisna varijabla mjerena u ovisnosti o $X = (X_1, \ldots, X_K)$. Linearni model koji opisuje vezu zavisne o neovisnim varijablama zadan je sa*

$$Y = \alpha + \beta_1 X_1 + \cdots + \beta_K X_K + \epsilon \tag{1}$$

gdje je ϵ slučajna varijabla koja predstavlja grešku i $\alpha, \beta_1, \ldots, \beta_K$ nepoznati koeficijenti modela (1).

Ako bismo htjeli pronaći vezu temeljenu na N promatranja, model (1) možemo proširiti u sustav jednadžbi na sljedeći način;

$$Y_i = \alpha + \beta_1 X_{1i} + \cdots + \beta_K X_{Ki} + \epsilon_i, \quad i = 1, \ldots, N \tag{2}$$

odnosno

$$\begin{aligned} Y_1 &= \alpha + \beta_1 X_{11} + \cdots + \beta_K X_{K1} + \epsilon_1 \\ &\vdots \\ Y_N &= \alpha + \beta_1 X_{1N} + \cdots + \beta_K X_{KN} + \epsilon_N \end{aligned} \tag{2.1}$$

Važna pretpostavka je nezavisnost po mjerenjima, tj. podaci korišteni za procjenu regresijskog modela dolaze iz nezavisnog slučajnog uzorka s N mjerenja. To je najbolje izraziti kao nezavisnost slučajnih vektora $(Y_i, X_{i1}, ..., X_{iK})$, $i = 1, \ldots, N$.
Također, u uzorku ne smiju postojati linearne veze među neovisnim varijablama, odnosno multikolinearnost.
Iduće dvije pretpostavke se odnose na vezu regresora i greške modela.[19]

- $E[\epsilon_i | X_i] = 0$ (uvjetno očekivanje greške je neovisno o vrijednosti X)

- $E[{\epsilon_i}^2 | X_i] = {\sigma_\epsilon}^2$ (homoskedastičnost)

Sustav 2.1 možemo zapisati i pomoću matrica

$$Y = \Lambda\beta + \epsilon$$

gdje su

$$Y = [Y_1, \ldots, Y_N]^T$$

$$\Lambda = \begin{bmatrix} 1 & X_{11} & \cdots & X_{K1} \\ 1 & X_{12} & \cdots & X_{K2} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & X_{1N} & \cdots & X_{KN} \end{bmatrix}$$

$$\beta = [\alpha, \beta_1, \ldots, \beta_K]^T, \quad \epsilon = [\epsilon_1, \ldots, \epsilon_N]^T$$

Sada nailazimo na problem procjene parametara modela. Najpoznatija i najčešće korištena je metoda najmanjih kvadrata (Ordinary Least Square OLS) koja se temelji na minimizaciji sume kvadrata reziduala. Rezidual e se definira kao razlika izmjerene, y, i teorijske vrijednosti od Y, $\hat{y}$, tj.

$$e_i = y_i - \hat{y}_i$$

Minimiziramo sljedeći izraz po parametru β :

$$e^T e = \sum_{i=1}^{N} e_i^2 = \sum_{i=1}^{N} (y_i - \hat{y}_i)^2 = \sum_{i=1}^{N} (y_i - \alpha - \beta_1 x_{1i} - \cdots - \beta_K x_{Ki})^2$$

gdje su x_{ki} izmjerene vrijednosti neovisnih varijabli X_{ki}.
Dobijemo da se minimum postiže u točki

$$\hat{\beta} = (x^T x)^{-1} x^T y.$$

Prema Gauss-Markovom teoremu

$$\hat{\beta} = (X^T X)^{-1} X^T Y$$

je najbolji linearni nepristrani procjenitelj $(BLUE)$ ukoliko model zadovoljava sljedeće pretpostavke [17]:

- $E[\epsilon_i] = 0, \quad i = 1, \ldots, N$
- $E[{\epsilon_i}^2] = \sigma_\epsilon^2, \quad i = 1, \ldots, N$ (homoskedastičnost)
- $Cov(\epsilon_i, \epsilon_j) = E[\epsilon_i \epsilon_j] = 0, \quad i \neq j$ (nepostojanje autokorelacije greške)
- $Cov(X_{ki}, \epsilon_i) = E[X_{ki} \epsilon_i] = 0, \quad k = 1, \ldots, K$ (nekoreliranost greške i regresora)

Česta je pretpostavka normalne distribuiranosti slučajne greske ϵ_i koja povlači i normalnu distribuciju procjenitelja $\hat{\beta}_k$ pri čemu je uvjetno očekivanje β_k, a uvjetna varijanca $\sigma_\epsilon^2 (x^T x)_{kk}^{-1}$.

2 Analiza i modeliranje panel podataka

U ovom poglavlju definirat ćemo strukturu podataka za varijable $(Y, X_1, ..., X_K)$ koja ima i vremensku komponentu. To znači da se mora odustati od pretpostavke nezavisnosti u modelu $(Y_i, X_{1i}, ..., X_{Ki})$, $i = 1, ..., N$. To je svojevrsni spoj linearne regresije i vremenskog niza i kao takvi su vrlo bitni u ekonometriji. Nastavak ovog diplomskog rada bit ce posvećen isključivo panel podacima i metodama modeliranja istih.

2.1 Panel podaci

Cross podaci su struktura podataka promatranih jedinki prikupljenih u jednoj vremenskoj jedinici (Tablica1). Vremenski nizovi bilježe podatke o jednoj ili više varijabli kroz niz vremenskih trenutaka koji mogu, ali ne moraju biti ekvidistantni (Tablica 2). Kada bismo ih spojili u novi tip, dobili bismo združene podatke. Posebna vrsta takvih podataka, koja opisuju iste vremenski presječne jedinice u istim vremenskim trenucima, zovemo panel podacima.

poduzeće	sektor	broj zaposlenih	plaća	kapital	proizvodnja
1	7	19,156	22,692	7,0975	91,4273
2	3	71,319	14,7909	16,9363	90,6629
3	8	5,041	13,1516	0,5894	95,0002
4	8	26,16	14,8283	8,4902	118,2223
5	7	1,65	28,555	0,933	107,4791
6	3	0,766	20,5393	0,1618	107,027
7	5	87,1	18,2782	22,2703	96,5038

Tablica 1: Primjer cross-podataka

godina	sektor	broj zaposlenih	plaća	kapital	proizvodnja
1969	7	4,715	4,715	4,715	4,715
1970	7	5,6	12,3018	0,6318	97,3569
1971	7	4,093	14,2897	0,5076	99,5581
1972	7	2,936	13,7784	0,392	100,0301
1973	7	5,015	12,8395	0,6771	99,6083
1974	7	3,166	14,8681	0,4229	98,6151
1975	7	5,041	13,1516	0,5894	95,7072

Tablica 2: Primjer vremenskih podataka

poduzeće	godina	sektor	broj zaposlenih	plaća	kapital	proizvodnja
1	1970	7	5,6	12,3018	0,6318	97,3569
1	1971	7	4,093	14,2897	0,5076	99,5581
1	1972	7	2,936	13,7784	0,392	100,0301
2	1970	3	71,319	14,7909	16,9363	90,6629
2	1971	3	72,918	14,9534	17,5413	99,6083
2	1972	3	69,815	13,2716	16,9363	88,7072
3	1970	8	5,041	13,1516	0,5894	95,0002
3	1971	8	19,156	22,692	7,0975	95,7072
3	1972	8	19,44	20,6938	6,9469	97,3569

Tablica 3: Primjer panel podataka

Panel podaci se mogu dijeliti prema kriteriju raspoloživosti na balansirane i nebalansirane. Ukoliko imamo balansirane znači da je svaka promatrana jedinica promatrana jednak broj puta, tj. vremenski niz svake promatrane jedinice je jednake duljine i ukupno ćemo imati NT promatranja. U slučaju da za neku jedinku nedostaju podaci za neku varijablu u nekom razdoblju, radit će se o nebalansiranim podacima.

2.2 Vrste modela

Kod modela vremenskih nizova (na primjer autoregresivnog reda p) koriste se regresije na neki od prošlih trenutaka. Pretpostavka modela koje ćemo u nastavku obraditi je da ne postoji autokorelacija tj. sadašnja vrijednost neke varijable ne ovisi o njenoj prethodnoj vrijednosti. Takvi modeli se nazivaju statičkim modelima.
Opći linearni panel model je oblika

$$Y_{it} = \alpha_{it} + \beta_{1,it}X_{1,it} + \cdots + \beta_{K,it}X_{K,it} + \epsilon_{it}, \quad i = 1, \ldots, N, \quad t = 1, \ldots, T \tag{3}$$

odnosno

$$Y_{it} = \alpha_{it} + X_{it}^T\beta_{it} + \epsilon_{it}, \quad i = 1, \ldots, N, \quad t = 1, \ldots, T \tag{4}$$

gdje je N broj promatranih jedinica i T broj jedinica vremena. α_{it} je slobodni član i-te jedinice promatrane u trenutku t, $\beta_{k,it}$ su nepoznati koeficijenti regresije, a ϵ_{it} je slučajna greška koja ima očekivanje 0 i varijancu σ_ϵ^2.

U ovakvom modelu je pretpostavka da sve jedinice promatranja i imaju međusobno različite veze s neovisnim varijablama, s tim da se i za svako promatranje i ta veza razlikuje i kroz vrijeme. To znači da za ovakav model moramo procijeniti $NT(K+1)$ parametara, sto je veće od NT podataka s kojima raspolažemo. Da bi se riješio ovaj problem moraju se uvesti određene pretpostavke i ograničenja na model.

Prvo cemo pretpostaviti da su parametri $\beta_{k,it}$ koji pripadaju neovisnim varijablama, konstantni za svaku promatranu jedinku i za svaki vremenski trenutak, odnosno

$$\beta_{k,it} = \beta_k, \quad \text{za sve } i = 1, \ldots, N, \quad t = 1, \ldots, T$$

a slobodne komponente α_{it} ostavljamo kao slučajne varijable. Kako se ne bi narušila heterogenost među promatranim jedinicama i vremenskih trenutaka, α_{it} će obuhvatiti efekt varijabli koje nisu direktno uvrštene u model. Regresore ćemo procjenjivati pomoću tri modela: združenog modela, modela fiksnih efekata, modela slučajnih efekata.

