

# Įmonių finansinių įsipareigojimų neįvykdymo tikimybės vertinimas nustatant kredito reitingus

Straipsnyje statistiniais ir dirbtinio intelekto metodais sudarytas įmonių kredito rizikos vertinimo modelis. Analizuojant finansinių ataskaitų duomenis, įmonės klasifikuojamos į 8 rizikos grupes, nustatomas jų kredito reitingas ir įvertinama finansinių įsipareigojimų neįvykdymo tikimybė.

**Raktiniai žodžiai:** bankai, kredito reitingai, kredito rizika, statistinė analizė.

The statistical and artificial intelligence enterprise credit risk assessment model was developed in this research. Analyzing the financial data the model classifies enterprises into 8 risk groups, attributes the credit ratings and evaluates the probability of default.

**Keywords:** banks, credit ratings, credit risk, statistical analysis.

**JEL Classifications:** C45/C58/G24.

---

## Įvadas

Finansų sistemoje komerciniai bankai yra svarbiausi finansų tarpininkai, kurie savo veiklą grindžia indėlių ar kitų grąžintinių lėšų priėmimu iš juridinių ar fizinių asmenų, ir kreditų teikimu prisiimant su tuo susijusią riziką ir atsakomybę. Ekonominiu požiūriu kredito srautas turi reikšmingą poveikį šalies ūkio raidai, kuris pasireiškia verslo investicijų ir vartojimo skatinimu, ūkio gamybinio pajėgumo didinimu. T. Ramanauskas (2011) teigė, kad komercinių bankų kredito srautas padidina visuminę paklausą, įmonių pelną ir darbo užmokestį.

Galimybė gauti paskolas didina sukuriamos pridėtinės vertės apimtis, aktyvina įmonių veiklą ir dar labiau didėja kredito paklausa, o didėjant paskoloms, didėja indėlių bankuose, dalis šių indėlių tampa naujų paskolų finansavimo šaltiniu. Tačiau kreditas didina ne tik ūkio plėtros, bet ir nuosmukio spartą ekonominės krizės metu. Didėjant finansinių įsipareigojimų nevykdymo apimtims, bankai griežtina kreditų teikimo politiką, padidėja paskolų palūkanų normos, kad kompensuotų bankų patiriamus nuostolius. Dėl reikšmingos įtakos ekonomikai komercinių bankų kredito teikimo veiklai būdingas reguliavimas. Bazelio bankų

priežiūros komiteto rekomendacijos perkeltos į šalių centrinių bankų teisės aktus, kurių privalo laikytis komerciniai bankai. Vadovaudamiesi pateiktomis nuostatomis, komerciniai bankai turi galimybę formuoti savo kredito rizikos vertinimo modelius, siekdami kuo didesnio rizikos vertinimo tikslumo, o šių modelių formavimas taip pat yra dažnas mokslinių tyrimų objektas. Mokslinėje literatūroje dažniausiai pateikiami tyrimų rezultatai, kur įmonės klasifikuojamos vien tik į patikimų ir nepatikimų klientų grupes. Pastaraisiais metais paskelbtų tyrimų rezultatai rodo, jog A. Khashman (2011) sudarė dirbtinių neuronų tinklų modelį, kuriuo įmonės klasifikuojamos į 2 rizikos grupes. G. Derelioglu ir F. Gurgen (2011) šiam tikslui pritaikė dirbtinių neuronų tinklų, faktoriinės analizės, sprendimų medžio ir *k*-osios artimiausios jungties metodus. I. Brown ir C. Mues (2012) įmonių klasifikavimui sudarė logistinės regresijos, diskriminantinės analizės, dirbtinių neuronų tinklų, atraminių vektorių (SVM), sprendimų medžio modelius. G. Wang ir J. Ma (2012) sudarytu SVM modeliu klasifikavo įmones į 2 grupes. W. Chen, G. Xiang, Y. Liu ir K. Wang (2012) klasterinės analizės ir SVM metodais klasifikavo įmones į 4 rizikos grupes ir t. t. Tačiau trūksta skelbiamų tyrimų rezultatų, kur būtų nurodyta, kaip įmones bankuose klasifikuoti į ne mažiau kaip 8 rizikos grupes, kaip nurodyta Bazelio bankų priežiūros komiteto rekomendacijose. Todėl šiame tyrime siekiama sudaryti tokio pobūdžio kredito reitingų modelį.