2.2.1 Združeni model

Poznat i kao *pooled model* i *model konstantnih koeficijenata*. Temelj ovoga modela je pretpostavka da imamo sve parametre nepromjenjive, odnosno zanemaruje da se radi o N promatranih jedinica kroz T vremenskih trenutaka i spaja ih u NT cross-podataka. Možemo ga zapisati na sljedeći način:

$$Y_{it} = \alpha + X_{it}^T \beta + \epsilon_{it}, \quad i = 1, \ldots, N, \quad t = 1, \ldots, T \tag{5}$$

gdje je X_{it} vektor regresora, β vektor parametara i ϵ_{it} slučajna greška s očekivanjem 0 i varijance σ^2. Vidimo da su slobodni član α i vektor parametara β nepromjenjivi, jednaki su za sva promatranja.
Ukoliko ne možemo pretpostaviti da je fiksni slobodni član konstantan za sve jedinice promatranja, i da je efekt bilo koje neovisne varijable na zavisnu konstantan kroz sva promatranja, onda nije preporučljivo koristiti ovaj model.
Model konstatnih koeficijenata leži na četiri teorijske pretpostavke[8]:

- $E[X_{it}\epsilon_{it}] = 0$, za svaki i,t (nekoreliranost greške s regresorima u istom vremenskom trenutku-egzogenost)

- $E[\epsilon_{it}^2] = \sigma^2$ za svaki i, t (stroga homoskedastičnost)

- $E[\epsilon_{it}\epsilon_{js}] = 0, \quad i \neq j, \ t \neq s, \ \forall i, j = 1, ..., N, \ s, t = 1, ..., T$ (nepostojanje autokorelacije greške)

- matrica X je punog ranga (nema multikolinearnosti)

2.2.2 Model fiksnih efekata

Ideja modela fiksnih efekata je uvesti novi član α_i, koji predstavlja individualni efekt za svaku promatranu jedinicu i konstantan je u vremenu;

$$Y_{it} = \alpha + \alpha_i + \beta_1 X_{1,it} + \cdots + \beta_K X_{K,it} + \epsilon_{it}, \quad i = 1, \ldots, N,\ t = 1, \ldots T \tag{6}$$

$\epsilon_{it} \sim N(0, \sigma_\epsilon^2)$ slučajna greška, a α_i slučajna varijabla koja opisuje utjecaj i-te jedinke.
Iz prvog modela ponavljaju se pretpostavke su da su greške međusobno nekorelirane

$$Cov(\epsilon_{it}, \epsilon_{js}) = E[\epsilon_{it}\epsilon_{js}] = 0, \quad \forall i, j = 1, ..., N,\ s, t = 1, ..., T$$

i da su greške i neovisne varijable nekorelirane

$$Cov(X_{k,it}, \epsilon_{it}) = E[X_{k,it}\epsilon_{it}] = 0.$$

Međutim, budući da se u modelu fiksnih učinaka dopušta korelacija individualnih efekata i neovisnih varijabli [14],

$$Cov(X_{k,it}, \alpha_i) \neq 0 \tag{*}$$

OLS procjenitelj može biti pristran. Zato u modelu fiksnih efekata postoje različite metode procjena: korištenje pomoćnih (tzv. dummy) varijabli, transformacija podataka unutar jedinica promatranja i metoda prvih razlika. [18]

Princip metode pomoćnih (dummy) varijabli je da se za svaku promatranu jedinku uvede indikator sa specifičnim efektom te model (6) dobiva sljedeći oblik:

$$Y_{it} = \sum_{j=1}^{N} \alpha_j d_{ij} + \beta_1 X_{1,it} + \cdots + \beta_K X_{K,it} + \epsilon_{it}, \quad d_{ij} = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \tag{7}$$

Sada α_j možemo promatrati kao parametar uz slučajnu varijablu.
Ako je u modelu prisutna konstanta, broj dummy varijabli trebao bi biti N-1. Ispuštena jedinka postaje referentna kategorija. [21]
Ovakva metoda se naziva metodom najmanjih kvadrata s dummy varijablama (engl. Least Squers Dummy Variables, LSDV).

2.2.3 Model slučajnih efekata

Temelj ovoga modela je pretpostavka da se individualni efekt α_i koji je promjenjiv, može smatrati dijelom slučajne greške:

$$Y_{it} = \alpha + X_{it}^T \beta + u_{it}, \quad i = 1, ..., N,\ t = 1, ..., T \tag{8}$$

$$u_{it} = \alpha_i + \epsilon_{it}, \quad \alpha_i \sim N(0, \sigma_\alpha^2),\ \epsilon_{it} \sim N(0, \sigma_\epsilon^2)$$

Model slučajnih efekata (8) je zbog rastava slučajne greške u_{it} nazvan i modelom komponenti slučajne greške. Bitne pretpostavke modela su:

- $E[\alpha_i \alpha_j] = E[\epsilon_{it}\epsilon_{js}] = E[\alpha_i \epsilon_{it}] = 0$ (nekoreliranost komponenti greške)

- $Cov(\alpha_i, X_{k,it}) = 0,\ Cov(\epsilon_{is}, X_{k,it}) = 0$ (nekoreliranost komponenti s neovisnim varijablama)

Iz rastava u_{it} slijedi da je

$$\begin{aligned} E(u_{it}) &= E(\alpha_i + \epsilon_{it}) = E(\alpha_i) + E(\epsilon_{it}) = 0 \\ Var(u_{it}) &= Var(\alpha_i + \epsilon_{it}) = Var(\alpha_i) + Var(\epsilon_{it}) = {\sigma_\alpha}^2 + {\sigma_\epsilon}^2 \\ Cov(u_{it}, X_{k,it}) &= 0 \\ Cov(u_{it}, u_{js}) &= \begin{cases} {\sigma_\alpha}^2 + {\sigma_\epsilon}^2,\ i = j, t = s \\ {\sigma_\alpha}^2,\ i = j, t \neq s \\ 0,\ \text{inače} \end{cases} \end{aligned}$$

Uočimo da je u modelu fiksnih efekata je bila dopuštena koreliranost individualnih efekata i regresora (svojstvo *). Ovdje to nije slučaj.
Kako greška u_{it} ovisi o vremenski varijabilnoj komponenti t, ali i o vremenski konstantnoj komponenti α_i, one sada postaju korelirane što znači da OLS metoda neće dati efikasnog procjenitelja. Rješenje problema se nalazi u generaliziranoj metodi najmanjih kvadrata GLS, kojom se eliminira korelacija greški istih jedinica promatranja.

2.3 Statistički testovi za odabir modela

Kada kod izbora modela imamo više mogućnosti, važno je provesti testove koji će nam pomoći odlučiti koji je model bolji i kvalitetniji. U (2.2) smo naveli tri modela. S jedne strane imamo model konstantnih koeficijenata koji ne sadrži individualne efekte, a s druge model fiksnih i slučajnih efekata koji ih sadrže.
Da bi se mogao odabrati prigodni model prvo moramo znati postoje li individualni efekti. Obradit ćemo tri testa: LM test (usporedba združenog i modela slučajnih efekata), F test (usporedba združenog i modela fiksnih efekata) i Hausman test (usporedba modela slučajnih i modela fiksnih efekata).

2.3.1 Lagrangeov multiplikacijski test

LM testom uspoređujemo združeni model i model slučajnih efekata. U potpoglavlju (2.2.3) smo naveli bitnu pretpostavku da je $\alpha_i \sim N(0, \sigma_\alpha^2)$, $\sigma_\alpha^2 > 0$. Hipoteze testa su definirane na način

$$\begin{aligned} H_0: &\quad \sigma_\alpha^2 = 0 \text{ (ne postoje individualni efekti)} \\ H_1: &\quad \sigma_\alpha^2 \neq 0 \text{ (postoje individualni efekti)} \end{aligned}$$

a statistika kao

$$LM = \frac{NT}{2(T-1)} \left[\frac{\sum_{i=1}^{N} (\sum_{t=1}^{T} e_{it})^2}{\sum_{i=1}^{N} \sum_{t=1}^{T} e_{it}^2} - 1 \right]^2$$

LM statistika koristi reziduale modela konstatnih koeficijenata, e_i. U uvjetima istinitosti nul-hipoteze $LM \sim \chi^2(1)$ i možemo koristiti združeni model. U suprotnom biramo model slučajnih efekata.

2.3.2 F test

Provjeriti prikladnost združenog modela i modela fiksnih efekata možemo uz pomoć F-testa. F-test će nam potvrditi postoje li individualni efekti. Hipoteze testa su

$$\begin{aligned} H_0: &\quad \alpha_1 = \cdots = \alpha_{N-1} = 0 \\ H_1: &\quad \alpha_i \neq 0 \text{ za barem jedan } i \end{aligned}$$

Nul-hipoteza tvrdi da su svi osim jednog individualnog koeficijenta jednaki nuli. Formula statistike kojom se provodi test je

$$F = \frac{(SSE_{pooled} - SSE_{fixed})/(N-1)}{(SSE_{fixed})/(NT-N-K)}$$

- SSE_{pooled} = suma kvadrata reziduala združenog modela

- SSE_{fixed} = suma kvadrata reziduala modela fiksnih efekata procijenjenog LSDV metodom

U uvjetima istinitosti nul-hipoteze statistika $F \sim F(N-1,\ NT-N-K)$. Ako bismo testiranjem dobili da se nul-hipoteza ne odbacuje, odabrat ćemo model konstatnih koeficijenata. U slučaju odbacivanja H_0 dolazimo do zaključka da je adekvatniji model fiksnih efekata.

U slučaju nebalansiranih panel podataka potrebne su manje izmjene u izračunu F statistike. [8]
Općenito, $SSE = \sum_{i=1}^{n} \hat{e}_i^2$ gdje je n broj promatranja. Kod balansiranih podataka taj n iznosi NT, dok kod nebalansiranih $n = \sum_{i=1}^{N} T_i$, gdje je T_i broj pojavljivanja i-te jedinke.
Stoga u formuli F statistike umjesto NT pišemo n. Unatoč tim razlikama koje su ranije predstavljale izazov u izračunima, današnji softveri s lakoćom rješavaju taj problem.

2.3.3 Hausmanov test

Opća ideja Hausmanovog testa je da se uspoređuju dva procjenitelja: onaj koji je konzistentan i pod nultom i alternativnom hipotezom i onaj koji je konzistentan (i efikasan) samo pod nultom hipotezom. Hipoteze Hausmanovog testa su

$$\begin{aligned} H_0: &\quad Cov(\alpha_i, X_{k,it}) = 0 \quad \forall k = 1, \ldots, K \\ H_1: &\quad Cov(\alpha_i, X_{k,it}) \neq 0 \text{ za neki } k \end{aligned}$$

Uočimo da je H_0 zapravo jedna od dvije bitne pretpostavke modela slučajnih efekata (2.2.3). Bit Hausmanovog testa je testiranje postoji li značajna razlika između dva procjenitelja, a razlika dolazi iz koreliranosti α_i i $X_{k,it}$. Hausmanova statistika je oblika

$$H = (\hat{\beta}_{rand} - \hat{\beta}_{fix})^T [Var(\hat{\beta}_{rand}) - Var(\hat{\beta}_{fix})]^{-1} (\hat{\beta}_{rand} - \hat{\beta}_{fix})$$

Gdje su $\hat{\beta}_{rand}$ i $\hat{\beta}_{fix}$ procijene parametra β za redom slučajne $(random)$ i fiksne $(fixed)$ efekte, pri tom je za procjenu $\hat{\beta}_{fix}$ koristena metoda "unutar grupe", a za $\hat{\beta}_{rand}$ GLS metoda. Ako je H_0 istinita onda $H \sim \chi^2(K)$. Ukoliko ne odbacujemo nul-hipotezu biramo model slučajnih efekata.

3 Emprijsko istraživanje: Modeliranje rasta poduzeća u Hrvatskoj

Rast poduzeća se može mjeriti na različite načine, kroz rast broja zaposlenika, rast prihoda, prodaje, rast veličine asortimana proizvoda, rast tržišta, itd[16]. Budući da se može mjeriti na više načina i ne postoji jedinstvena definicija rasta, mi ćemo rast pratiti kroz EBIT (earnings before interests and taxes) odnosno kao dobit poduzeća prije kamata i poreza. U ovom radu smo se odlučili za mjerenja rasta na taj način zato što želimo istražiti na koji način vjerojatnost za insolventnost utječe na rast dobiti prije poreza i kamata.

Zašto postoji interes za rastuća poduzeća i tko je zainteresiran? Rastuća poduzeća su u mogućnosti osigurati nova radna mjesta, dati bolji povrat javnih uloga i investicija te povećati izvozni potencijal. Stoga su za njih zainteresirani ulagači, bankari, vlada, lokalne vlasti i drugi.

Kako bi se mogao modelirati rast poduzeća, potrebno je otkriti koje varijable i na koji način utječu na rast.

3.1 Čimbenici rasta poduzeća

2010. godine Kjell Bjørn Nordal i Randi Næs su objavili rezultate istraživanja veze između rizika bankrota i rasta poduzeća [3]. Istraživanje provedeno na podacima o norveškim poduzećima u razdoblju od 1988. do 2007. pokazalo je da su karakteristike poduzeća s visokim rizikom bankrota slične karakteristikama poduzeća s očekivanim velikim rastom prodaje. Zajednički pokazatelji su bili nizak omjer kapitala i ukupne imovine, niska trenutna profitabilnost i trenutačno niska razina prihoda od kapitala. U dobivenom modelu za vjerojatnost bankrota značajnim su se pokazali obrt imovine, zadržana dobit, ROA, veličina i omjera kapitala. Sve varijable su imale negativne koeficijente. Vjerojatnost bankrota se ispostavila značajnom varijablom u procjeni rasta te je imala pozitivan predznak. U obzir su uzimali i sektor u kojem poduzeće posluje te dob. Ako je većina malih tvrtki mlada, i ako mnoge mlade tvrtke bankrotiraju, preostale male tvrtke prirodno imaju veću stopu rasta od većih.

Veličina poduzeća se u više studija provlači kao bitna stavka. U prethodno navedenom članku veličina se pokazala značajnom varijablom s negativnim utjecajem, što su svojim istraživanjem podržali i Pelin Demirel i Mariana Mazzucato kad su 2013. godine objavili rad o utjecaju i R&D-a[4] na rast poduzeća [4], gdje se varijabla veličine tvrtke po-

[4]Research and development-u Europi poznat kao istraživanje i tehnološki razvoj, odnosi se na inovativne aktivnosti koje poduzimaju korporacije ili vlade u razvoju novih usluga ili proizvoda ili poboljšanju postojećih. Istraživanje i razvoj predstavlja prvu fazu razvoja potencijalne nove usluge ili proizvodnog procesa.

kazala značajnom s negativnim utjecajem na rast poduzeća u svim kategorijama tvrtki, ali posebno za male tvrtke. Uloga R&D-a u rastu poduzeća je istražena u američkoj farmaceutskoj industriji između 1950. i 2008. godine. Otkriveno je da R&D bio uspješan u poticanju rasta poduzeća kroz čitavu povijest industrije. Ali samo u slučaju malih poduzeća. Velikim poduzećima R&D je usporavao rast. Konačno, pokazatelj zaostalih rezultata poslovanja firmi imaju značajan negativan utjecaj na rast poduzeća.

Suprotno istraživanjima Nørdal-Næs i Demirel-Mazzucato, Francisco Diaz Hermelo i Roberto Vassolo su 2007. godine u svojoj studiji o determinantama rasta poduzeća [5] došli do zaključka da veličina poduzeća nema utjecaj. Time je potvrđen Gibratov zakon koji kaže da je rast mjeren prodajom u bilo kojem vremenskom razdoblju neovisan o početnoj veličini tvrtke. Mjera rasta u ovom slučaju je bila stopa rasta prodaje firmi u trogodišnjem razdoblju. Osim što su utvrdili izostanak utjecaja veličine, došli su do još nekoliko zaključaka. Prvi je da povrat od prodaje (ROS) ima pozitivnu i značajnu vezu s rezultatima rasta. Poduzeća s visokim prinosom imaju veća financijska sredstva od zadržane zarade što im između ostalog omogućuje ulaganje u novu tehnologiju. Time smo došli do drugog zaključka koji se odnosi na korištenje tehnologije. Veći vremenski perioda od posljednjeg ulaganja u novu tehnologiju je negativno utjecao na stopu rasta. Osvrnuli su se i na raznolikost usluga. Suprotno od očekivanog , zaključak je da raznolikost proizvoda poduzeća nije imalo utjecaj na rast. Specijalizirana poduzeća su imala jednake mogućnosti za rast kao i ona sa raznolikim uslugama. I na kraju, geografsko područje djelovanja. Poduzeća koja imaju pristup regionalnom, nacionalnom i međunarodnom tržištu bila su uspješnija u kontekstu rasta od poduzeća sa isključivo nacionalnim i regionalnim tržištem.

Širenjem na strana tržišta, odnosno izvozom su se bavili i James H. Love i Stephen Roper. Oni su 2015. godine objavili članak u kojemu su na temelju provedenih istraživanja sumirane veze između inovativnosti, izvoza i rasta malih i srednjih poduzeća [11]. Uočena je snažna pozitivna veza između izvoza i rasta. Istraživanje upućuje na to da je veća vjerojatnost da će mala i srednja poduzeća koja imaju prethodno iskustvo u inovacijama izvoziti, i to uspješno, i vjerojatnije će ostvariti rast od izvoza nego poduzeća koja nisu inovativna. Jedno od najvažnijih istraživanja je bilo na 1400 španjolskih malih i srednjih poduzeća u razdoblju od 10 godina [7] gdje je donešen zaključak da samo mala i srednja poduzeća koja i inoviraju i izvoze generiraju znatno veći rast prodaje, samo izvoz ili samo inovativnost nisu dovoljne.

Osim prethodno navedenih stavki, ustanovilo se da je za postizanje rasta moraju pokriti sve tri dimenzije - poduzetnik, poduzeće i okoliš [15]. Najvažnijim osobinama poduzetnika su se pokazale kreće radno iskustvo i dobre networking vještine. Poželjne su i mlađa dob poduzetnika, nova tehnologija i spremnost za rast. Novi čimbenik koji se u prijašnjim istraživanjima nije pojavio je suradnja s pravnicima. Mala i srednja poduzeća

koja primaju poslovne savjete, ideje ili surađuju s odvjetnicima imaju veću vjerojatnost da će postati poduzeća s visokim rastom. Kada poduzeće počne sklapati ozbiljnije ugovore i krene s rastom, poželjne su konzultacije s odvjetnicima. Kada je riječ o financijskim resursima, negativni predznak omjera zadržane dobiti i ukupne imovine ukazuje na to da mala i srednja rastuća poduzeća više ulažu vlastite resurse, a ne da ih čuvaju u obliku zadržane dobiti. Također, rast plaća zaposlenika je smanjivao vjerojatnost rasta poduzeća. Sa strane okoliša, održavanje razine konkurentnosti je ključno. Ako ga malo i srednje poduzeće uspije održati na visokoj razini, imaju veće šanse da ostvare visoki rast.

Osim klasifikacije rastućih od nerastućih poduzeća, A.M.Moreno i J.C.Casillas su tražili pokazatelje koji bi unutar rastućih razlikovali one brzo rastuće [13]. Visoki rast poduzeća shvaća se kao izvanredan rast u usporedbi s prosječnim rastom ostalih firmi u istoj industriji. Bitnim varijablama su se pokazale ukupna i trenutna likvidnost. Koeficijent trenutne likvidnosti je bio u pozitivnoj korelaciji s brzo rastućim poduzećima.

3.2 Opis varijabli i podataka za modeliranje rasta poduzeća u Hrvatskoj

Istraživanje se provodi na reprezentativnom uzorku od 466 poduzeća koja posluju u Hrvatskoj, promatranih kroz razdoblje od 2010. do 2015. godine. Zabilježeno je ukupno 2790 observacija opisanih sa sljedećim varijablama.

oznaka	opis
insolv	1=insolventan/loš, 0=nije insolventan/dobar
KUL	koeficijent ubrzane likvidnosti
KTL	koeficijent tekuće likvidnosti
KFS	koeficijent financijske stabilnosti
KFZ	koeficijent zaduženosti
KVF	koeficijent vlastitog financiranja
KF	faktor zaduženosti
SPI	stupanj pokrića 1
SPII	stupanj pokrića 2
KOUI	koeficijent obrtaja ukupne imovine
KOKI	koeficijent obrtaja kratkotrajne imovine
KOP	koeficijent obrtaja potraživanja
KODI	koeficijent obrtaja dugotrajne imovine
EUP	ekonomičnost ukupnog poslovanja
EP	ekonomičnost prodaje

NPM	neto profitna marža (%)
NRI	neto rentabilnost imovine (%)
ROE	povrat na kapital (%)
ROA	povrat na imovinu (%)
EBIT	poslovni prihodi – poslovni rashodi
EBIT II	ukupni prihodi – ukupni rashodi
EBITDA	EBIT + amortizacija+ vrijednosna usklađenja
EBITDA II	EBIT II+ amortizacija+ vrijednosna usklađenja
KTRL	koeficijent trenutne likvidnosti
ZDKAP	zadržana dobit/kapital
TKKAP	temeljni kapital/kapital
NOVKI	novac/kratkotrajna imovina
ZALKI	zalihe/kratkotrajna imovina
FINIM/KI	financijska imovina/kratkotrajna imovina

Tablica 4: opis varijabli

Zavisne varijable će nam biti *insolv*, čiju vjerojatnost ćemo modelirati logističkom regresijom, te ćemo dobivenu vjerojatnost uvrstiti kao neovisnu varijablu u novi model, u kojem će zavisna varijabla biti EBIT, što je razlika između poslovnih prihoda i poslovnih rashoda. Poslovnim prihodima se smatra vrijednost prodanih dobara i usluga koje su iskazane kroz obračunsko razdoblje. Iznos je jednak prodajnoj vrijednosti realiziranih proizvoda, roba ili usluga. Poslovni rashodi nastaju kao posljedica obavljanja glavne djelatnosti poduzeća, poput sirovina i materijala,rezervnih dijelova, energije, usluge prijevoza, premije osiguranja, plaće, porezi, amortizacije i dr.[22].

Dalje ćemo definirati ostale varijable. Definicije i tumačenja financijskih pokazatelja su preuzeta s [22] i [20].

Insolventnost
Insolventnost je situacija u kojoj poduzeće ili druga pravna, odnosno fizička osoba, nije u mogućnosti podmiriti dospjele obveze plaćanja u rokovima njihova dospijeća.

Koeficijent ubrzane likvidnosti
Koeficijent ubrzane likvidnosti se difinira kao omjer razlike kratkotrajne imovine i zaliha i ukupnih kratoročnih obveza

$$KUL = \frac{kratkotrajna\ imovina - zalihe}{ukupne\ kratkorocne\ obveze}$$

Tumačimo kao sposobnost poduzeća da kratkoročnim sredstvima podmiri kratkoročne obveze bez prodaje zaliha. Poželjno je da vrijednost ne padne ispod 0,9.

Koeficijent tekuće likvidnosti

Koeficijent tekuće likvidnosti je omjer kratkotrajne imovine i kratkoročnih obveza

$$KTL = \frac{kratkotrajna\ imovina}{kratkorocne\ obveze}$$

Pokazatelj likvidnosti najvišeg stupnja jer u odnos dovodi pokriće i potrebe za kapitalom u roku od 1 godine. Ukoliko je vrijednost manja od 1,5 postoji rizik da poduzeće ostane bez sredstava za podmirenje kratkoročnih obveza. S druge strane, vrijednost daleko iznad prosijeka može značiti neefikasno korištenje sredstava. Prosjek se određuje za pojedini sektor poslovanja.

Koeficijent trenutne likvidnosti

$$KTRL = \frac{novac}{ukupne\ kratkorocne\ obveze}$$

ukazuje na sposobnost poduzeća da trenutno podmiri obveze. Dobar je pokazatelj u slučaju da potraživanja čine većinu kratkotrajne imovine, a postoji praksa kašnjenja u njihovoj naplati.