Mokslinėse publikacijose nėra vieningai nustatyta, kokius kintamuosius ir duomenų analizės metodus bankai turėtų taikyti kredito rizikos vertinimui, taip pat nėra apibrėžtas vieningas kredito rizikos vertinimo modelių formavimo procesas.

Tai yra bankų veiklos praktikai aktualių ir besitęsiančių tyrimų objektas, todėl Lietuvoje veikiančių įmonių kredito rizikos vertinimo modelio formavimo tyrimai yra šios krypties tyrimų tęsimas ir rezultatų paieška. Kadangi kredito rizikos valdymas bankuose daugiausiai apima pasirinktų principų, būdų ir procesų taikymą rizikos lygio įvertinimui, bei reagavimo į riziką veiksmų planavimą ir įgyvendinimą, veiksmingų kredito rizikos vertinimo modelių sudarymo tyrimai padeda formuoti sistemingą banko vidinę aplinką proaktyviajam kredito rizikos valdymo sprendimų priėmimui ir banko veiklos rezultatų gerinimui.

**Tyrimo objektas** – įmonių finansinių įsipareigojimų neįvykdymo tikimybė.

**Tyrimo tikslas** – sudaryti įmonių kredito rizikos vertinimo modelį, kuriuo galima įmonėms priskirti kredito reitingus ir įvertinti finansinių įsipareigojimų neįvykdymo tikimybę.

#### **Uždaviniai:**

1. pateikti pagrindinius įmonių kredito rizikos rodiklius ir jų vertinimo ypatumus;
2. sudaryti įmonių kredito rizikos vertinimo modelį, pasitelkiant statistinius ir dirbtinio intelekto duomenų analizės metodus.

#### **Tyrimo metodai:**

1. mokslinių publikacijų ir įmonių kredito rizikos vertinimą reglamentuojančių teisės aktų analizė;
2. įmonių kredito rizikos vertinimo modelio formavimas programų paketu „Statistica“.

Modelio formavimo metu analizuoti pelningai veikiančių ir bankrutavusių įmonių finansiniai duomenys iš metinės finansinės atskaitomybės dokumentų.

## Pagrindiniai įmonių kredito rizikos rodikliai ir jų vertinimas

Kredito rizikos vertinimui komerciniuose bankuose Bazelio bankų priežiūros komiteto II kapitalo susitarimas (Bazelis II) sudarė galimybę taikyti vidaus reitingų modelius. Atsižvelgiant į kredito rizikos vertinimo rezultatus priimami sprendimai dėl klientų finansavimo ir skaičiuojamas banko kapitalo pakankumas (Truck, 2008). Pagrindinis kredito rizikos rodiklis yra kredito reitingas, kuris atspindi skolininko finansinių įsipareigojimų neįvykdymo tikimybę (PD). Kredito reitingas yra skolininko gebėjimo vykdyti finansinius įsipareigojimus vertinimo rodiklis. Komerciniai bankai klientų kredito rizikos matavimui taiko reitingų skales, panašias į tarptautinių reitingų agentūrų „Standard & Poor’s“, „Moody’s“ ir „Fitch Ratings“. Banko kliento kredito reitingas laiko momentu  $t$  yra  $R(t) = \{1, 2, \dots, K\}$ , kur aukštą ir žemą gebėjimą vykdyti finansinius įsipareigojimus parodo reitingai nuo 1 iki  $K-1$ , o paskutinis reitingas  $K$  reiškia įsipareigojimų nevykdymą. Reitingų žymėjimui bankuose naudojamos raidinės išraiškos, panašiai kaip agentūros „Standard & Poor’s“ reitingai {AAA, AA, A, BBB, BB, B, C}, kurie kartu su žemiausiu  $D$  reitingu sudaro  $K = 8$  pagrindinių reitingų skalę (Fei, Fuertes, Kalotychou, 2012). Dažniausiai kredito reitingas atspindi banko kliento įsipareigojimų neįvykdymo ateinančiais finansiniais metais tikimybę (Wozabal, Hochreiter, 2012).