Koeficijent financijske stabilnosti

Koeficijent financijske stabilnosti suprotstavlja dugotrajnu imovinu i kapital s dugoročnim obvezama.

$$KFS = \frac{dugotrajna\ imovina}{kapital + dugorocne\ obveze}$$

Što je vrijednost ovog pokazatelja manja, to je likvidnost i financijska stabilnost veća, tj. povećava se učešće radnog kapitala.

Koeficijenti ubrzane likvidnosti, tekuće likvidnosti, trenutne likvidnosti i financijske stabilnosti čine grupu pokazatelja likvidnosti, tj. mjere sposobnost poduzeća da podmiri svoje kratkoročne obveze.

Koeficijent zaduženosti

koeficijent zaduženosti uspoređuje ukupne obveze i ukupnu imovinu

$$KFZ = \frac{ukupne\ obveze}{ukupna\ imovina},$$

tj. pokazuje do koje mjere poduzeće koristi zaduživanje kao oblik financiranja. Veća vrijednost dovodi do većeg rizika od insolventnosti. Poželjno je da bude 0,5 ili manja.

Koeficijent vlastitog financiranja

Pokazatelj vlastitog financiranja govori koliko je imovine financirano iz vlastitih izvora

$$KVF = \frac{glavnica}{ukupna\ imovina}.$$

Poželjna vrijednost je veća od 0,5.

Faktor zaduženosti

Jedan od najznačajnijih pokazatelja zaduženosti

$$KF = \frac{ukupne\ obveze}{zadrzana\ dobit + amortizacija}.$$

Budući da se iznosi zadržane dobiti i amortizacije najčešće odnose na jednogodišnje razdoblje, faktor zaduženosti govori za koliko se godina iz sredstava amortizacije i zadržanog dobitka mogu podmiriti ukupne obveze. Vrijednost pokazatelja ne bi trebala biti iznad 3-4 godine, inače znači da poduzeće ima financijske teškoće i pretjeranu zaduženost poduzeća.

Stupanj pokrića I i II

$$SPI = \frac{vlastiti\ kapital}{dugotrajna\ imovina} * 100$$

$$SPII = \frac{vlastiti\ kapital + dugorocne\ obveze}{dugotrajna\ imovina} * 100.$$

Stupnjevi pokrića I i II govore o pokriću dugotrajne imovine kapitalom, odnosno kapitalom uvećanom za dugoročne obveze. Ukoliko je vrijednost pokazatelja stupanj pokrića II veća od I to znači da je dio dugoročnih izvora iskorišten za financiranje kratkotrajne imovine. Stupanj pokrića II mora imati vrijednost veću od 1.

Koeficijenti zaduženosti, faktor zaduženosti, koeficijent vlastitog financiranja, stupanj pokrića I, stupanj pokrića II pokazuju strukturu kapitala i izvore financiranja i nazivaju se pokazateljima zaduženosti.

Mjera efikasnosti upotrebljavanja resursa poduzeća su pokazatelji aktivnosti. U tu grupu spadaju koeficijent obrta ukupne imovine, koeficijent obrta dugotrajne imovine, koeficijent obrta kratkotrajne imovine i koeficijent obrta potraživanja.

Koeficijent obrta ukupne imovine

$$KOUI = \frac{ukupni\ prihod}{ukupna\ imovina}$$

pokazuje koliko puta se ukupna imovina poduzeća obrne u tijeku jedne godine. Odnosno koliko poduzeće uspješno koristi imovinu s ciljem stvaranja prihoda. "Koliko svaka kuna imovine donosi kuna iz prodaje".

Koeficijent obrta kratkotrajne imovine

$$KOKI = \frac{ukupni\ prihod}{kratkotrajna\ imovina}$$

pokazuje koliko puta se kratkotrajna imovina poduzeća obrne u tijeku jedne godine, odnosno mjeri relativnu efikasnost kojom poduzeće rabi kratkotrajnu imovinu za stvaranje prihoda. Koeficijenti obrta ukupne i kratkotrajne imovine se koriste pri ocjeni djelotvornosti kojom menadžment angažira imovinu.

Koeficijent obrta potraživanja

$$KOP = \frac{prihod\ od\ prodaje}{potrazivanja}$$

Na temelju koeficijenta obrta potraživanja moguće je utvrditi prosječno trajanje naplate potraživanja ako se stavi u omjer sa brojem dana u obračunskom razdoblju.

Koeficijent obrtaja dugotrajne imovine

$$KODI = \frac{ukupni\ prihod}{dugotrajna\ imovina}$$

pokazuje koliko uspješno poduzeće koristi dugotrajnu imovinu s ciljem stvaranja prihoda. Opadajući pokazatelj može biti pokazatelj preinvestiranja u postrojenja, opremu ili neku drugu stalnu imovinu.

Pokazatelji ekonomičnosti mjere odnos prihoda i rashoda. Iz ove grupe mi imamo ekonomičnost ukupnog poslovanja i ekonomičnost prodaje.

Ekonomičnost ukupnog poslovanja

$$EUP = \frac{ukupni\ prihodi}{ukupni\ rashodi}$$

pokazuje koliko se prihoda ostvari po jedinici rashoda. Ukoliko je vrijednost pokazatelja manja od 1, to znači da poduzeće ostvaruje gubitak.

Ekonomičnost prodaje

$$EP = \frac{prihodi\ od\ prodaje}{materijalni\ troskovi + troskovi\ osoblja}$$

pokazuje koliko se jedinica prihoda od prodaje dobije za jednu jedinicu materijalnih i troškova osoblja. Općenito, za pokazatelje ekonomičnosti vrijedi pravilo da koeficijent bude što veći broj.

Povrat uloženog kapitala mjerimo pokazateljima profitabilnosti. To su neto profitna marža, neto rentabilnost imovine, stopa povrata imovine ROA i stopa povrata kapitala ROE.

Neto profitna marža

$$NPM = \frac{neto\ dobit}{ukupni\ prihod}$$

pokazuje kolika je neto dobit na jedinicu ukupnog prihoda. Pokazuje učinkovitost poslovanja, tj. koliko se dobro prodaja pretvara u profit. Ovim pokazateljem je poželjno uspoređivati poduzeća iz istog sektora, pa čak i slične veličine. Izražava se u postotku.

Neto rentabilnost imovine

$$NRI = \frac{neto\ dobit + rashodi\ od\ kamata}{ukupna\ imovina}$$

Ako se maržu profita pomnoži s koeficijentom obrtaja ukupne imovine, kao rezultat će se dobiti pokazatelj rentabilnosti imovine. Rashodi od kamata predstavljaju naknadu za korištenje tuđih izvora financiranja. "Rentabilnost imovine mjeri sposobnost poduzeća da koristi svoju imovinu za stvaranje profita."

Povrat na kapital
Odnoso stopa povrata glavnice

$$ROE = \frac{neto\ dobit}{glavnica}$$

pokazuje koliki profit društvo generira koristeći novac koji su vlasnici investirali u njega. "Koliko poduzeće ostvari dobiti na 1 kn uloženog vlastitog kapitala". Jedan je od najznačajnijih pokazatelja.

Povrat na imovinu

Odnosno stopa povrata imovine

$$ROA = \frac{neto\ dobit}{ukupna\ imovina}$$

pokazuje koliko uspješno poduzeće koristi imovinu u svrhu stvaranja dobiti. Odnosi se na dobit koju poduzeće generira iz jedne novčane jedinice imovine.

EBIT II

EBIT II računamo kao $ukupni\ prihodi - ukupni\ rashodi$. Ukupni prihodi i rashodi su širi pojam od poslovnih prihoda i rashoda jer obuhvaćaju jos i financijske i ostale prihode/rashode.

EDITDA

$$EBITDA = EBIT + amortizacija + vrijednosna\ uskladjenja$$

EBITDA pokazateljem se utvrđuje koliki postotak dobitka prije kamata, poreza i amortizacije ostaje gospodarskom subjektu po svakoj jedinici poslovnih prihoda (EBITDA marža). Veća je vrijednost EBITDA marže povoljnija, jer takvim gospodarskim subjektima ostaje veći dio prihoda nakon pokrića poslovnih troškova u odnosu na one koji ostvaruju niže vrijednosti ovog pokazatelja.

EBITDA II

$$EBITDA\ II = EBIT\ II + amortizacija + vrijednosna\ uskladjenja$$

Omjer zadržane dobiti i kapitala

$$ZDKAP = \frac{zadrzana\ dobit}{kapital}$$

Koristan je za sagledavanje trenda zadržavanja i reinvestiranja dobiti. Ukoliko pokazatelj opada, poslovanje se financira dugom što povećava rizik.

Omjer temeljnog kapitala i kapitala

$$TKKAP = \frac{temeljni\ kapital}{kapital}$$

Omjer novca i kratkotrajne imovine

$$NOVKI = \frac{novac}{kratkotrajna\ imovina}$$

govori koliki je udio vlastitog novca u kratkotrajnoj imovini.

Omjer zaliha i kratkotrajne imovine

$$ZALKI = \frac{zalihe}{kratkotrajna\ imovina}$$

govori koliki je udio zaliha u kratkotrajnoj imovini.

Omjer financijske imovine i kratkotrajne imovine

$$FINIM.KI = \frac{financijska\ imovina}{kratkotrajna\ imovina}$$

3.3 Analiza čimbenika rasta poduzeća u Hrvatskoj

Na temelju prikupljenih podataka pokušat ćemo odrediti varijable koje utječu na rast poduzeća te vezu rasta s rizikom insolventnosti.
Prvo ćemo logističkom regresijom procijeniti rizik insolventnosti te dobivenu vjerojatnost uključiti kao neovisnu varijablu u model rasta poduzeća.
Analiza podataka i modeliranje će u cijelosti biti napravljeno u R 4.0.0 programu.
U tablici koja slijedi prikazat ćemo deskriptivnu statistiku neovisnih varijabli.

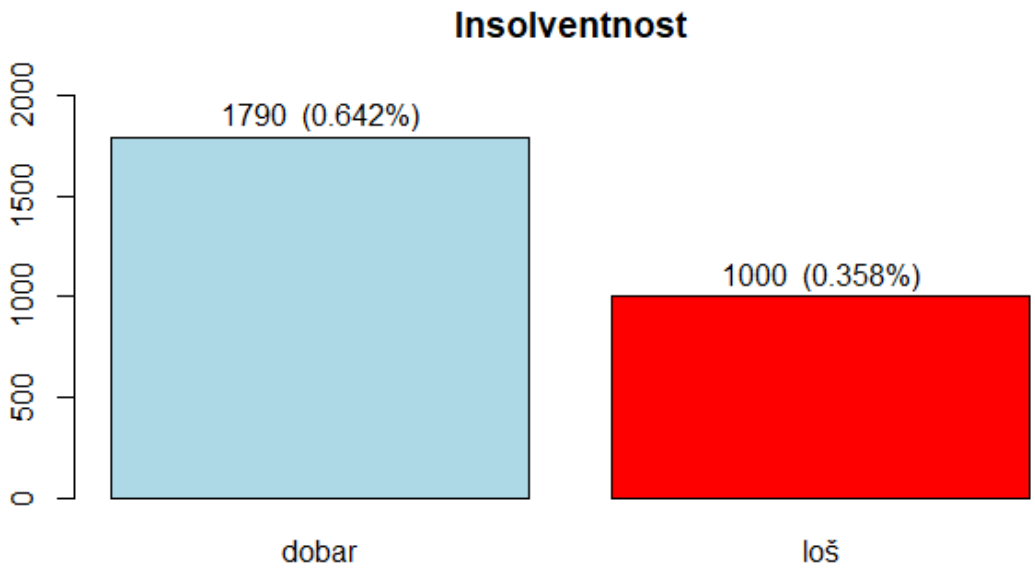
	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	NA's
KUL	0.0000	0.2626	0.6478	0.7654	1.0903	3.4901	785
KTL	0.0000	0.5324	0.9887	1.0456	1.3740	3.9753	804
KFS	-2.3776	0.0684	0.4803	0.5971	0.9575	3.3813	1214
KFZ	0.0000	0.4310	0.7884	0.7380	0.9638	2.4788	590
KVF	-1.2976	0.0084	0.1770	0.2907	0.5198	2.2733	456
KF	-2.9357	0.3987	1.2913	2.6305	4.0355	15.5593	1245
SPI	-2.8566	0.0064	0.4971	0.7807	1.1826	4.9240	1069
SPII	-3.8321	0.3343	0.9775	1.1082	1.5607	5.7562	1112
KOUI	0.0000	0.2986	0.9883	1.1838	1.7794	5.5898	529
KOKI	0.0000	0.6027	1.6051	1.8729	2.7072	7.9444	628
KOP	0.0000	0.8057	2.6859	3.5267	5.2504	15.7602	950
KODI	0.0000	0.6341	2.3510	4.1206	5.9246	26.5435	1220
EUP	0.8991	1.0054	1.0165	1.0237	1.0416	1.1360	1489
EP	0.0000	0.9948	1.0413	1.0236	1.1369	2.1571	1162
NPM	0.0000	0.0000	0.1264	0.9037	1.3205	9.4219	1112
NRI	0.0000	0.0000	0.0002	0.9068	1.2344	8.9087	1050
ROE	-5.2704	0.0000	0.0431	0.1356	0.1847	7.6897	1080
ROA	0.0000	0.0000	0.0016	0.0285	0.0211	9.4181	840
KTRL	-0.0001	0.0029	0.0278	0.1090	0.0932	4.9537	1064
ZDKAP	-1.9849	0.0000	0.3348	0.4091	0.7126	2.8226	939
TKKAP	-0.7803	0.0532	0.2172	0.3518	0.5621	2.3559	1102
NOVKI	-0.0002	0.0067	0.0455	0.1008	0.1602	0.5989	804
ZALKI	0.0000	0.0000	0.0378	0.2243	0.4185	1.0000	431
FINIM.KI	0.0000	0.2442	0.5801	0.5431	0.8551	1.0000	848

Tablica 5: Deskriptivna statisktika neovisnih varijabli

Ukoliko bismo za svako poduzeće imali jednak broj promatranja, tada bi se naš panel sastojao od 2796 observacija. Međutim nemamo podatke za sva poduzeća kroz cijelo razdoblje. Iz tablice 5 uočavamo da imamo veliki broj nedostajućih vrijednosti. Prilikom uključivanja varijabli u model, za svaku nedostajuću vrijednost unutar varijable, ćemo gubiti po jednu observaciju. Zbog toga će model biti temeljen na manjem broju promatranja te možda nećemo dobiti realnu statističku značajnost varijabli koju bismo imali u slučaju balansiranih podataka.

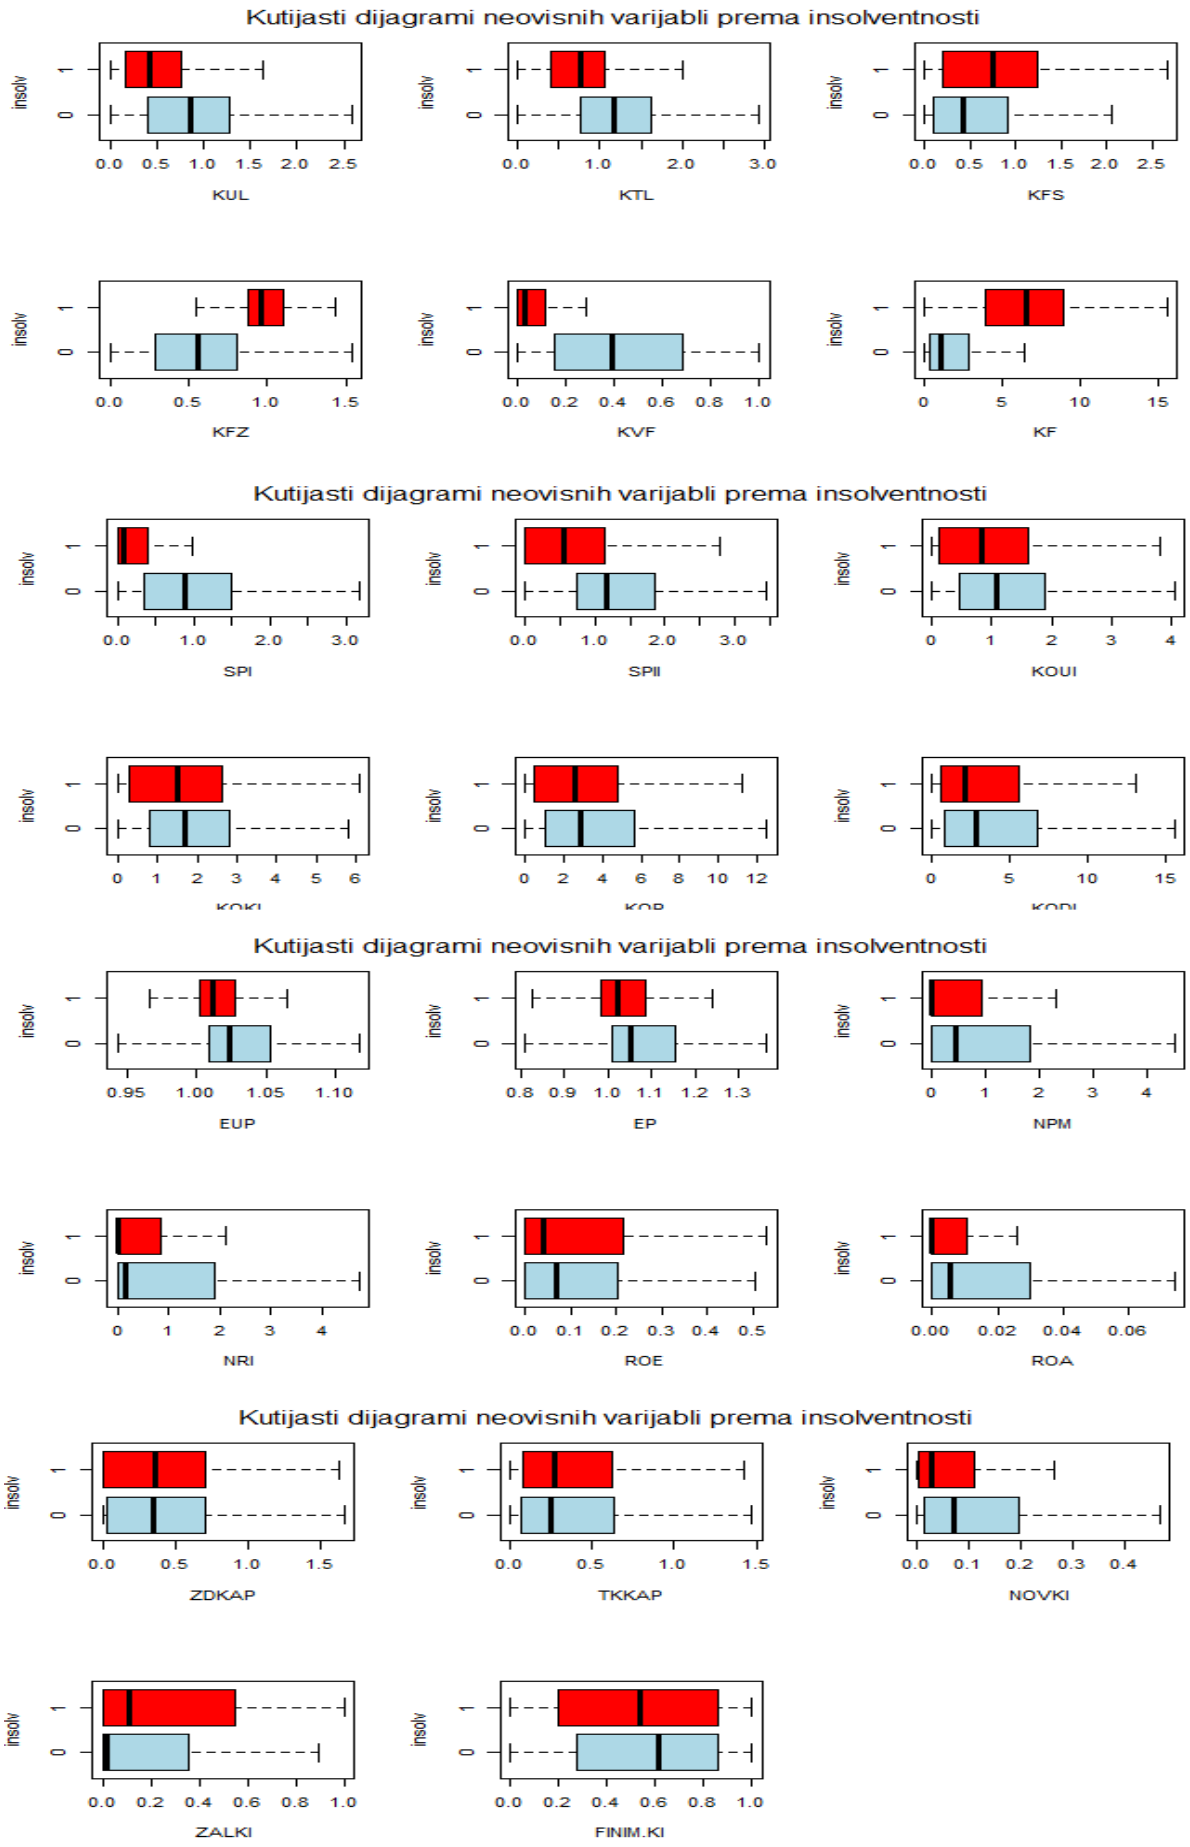
3.4 Model logističke regresije za procjenu insolventnosti poduzeća u Hrvatskoj

U prvom koraku postupka modeliranja primijenit ćemo logističku regresiju kako bismo napravili model za procjenu insolventnosti.
Želimo vidjeti pomoću kojih pokazatelja možemo procijeniti insolventnost. Radit ćemo s pomakom ovisne varijable za jednu godinu, tj. s vrijednostima pokazatelja iz godine t ćemo modelirati insolventnost u godini $t+1$.
Pogledajmo prvo raspodjelu poduzeća na dobre i loše.



Slika 1: barplot varijable insolv

Sa slike 1 možemo odmah uočiti frekvenciju i relativnu frekvenciju dobrih i loših poduzeća te vidjeti da je u šestogodišnjem razdoblju 64,2% poduzeća nije bilo insolventno.
Kako bismo mogli zaključiti koje varijable imaju drugačiju raspodjelu u odnosu na dobar/loš pogledat ćemo kutijaste dijagrame. Iz kutijastih dijagrama smo izbacili stršeće vrijednosti kako bismo dobili jasniji prikaz.