Pastaraisiais metais bankuose mažinamos subjektyvaus ekspertinio vertinimo apimtys. Dažniau sudaromi ar išsigjami statistiniai modeliai, galintys įvertinti didelį informacijos kiekį ir ją transformuoti į kiekybinę kredito rizikos išraišką. Modelių

sudarymui taikomi statistiniai ir dirbtinio intelekto metodai, o modelio tinkamumo vertinimas remiasi klasifikavimo klaidos minimizavimu žinant neišvengiamą tikėtiną klaidingo klasifikavimo dalį (Odeh, Koduru, Featherstone, Das, Welch, 2011). Vidaus kredito reitingų modelių formavimas gali būti pakankamai brangus bankams, tačiau jų įdiegimas suteikia reikšmingų privalumų. Visų pirma, tikslūs kredito rizikos vertinimo rezultatai užtikrina banko veiklos stabilumą, kadangi mažesnės paskolų apimtys suteikiamos didelės rizikos ir nemokiems skolininkams. Antra, tiksliau įvertinama individuali skolininkų rizika, lyginant su standartizuotu metodu, sumažina rizikos kapitalo poreikį. Jei paskolos daugiausiai teikiamos maži rizikingiems skolininkams, bankas įgyja konkurencinį pranašumą, nes dėl susidarančio mažesnio rizikos kapitalo poreikio didesnė dalis banko finansinių išteklių gali būti skirta naujų paskolų teikimui arba investuota. Kadangi paskolų mokiems klientams palūkanos turi kompensuoti bankų patiriamus nuostolius dėl klientų nemokumo, tai padidėjęs patikimų klientų finansavimas mažina paskolų palūkanų normų vidurkį ir kreditų kainas banke (Antao, Lacerda, 2011). Todėl statistikos ir finansų inžinerijos tyrinėtojai kuria instrumentus, kuriais bankų netikrumas dėl paskolos susigrąžinimo transformuojamas į kiekybines kredito rizikos išraiškas. Inovatyvūs sprendimai kredito rizikos srityje sudaro galimybę tinkamai šią riziką įvertinti ir valdyti (Wigan, 2010).

Bankai turi galimybę pasirinkti nepriklausomus kintamuosius, kurie analizuojami įmonių reitingavimo procese. Dažnai kintamųjų rinkinį sudaro pelningumo, mokumo, kapitalo struktūros, turto naudojimo efektyvumo ir kiti santykiniai finansiniai rodikliai. Modeliais gali būti