Kutijasti dijagrami neovisnih varijabli prema insolventnosti
insolv
KUL
KTL
KFS
KFZ
KVF
KF
Kutijasti dijagrami neovisnih varijabli prema insolventnosti
SPI
SPII
KOUI
Kutijasti dijagrami neovisnih varijabli prema insolventnosti
EUP
EP
NPM
NRI
ROE
ROA
Kutijasti dijagrami neovisnih varijabli prema insolventnosti
ZDKAP
TKKAP
NOVKI
ZALKI
FINIM.KI

Promatrajući kutijaste dijagrame možemo jasno uočiti da u slučaju nekih varijabli, poput KFZ, KVF i KF, postoje jasne razlike u distribuciji dobrih i loših poduzeća. Kod varijabli KUL, KTL i KFS vidimo razliku, međutim moramo uzeti u obzir raspon vrijednosti tih varijabli jer u slučaju malog raspona od 0 do 3.0 ne možemo znati kolika razlika bi bila značajna. Varijable ROE, ZDKAP i TKKAP nam djeluju kao da ne postoje razlike u vrijednostima s obzirom na insolventnost.

Izgradnju logističke regresije smo započeli punim modelom. Takav model je izbacio najviše promatranja, čak 2642 od ukupnih 2790. Smanjivanjem boja varijabli broj promatranja se povećavao, ali su modeli gubili na reprezentativnosti te je AIC svakom izbačenom varijablom bio sve veći. Statističke značajnosti su također bile promjenjive i u većini kombinacija jako loše. Morali smo odlučiti želimo li model sa većim brojem varijabli i tako izgubiti veliki broj promatranja, ili model sa manjim brojem varijabli, ali više promatranja.

Odabrali smo sačuvati velik broj promatranja te se ograničiti na modele sa 5 ili manje varijabli. Pokušali smo napraviti model koji će sadržavati pokazatelje iz različitih grupa. Nakon što smo si ograničili broj varijabli, modele smo kreirali vodeći se idejom forward i backward selekcije. Sve testirane varijante modela su davale slične rezultate. Koeficijenti dobrih statističkih značajnosti su u većini slučajeva izostajali.

Na kraju se najboljim modelom pokazao onaj koji je sadržavao sljedeće varijable: *KUL (koeficijent ubrzane likvidnosti), KFS (koeficijent financijske stabilnosti), KFZ (koeficijent zaduženosti), NPM (neto profitna marža), ROE (povrat na kapital).*

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	-6.42481	0.82634	-7.775	7.55e-15 ***
KUL (koef. ubrzane likvidnosti)	-0.19123	0.29386	-0.651	0.51519
KFS (koef. financijske stabilnosti)	0.39275	0.17317	2.268	0.02333 *
KFZ (koef. zaduženosti)	7.27712	0.86820	8.382	< 2e-16 ***
NPM (neto profitna marža)	-0.25938	0.09745	-2.662	0.00778 **
ROE (povrat na kapital)	1.81015	0.82499	2.194	0.02823 *

Tablica 6: model logističke regresije

KUL i KFS su pokazatelji likvidnosti, KFZ je pokazatelj zaduženosti, a NPM i ROE pokazatelji profitabilnosti.
Navedene varijable su međusobno nekorelirane i sve osim KUL varijable su statistički značajne.
Negativan predznak koeficijenta varijable KUL je očekivan jer uspješno podmirivanje kratkoročnih obveza smanjuje vjerojatnosti insolventnosti.
KFS mora biti manji od 1 i što je koeficijent veći, financijska stabilnost poduzeća je manja.

To opravdava pozitivan odnos.
Veći odnos duga i imovine, odnosno KFZ, povlači veći financijski rizik (rizik da poduzeće neće biti u mogućnosti vratiti dug), stoga je pozitivan predznak očekivan.
Povećanjem NPM raste vjerojatnost nelikvidnosti. Nelikvidnost može, iako ne mora, dovesti do insolventnost, što objašnjava negativan odnos.
Poduzeća mogu povećati ROE na način da pogoršaju solventnost te je i u ovom slučaju pozitivan odnos opravdan.
Za sve varijable smo dobili teorijski podržane odnose te možemo pretpostaviti da će model imati dobru sposobnost predikcije.

Za validaciju modela odabrat ćemo tri kriterija: *KS* statistiku, matricu pogrešaka (confusion matricu), ROC krivulju.

Vrijednost *KS* statistike iznosi 0.59, odnosno 59%.

vrijednost KS statistike	ocjena modela
<0.2	model neće raditi
0.21-0.4	fer
0.41-0.5	dobar
0.51-0.6	jako dobar
0.61-0.75	odličan
>0.75	predobar da bi bio istinit

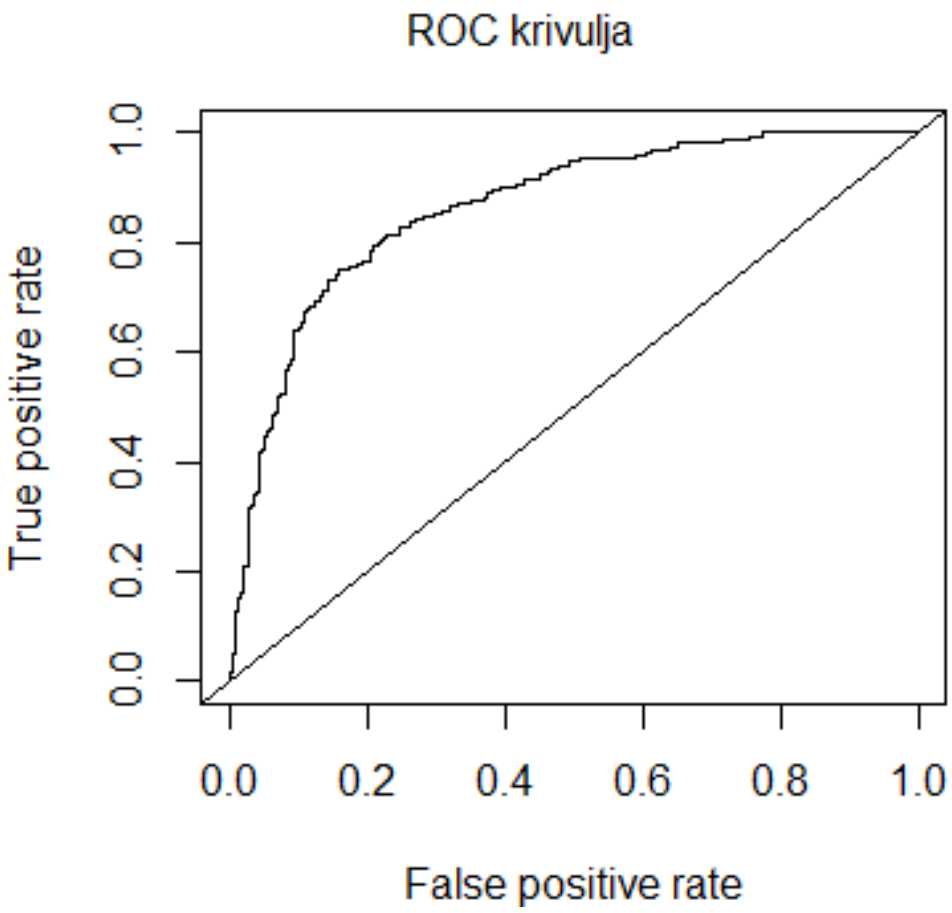
Tablica 7: kategorizacija KS pokazatelja

Prema kategorizaciji KS pokazatelja (tablica 7) to je jako dobro.

	PROCIJENJENI (%)	
STVARNI (%)	0	1
0	399 (0.943)	24 (0.057)
1	104 (0.550)	85 (0.450)

Tablica 8: matrica pogrešaka

Iz matrice pogrešaka modela (tablica 8) vidimo da su 24 dobra poduzeća pogrešno svrstana u loša, i da su 104 loša svrstana u dobra.



Slika 2: ROC krivulja modela

Dijagonalna *ROC* krivulja (Slika 2) bi značila da model uopće ne razlikuje dobre od loših. Što se krivulja nalazi više iznad dijagonale to je bolja klasifikacija. Površina ispod krivulje (AUC) iznosi 0.8634971 te na temelju grafičkog prikaza možemo zaključiti da naš model dobro klasificira.

Sada kada imamo model za insolventnost kreirat ćemo novu varijablu *PI (Probability of Insolvency)* koju ćemo kao neovisnu iskoristiti za modeliranje *EBIT*-a.

$$PI = \frac{1}{1 + e^{-(-5.62164 - 0.56845KUL + 0.39275KFS + 7.10941KFZ - 0.30642NPM + 2.09817ROE)}}$$

3.5 Panel modeli rasta poduzeća u Hrvatskoj

U drugom koraku postupka modeliranja želimo vidjeti koji pokazatelji, uz vjerojatnost insolventnosti, najbolje procjenjuju rast poduzeća. Za varijablu *EBIT* ćemo napraviti tri panel modela. Nakon što provedemo LM i F test, ovisno o dobivenim rezultatima potražit ćemo dobivenu kombinaciju (ne)odbačenih hipoteza u tablici 9 i odabrati naš model.

LM test	F test	odabir
H_0 odbacujemo	H_0 odbacujemo	Hausman test (biramo između slučajnih i fiksnih efekata)
H_0 odbacujemo	H_0 ne odbacujemo	model slučajnih efekata
H_0 ne odbacujemo	H_0 odbacujemo	model fiksnih efekata
H_0 ne odbacujemo	H_0 ne odbacujemo	združeni model

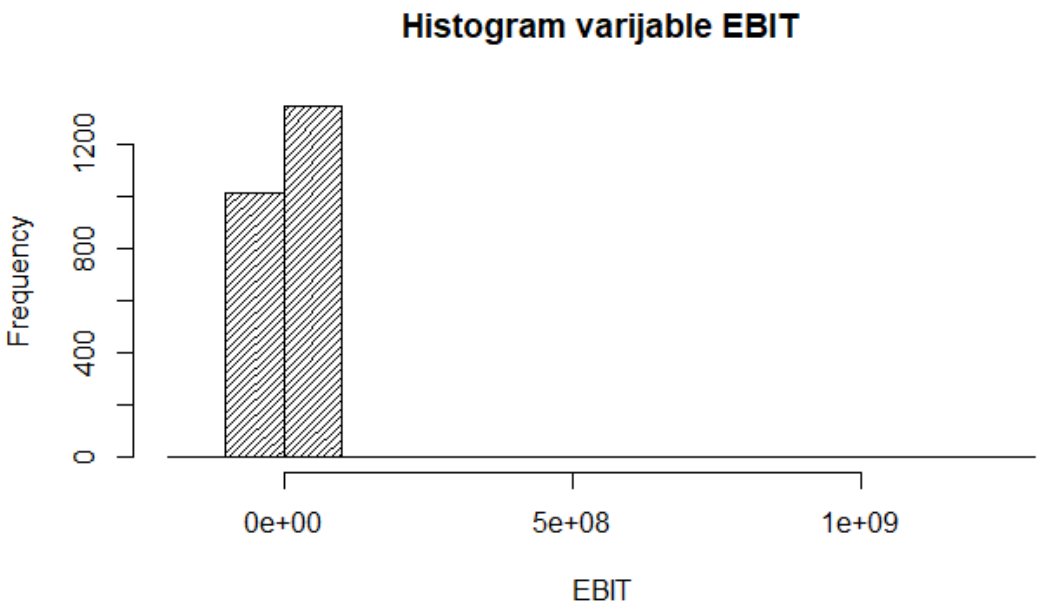
Tablica 9: Kako odabrati model

Pogledajmo prvo deskriptivnu statistiku *EBIT* varijable.

	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	NA's
EBIT	-180780794	-17338	5299	1822314	87607	1253356634	425

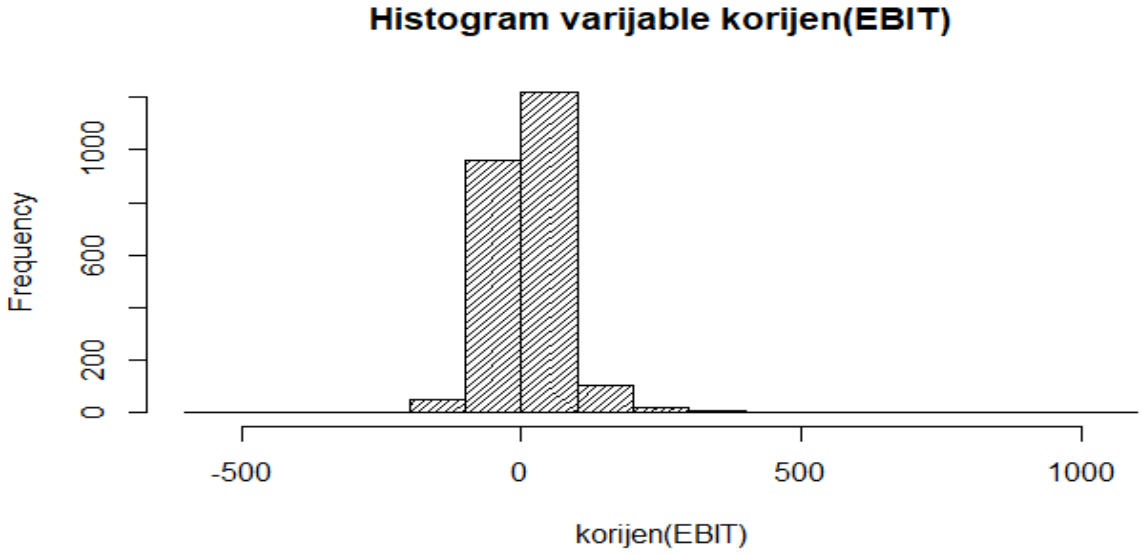
Tablica 10: Deskriptivna statisktika varijable EBIT

U tablici 10 uočavamo da varijabla ima izuzetno velik raspon vrijednosti. Takav raspon je teško prikazati grafički što vidimo i na histogramu sa slike 3 iz kojeg ne možemo puno toga zaključiti.



Slika 3: Histogram varijable EBIT

Iz tog razloga ćemo *EBIT* transformirati kako bismo dobili bolju kontrolu nad podacima. Budući da imamo i negativne i pozitivne vrijednosti, koristit ćemo transformaciju trećim korijenom. Tako dobivena varijabla će sada imati sljedeću distribuciju.



Slika 4: Histogram varijable korijen(EBIT)

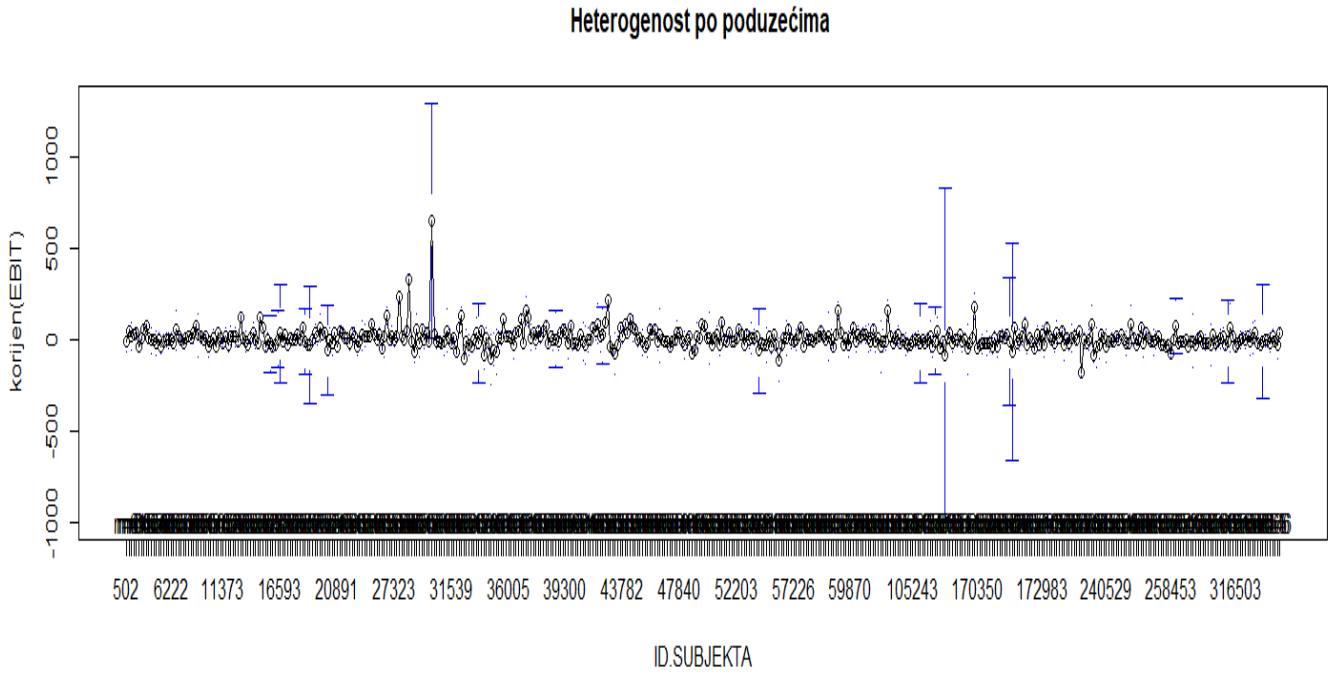
	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	NA's
korijen(EBIT)	-565.44	-25.88	17.43	14.57	44.41	1078.18	425

Tablica 11: Deskriptivna statisktika varijable korijen(EBIT)

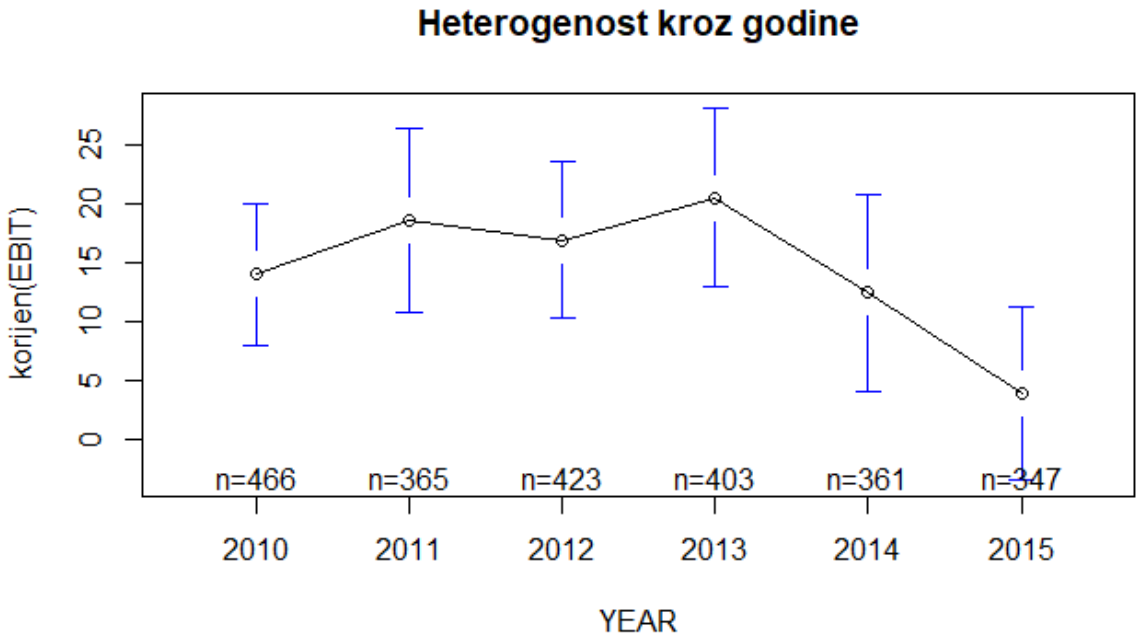
Prije nego navedemo modele moramo napomenuti da će veliki broj nedostajućih vrijednosti utjecati na kvalitetu kao što je to bio slučaj kod logističke regresije.
I ovdje smo najbolji model tražili istim postupkom. U korist sačuvanja većeg broja promatranja odlučili smo smanjiti broj varijabli. Kao i u logističkoj regresiji, ovdje smo se također vodili idejom forward i backward selekcije, s tim da smo uvijek zadržali varijablu *PI*. Isprobavanjem različitih kombinacija odučili smo se za varijable *PI, KTL, KOUI, EP, NRI*.
Za njih smo napravili model konstantnih koeficijenata, fiksnih efekata i slučajnih efekata.

U modelu konstantnih koeficijenata za varijable *PI* i *KTL* smo dobili lošu razinu statističke značajnosti, ali smo ih odlučili ne izbaciti u slučaju da se stanje popravi u idućim modelima.

Sljedeće ćemo provjeriti postoji li bitan učinak individualnih koeficijenata poduzeća ili vremenske komponente.
Heterogenost podataka znači da utjecaj neovisnih varijabli na zavisnu varira među jedinicama promatranja ili tokom vremena.



Slika 5: Heterogenost po poduzećima



Slika 6: Heterogenost po godinama

Na slikama 5 i 6 vidimo grafički prikaz heterogenosti po poduzećima i kroz godine. Možemo zaključiti da je izraženija kroz poduzeća, nego kroz vrijeme, stoga pretpostavljamo da vremenska komponenta neće igrati bitnu ulogu.
Testirajući postojanje individualnih efekata F-testom dobili smo p-vrijednost manju od 0.05 zbog čega smo odbacili nultu hipotezu koja tvrdi da su svi individualni koeficijenti osim jednog jednaki nula. Uvođenjem vremenske komponente u model nismo ga poboljšali što je također pokazano F-testom gdje smo dobili p-vrijednost veću od 0.05 što znači efekt vremena nije potreban.
Kod modela fiksih efekata gubi se statistička značajnost svim varijablama osim *EP* i *NRI*. Izbacivanjem neke od varijabli ne bismo popravili značajnost ostalim varijablama.

Preostaje nam jos napraviti model slučajnih efekata. Statističke značajnosti varijabli su ostale iste kao u modelu konstantnih koeficijenata.
Provođenjem LM-testa dobili smo p-vrijednost manju od 0.05 te zaključujemo da će ovaj model biti također prikladniji od prvog.
Budući da smo dobili da su i model fiksnih i model slučajnih efekata bolji od modela konstatnih koeficijenata moramo provesti Hausmanov test kako bismo odabrali bolji.
Dobili smo p-vrijednost 0.03303 što je manje od 0.05 te se odlučujemo za model fiksih efekata.

S obzirom da nismo zadovoljni statističkim značajnostima koeficijenata dobivenih modela, pokušat ćemo napraviti preinake modela kako bismo ih poboljšali.
Iz modela konstantinh koeficijenata i slučajnih efekata smo izbacili slobodni član. Model fiksnih efekata ga nije ni imao te on ostaje nepromjeniv. Ovime se prvi model pogoršao, ali zato smo u modelu slučajnih efekata bez slobodnog člana dobili sve statistički značajne varijable.
Hausmanovim testom smo dobili *p*-vrijednost 0.2364 što je veće od 0.05 te na temelju toga biramo njega ispred modela fiksnih efekata.