vertinamas įmonės našumas, dydis, pinigų srantai, atsižvelgiama į bendruosius pramonės šakos rodiklius ir verslo ciklo stadiją. Analizuojami ir kokybiniai rodikliai: įmonės padėtis konkurentų atžvilgiu, valdymo kokybė ir pan. (Hovakimian, Kalyhan, Titman, 2012). Taip pat kredito reitingas priklauso nuo įmonės veiklos trukmės. Dažnai naujos įmonės, dėl duomenų analizei nepakankamumo, įgyja žemesnius reitingus, lyginant su ilgiau veikiančiomis įmonėmis, nors jų finansinė būklė panaši (Chen, Ho, Lin, Tsai, 2012). Įmonių finansinės būklės pokyčius, o tuo pačiu ir jų kredito riziką veikia sisteminiai veiksniai, t. y. makroekonominė šalies būklė ir pramonės šakos bendrieji rodikliai. Tyrimais nustatyta reikšminga skirtingų pramonės sektorių bankroto apimčių koreliacija, kuri reiškia, jog įmonių finansiniai įsipareigojimai nevykdomi ne tik bankams, bet ir tiekėjams bei verslo partneriams. Todėl vienos įmonės nemokumas dažnai perduodamas kitoms, ypačingai ekonominio nuosmukio laikotarpiais (Pu, Zhao, 2012). Taigi, bankams reikalingi instrumentai, papildomai įvertinantys makroekonominės aplinkos būklę. Ekonomikos pakilimo laikotarpis sąlygoja įmonių finansinės būklės gerėjimą ir kredito rizikos mažėjimą. Tuo tarpu nuosmukio laikotarpiu padidėja įmonių finansinių įsipareigojimų nevykdymo ir bankrotų apimtys. Jei banko vidaus reitingų modeliu makroekonominiai veiksniai neanalizuojami, nuosmukio laikotarpiu kredito rizika teikiant paskolas turi būti vertinama konservatyviau (Kubo, Sakai, 2011). Esant tam pačiam kredito rizikos lygiui, didesnę tikimybę gauti paskolas turi vertybinių popierių biržose kotiruojamos įmonės; taip pat įmonės, kurių veiklos laikotarpis praeityje yra pakankamai ilgas; didelės bendrovės; įmonės, taikančios tarptautinius apskaitos standartus;

kurių ataskaitos tikrinamos nepriklausomų auditorių; ilgą laiką esantys to paties banko klientai (Drakos, Giannakopoulos, 2011).

Pagal įvertintą kredito rizikos lygį nustatoma paskolų palūkanų norma. Įmonės, turinčios žemus reitingus, turi mokėti aukštesnes palūkanas arba paskolos joms nesuteikiamos. Todėl banko nustatyta paskolos palūkanų norma tuo pačiu atspindi ir tikėtiną skolininko įsipareigojimų nevykdymą. Teikdami paskolas bankai vertina tikėtinas pajamas ir palygina jas su nerizikingų investicijų pajamomis. Šiam vertinimui reitingų modeliu turi būti nustatyta įsipareigojimų neįvykdymo tikimybė PD. Atvirkščia šiam rodikliui yra tikimybė, kad paskola bus gražinta:  $P = 1 - PD$ . Ši tikimybė yra intervale  $0 \leq P \leq 1$ . Rizikingų paskolų atveju bankams yra alternatyva investuoti į nerizikingas paskolas ( $P = 1$ ), kurių palūkanų norma  $i_0$ . Įvykdžius įsipareigojimus, kredito sutarties pabaigoje banko gauta bendra pinigų suma lygi gražintai paskolai ( $C$ ) ir sumokėtoms palūkanoms:  $(1 + i_0)C$ . Taip pat bankas turimus finansinius išteklius gali skolinti didesnės rizikos skolininkui, kuriam bus nustatyta palūkanų norma  $i_1$ , kai  $i_1 > i_0$  (Czarnitzki, Kraft, 2007). Banko tikėtinos paskolos pajamos iš didesnės rizikos įmonės:

$$E_1(\pi) = P_1(1 + i_1)C \quad (1)$$

Teikiant mažos rizikos paskolas taip pat susiduriama su tam tikra įsipareigojimų neįvykdymo tikimybe ( $P < 1$ ), todėl banko tikėtinos paskolos pajamos iš mažos rizikos įmonės:

$$E_0(\pi) = P_0(1 + i_0)C \quad (2)$$

Bankas pasirinks rizikingesnį variantą, jei tenkinama sąlyga:

$$P_1(1 + i_1)C > P_0(1 + i_0)C \quad (3)$$

Galima išreikšti kritinę didesnės rizikos įmonės tikimybę, jog paskola bus gražinta:

$$P_{1kr} = \frac{P_0(1+i_0)}{1+i_1} \quad (4)$$

Jei  $P_1 > P_{1kr}$ , bankas suteiks paskolą didesnės rizikos skolininkui. Kiti kredito rizikos parametrai yra pozicijos vertė esant įsipareigojimų neįvykdymui (EAD) ir nuostolis dėl įsipareigojimų neįvykdymo (LGD). Kai skolininkas nevykdo įsipareigojimų, bankas turi galimybę perimti įkeistą turtą ir jį realizavęs atgauti visą ar dalį paskolos, todėl bankuose vertinamas LGD rodiklis, rodantis, kokios dalies EAD bankas nesusigrąžins. Taigi, paskolos suteikimą lemia ne tik PD vertė, bet ir įkeisto turto likvidumas (Thomas, Matuszyk, Moore, 2012). Svarbus kredito rizikos parametras taip pat yra kredito reitingo pokyčio tikimybė. Dėl makroekonominė pokyčių ir kitų veiksnių įmonės kredito reitingas nėra nekintantis, todėl suteikus paskolas bankuose vertinami galimi kredito rizikos lygio pokyčiai (Truck, 2008).

Galima teigti, kad finansinių įsipareigojimų neįvykdymo tikimybė yra svarbiausias kredito rizikos rodiklis, nes ši rizika susijusi su galimybe, jog skolininkas neįvykdys savo finansinių įsipareigojimų bankui. Finansinių įsipareigojimų neįvykdymu dažniausiai laikomas kredito sutartyje nustatytų įmokų bankui mokėjimo pažeidimas. Finansinių įsipareigojimų vykdymą lemia įmonės turimo turto likvidumas, o šių įsipareigojimų nevykdymo pasekmė yra įmonės pripažinimas nemokia. Įmonės nemokumas yra pagrindas bankrotui arba restruktūrizavimui. Kadangi kreditiniuose santykiuose bankas pagal kredito sutartyje nustatytas sąlygas

siekia susigrąžinti paskolintą pinigų sumą bei gauti palūkanas, t. y. sutarto dydžio atlyginimą už skolininko naudojimąsi laikinai suteiktu kapitalu, kredito gavėjas turi sugebėti pagrįsti galimybes ateityje vykdyti sutarties įsipareigojimus, o kreditorius turi sugebėti įvertinti kliento kredito riziką. Ši rizika gali būti apibūdinta ir kaip skolininko neapibrėžtumo problema, nes visada gali atsitikti, jog skolininkas negalės įvykdyti savo įsipareigojimų bankui pagal iš anksto sutartas sąlygas. Todėl bankai, norėdami sumažinti galimus nuostolius dėl kreditų suteikimo nepatikimiems klientams, turi sugebėti tinkamai kredito riziką įvertinti.

## Tyrimo metodika

Statistinių kredito rizikos vertinimo modelių formavimo procese pagrindinė problema yra sudaryti nepriklausomų kintamųjų rinkinį, apibūdinantį įmones, ir rasti tinkamus duomenų analizės metodus, kuriais būtų galima sėkmingai klasifikuoti įmones į atskiras rizikos grupes. Kredito rizikos vertinimo modeliams reikalingi praeities duomenys apie skolininkus ir jų įsipareigojimų vykdymą. Tačiau bankuose susiduriama su duomenų trūkumu apie nepatikimus klientus. Nauji klientai klasifikuojami remiantis klientų duomenimis, kurie yra gavę kreditus praeityje. Bankai dažniausiai neturi duomenų apie klientus, kuriems kreditas nebuvo suteiktas, t. y. dažnai ši mokymo imtis nebūna pakankama. Tai riboja modelių tikslumą, nes duomenys apie nepatikimus klientus turėtų daug reikšmingos informacijos modeliui. Šiame tyrime tokio pobūdžio problema sprendžiama analizuojant bankrutavusių įmonių duomenis, kurios laikomos nepatikimais banko klientais.