	Pooled OLS		Fixed effects		Random effects		Random effects no.2	
Variable	Estimate	Pr(>|z|)	Estimate	Pr(>|z|)	Estimate	Pr(>|z|)	Estimate	Pr(>|z|)
Intercept	-58.4594	3.351e-06 ***			-40.5879	0.001012 **		
PI	15.0239	0.06951 .	-11.1330	0.3825	1.100898	0.901365	-17.9781	0.008738 **
KTL	5.6709	0.20311	-9.1399	0.1333	0.01114	0.998023	-9.6487	0.005342 **
KOUI	-9.0281	8.670e-05 ***	1.4960	0.7068	-4.90387	0.049579 *	-5.1748	0.040466 *
EP	61.2716	4.170e-11 ***	40.2059	4.462e-05 ***	49.29424	1.199e-09 ***	30.9272	1.593e-07 ***
NRI	10.6561	2.694e-15 ***	9.1194	1.456e-10 ***	10.0227	< 2.2e-16 ***	9.7748	< 2.2e-16 ***
R^2	0.18151		0.20722		0.18473		0.17025	
Adj.R^2	0.17427		-0.41656		0.17752		0.16439	
p-value	< 2.22e-16		1.231e-14		< 2.22e-16		< 2.22e-16	
RSS	1.401,800		386,270		695,980		691,050	
TSS	1.712,700		487,230		853,490		832,530	

Tablica 12: Pregled modela

Tablicom 12 smo prikazali pregled modela. Prvi Hausmanov test je **Fixed effects** model odabrao kao bolji, a zatim je drugi Hausmanov test **Random effects no.2** pokazao da je bolji od **Fixed effects** modela. Stoga će naš odabrani model biti **Random effects no.2**.

Unatoč tome što smo od ponuđenih modela odabrali najbolji, možemo vidjeti da su R^2 vrijednosti izuzetno male te nijedan model neće biti dobar za procjenu.
p-vrijednost modela određuje značaj modela u usporedbi s nul-modelom. Za linearni model, nul-model je onaj u kojem su svi koeficijenti neovisnih varijabli jednaki nuli, osim slobodnog člana. Za sva četiri modela ta vrijednost je manja od 0.05 što znači svi oni opisuju podatke značajno bolje nego što bi samo prosječna vrijednost ovisne varijable.
Moguće je dobiti značajnu p-vrijednost s niskom R^2 vrijednosti. To se često događa kada postoji velika varijabilnost u zavisnim varijablama, ali postoji dovoljno podataka da bi se mogao pokazati značajan odnos.

U konačnici naš model ima sljedeći oblik:

$$\sqrt[3]{EBIT} = -17.9781 \cdot PI - 9.6487 \cdot KTL - 5.1748 \cdot KOUI + 30.9272 \cdot EP + 9.7748 \cdot NRI + \epsilon$$

PI smo definirali kao vjerojatnost da poduzeće postane insolventno, stoga je negativan utjecaj očekivan.
Likvidnost mjerena koeficijentom tekuće likvidnosti *KTL* dokazano ima negativan učinak na profitabilnost poduzeća [6] što se pokazalo i u našem slučaju.
Poželjno je da poduzeće po jednoj jedinici imovine ostvaruje što više jedinica prihoda, jer se realizira veći profit, stoga nije neočekivano pretpostaviti da će *KOUI* imati pozitivnu vezu s rastom. U odabranom modelu je suprotno pretpostavci negativan odnos. To možemo pripisati drugom tumačenju *KOUI*-ja, odnosno da on ukazuje na veličinu imovine potrebne za obavljanje određene razine prodaje.
Najveći utjecaj ima ekonomičnost prodaje *EP*, što je očekivana pozitivna veza jer pokazuje koliko se jedinica prihoda od prodaje dobije za jednu jedinicu materijalnih i troškova osoblja.
Zadnja varijabla iz modela, neto rentabilnost imovine, također će očekivano pozitivno djelovati na rast poduzeća jer na nju možemo gledati kao na mjeru koliko uspješno poduzeće koristi vlastitu imovinu za stvaranje profita.

4 Zaključak

U novijoj povijesti ekonometrije panel struktura se pokazala izuzetno prikladnom. Razlog tome su prednosti u odnosu na podatke poprečnog presjeka i vremenske nizove. Neke od tih prednosti su što sadrže više podataka, i procjene dobivene panel analizom su preciznije jer se zavisna varijabla mijenja kroz vrijeme, ali i po jedinicama promatranja.

Naglasak rada je na primjeni panel analize, odnosno modeliranju rasta poduzeća u Hrvatskoj. Rast poduzeća je kompleksna tema koja već dugo budi interes među ekonomistima, poduzetnicima, ali i vladama, stoga je od velike važnosti istražiti koji to čimbenici određuju da li će neko poduzeće rasti ili ne. Mi smo pokušali na temelju reprezentativnog uzorka dovesti u vezu vjerojatnost insolventnosti i rast.

U dobivenom modelu logističke regresije za insolventnost odabrani pokazatelji su imali ujecaj u skladu s teorijskom pozadinom i tumačenjem. Dobili smo da koeficijent financijske stabilnosti, koeficijent zaduženosti i ROE imaju pozitivan utjecaj na insolventnost, dok koeficijent ubrzane likvidnosti i neto profitna marža djeluju negativno. Na temelju zadovoljavajućih vrijednosti *KS* statistike, *AUC*-a i izgleda *ROC* krivulje zaključili smo da model dobro klasificira poduzeća. Nakon uspješnog modela mogli smo definirati novu varijablu, vjerojatnost insolventnosti, koju ćemo koristiti za modeliranje rasta.

Za procjenu rasta, odnosno varijable $\sqrt[3]{EBIT}$, napravili smo četiri modela. Model konstantnih koeficijenata, model fiksnih efekata i dva modela slučajnih efekata. Modeli slučajnih efekata su se po broju varijabli razlikovali u slobodnim članovima. Na temelju rezultata statističkih testova odalučili smo se za model slučajnih efekata bez slobodnog člana. Dobivene vrijednosti i predznaci varijabli su pokazali da će vjerojatnost insolventnosti, koeficijent tekuće likvidnosti i koeficijent ukupne imovine imati negativan utjecaj, a ekonomičnost prodaje i neto rentabilnost imovine će imati pozitivan utjecaj na rast. Unatoč maloj R^2 vrijednosti, utjecaji odabranih varijabli u ovom modelu su se pokazali teorijski opravdanim.

Literatura

[1] P. BALESTRA, M. NERLOVE, *Pooling Cross Section and Time Series Data in the Estimation of a Dynamic Model: The Demand for Natural Gas*, The Econometric Society, 34(1966), 585-612

[2] B. H. BALTAGI, *Econometric Analysis of Panel Dana*, Third edition, John Wiley Sons Inc., New York, 2005.

[3] K. BJØRN NORDAL, R. NÆS, *The relationship between bankruptcy risk and growth for non-listed firms*, Norges Bank Working Paper, 31(2010)

[4] P. DEMIREL, M. MAZZUCATO, *Innovation and Firm Growth: Is RD Worth It?*, Industry and Innovation, 19(2012), 45-62

[5] F. DIAZ HERMELO, R. VASSOLO, *The determinants of firm's growth: an empirical examination*, Revista ABANTE, 10(2007), 3-20

[6] A. ELJELLY, *Liquidity-profitability trade off: an empirical investigation in an emerging market*, International Journal of Commerce and Management, 14(2004), 48-61

[7] E. GOLOVKO, G. VALENTINI, *Exploring the complementarity between innovation and export for SMEs' growth*, Journal of International Business Studies, 42(2011), 362–380

[8] W. H. GREENE, *Econometric Analysis*, Upper Saddle River, New Jersey, 2002.

[9] C. HSIAO, *Analysis of Panel Data*, Cambridge University Press, Cambridge, 2003.

[10] C. HSIAO, *Panel Data Analysis — Advantages and Challenges*, TEST: An Official Journal of the Spanish Society of Statistics and Operations Research, 16(2007)

[11] J. H. LOVE, S. ROPER, *SME innovation, exporting and growth: A review of existing evidence*, International Small Business Journal, 33(2015), 28–48

[12] R. D. MITROVIĆ, *Analiza panel serija*, Zadužbina Andrejević, Beograd 2002.

[13] A. M. MORENO, J. C. CASILLAS, *High-growth smes versus non-highgrowth smes: a discriminant analysis*, Entrepreneurship Regional Development: An International Journal, 19(2007)

[14] K. SCHMIDHEINY, *Short Guides to Microeconometrics*, Unversitat Basel, Basel, 2019.

[15] N. ŠARLIJA, A. BILANDŽIĆ, *Modeling and Predicting the Growth of SME*, Proceedings of the 6th International Conference on Innovation and Entrepreneurship, (2018), 391-398

[16] N. ŠARLIJA, S. PFEIFER, M. JEGER, A. BILANDŽIĆ, *Measuring Enterprise Growth: Pitfalls and Implications"*, International Scholarly and Scientific Research Innovation, 10(2016), 1606-1613

[17] M. VERBEEK, *A Guide to Modern Econometrics*, John Wiley Sons, Hoboken, 2008.

[18] J. M. WOOLDRIDGE, *Econometric Analysis of Cross Section and Panel Data*, The MIT Press, Cambridge, 2002.

[19] J. M. WOOLDRIDGE, *Introductory Econometrics: A Modern Approach*, 5th edition, South-Western, Mason, 2013.

[20] K. ŽAGER, L. ŽAGER, *Analiza financijskih izvještaja*, Masmedia, Zagreb, 1999.

[21] https://www.bauer.uh.edu/rsusmel/phd/ec1-15.pdf

[22] https://www.mathos.unios.hr/images/homepages/nsarlija/Financijska_analiza.doc.pdf

Sažetak

U ovom radu stražujemo vezu između rizika insolventnosti i rasta za hrvatske tvrtke koristeći panel podatke. U prvom dijelu definirani su različiti modeli primjenjivi na panel strukturu, kao i logistička regresija koja je korištena za modeliranje insolventnosti. Objašnjeni su i statistički testovi korišteni za odabir najadekvatnijeg modela. Drugi dio prikazuje primjenu panel podataka u ekonomiji. Cjelokupno modeliranje rađeno je programom R.

Ključne riječi

panel podaci, balansirani podaci, logistička regresija, združeni model, fikni efekti, slučajni efekti, Lagrange, F-test, Hausman, rast poduzeća, insolventnost, financijski pokazatelji

Title and summary

Firm growth modeling: panel data analysis

We investigate the relationship between insolvency risk and growth for Croatian firms using panel data. Different models for panel data are discussed in first part, as well as logistic regression which was used for modeling insolvency. Statistical tests used for model selection are also explained. The second part shows the application of panel data in economics. Entire modeling was done with the R program.

Keywords

panel data, balanced data, logistic regression, pooled model, fixed effects, random effects, Lagrange, F-test, Hausman, firm growth, insolvency, financial ratios

Životopis

Rođena sam 5. siječnja 1995. u Slavonskom Brodu gdje sam završila osnovnu školu i 2009. godine upisala prirodnoslovno-matematičku Gimnaziju Matija Mesić. Za vrijeme osnovnoškolskog obrazovanja sudjelovala sam na općinskom i županijskom natjecanju iz fizike. 2013. godine upisujem Preddiplomski studij matematike na Odjelu za matematiku. Završavam ga 2017. godine te iste upisujem Diplomski studij, smjer Financijska matematika i statistika.
U rujnu 2018. godine zapošljavam se kao student u Gideon Brothers d.o.o. poduzeću gdje sam do kolovoza 2020. godine radila u timu anotatora kao reviewer.
Na dan obrane diplomskog rada zaposlena sam u Privrednoj Banci Zagreb u Odjelu upravljanja rizicima na poziciji pripravnika za financijske i tržišne rizike.