Įmonių kredito reitingų nustatymo modelio sudarymui naudota 150 veikiančių ir 50 bankrutavusių įmonių imtis. Remiantis 3 metų balanso ir pelno (nuostolių) atskaitų duomenimis, analizuota 15 santykinų finansinių rodiklių:

- Bendrasis pelningumas (GPM) = Bendrasis pelnas / Pardavimų pajamos.
- Veiklos pelningumas (APM) = Tipinės veiklos pelnas / Pardavimų pajamos.
- Grynasis pelningumas (NPM) = Grynasis pelnas / Pardavimų pajamos.
- Turto pelningumas (ROA) = Grynasis pelnas / Turtas.
- Nuosavo kapitalo pelningumas (ROE) = Grynasis pelnas / Nuosavas kapitalas.
- Bendrasis padengimo koeficientas (CR) = Trumpalaikis turtas / Trumpalaikiai įsipareigojimai.
- Skubaus padengimo koeficientas (QR) = (Trumpalaikis turtas – Atsargos ir išankstiniai apmokėjimai) / Trumpalaikiai įsipareigojimai.
- Padengimo grynaisiais pinigais koeficientas (CSR) = Pinigai ir jų ekvivalentai / Trumpalaikiai įsipareigojimai.
- Grynojo apyvartinio kapitalo ir turto santykis (WCA) = (Trumpalaikis turtas – Trumpalaikiai įsipareigojimai) / Turtas.
- Bendrasis mokumo koeficientas (SR) = Nuosavas kapitalas / Įsipareigojimai.
- Įsiskolinimo koeficientas (DR) = Įsipareigojimai / Turtas.
- Ilgalaikių skolų koeficientas (LDR) = Ilgalaikiai įsipareigojimai / (Ilgalaikiai įsipareigojimai + Nuosavas kapitalas).
- Ilgalaikio turto apyvartumas (FTA) = Pardavimų pajamos / Ilgalaikis turtas.
- Turto apyvartumas (AT) = Pardavimų pajamos / Turtas.
- Nepaskirstytojo pelno ir turto santykis (UBA) = Nepaskirstytasis pelnas / Turtas.

Indeksai (1, 2, ir 3) prie santykinų rodiklių santrumpų nurodo duomenų metus, kur „1“ reiškia naujausią įmonių finansinę informaciją.

Įmonių klasifikavimui taikyti dirbtinių neuronų tinklai (DNT), paviršiaus atsako regresija (angl. *response surface regression*), daugiamatė adaptyvioji regresija (angl. *multivariate adaptive regression splines* – MARS), faktorinė regresija (angl. *factorial regression*) ir klasterinė analizė. Duomenų apimties mažinimui atlikta faktorinė analizė ir skaičiuoti *F*-įverčiai. DNT klasifikavimo tikslumo vertinimui sudaryta objektų klasifikavimo matrica, kuria remiantis skaičiuotas teisingo klasifikavimo rodiklis (CCR), modelio jautrumas (Se) ir specifškumas (Sp). Taip pat nubrėžta ROC kreivė ir vertintas plotas po šia kreive – AUC.

Kiekvieno reitingo įmonių finansinių įsipareigojimų neįvykdymo tikimybės gautos skaičiuojant bankrutavusių įmonių skaičiaus (N) tam tikro reitingo grupėje ir bendro įmonių skaičiaus (I) toje grupėje santykį:

$$PD = \frac{N}{I} \times 100\% \quad (5)$$

Atrinkti klasifikavimo tikslumo rodikliai, kurie skaičiuojami remiantis klasifikavimo matrica, leis įvertinti modelio tinkamumą patikimų ir nepatikimų banko klientų atskyrimui. Greta šių rodiklių kredito rizikos vertinimo modelio kokybę taip pat leidžia įvertinti ir finansinių įsipareigojimų neįvykdymo tikimybės, nes mažėjant kredito reitingui, PD rodiklis turi didėti. Modelių patikimumo vertinimas yra labai reikšmingas modelių formavimo proceso etapas, nes pasirinktieji rodikliai padeda įvertinti sudaryto modelio įvairius parametrus bei bankui pasirinkti tinkamiausią modelį.

## Įmonių kredito reitingų nustatymo modelis

Įmonių kredito reitingų nustatymo modelio formavimo schema pavaizduota 1 pav. Visų pirma, įmonių bankroto galimybei prognozuoti buvo sudarytas dirbtinių neuronų tinklų modelis, kurio nepriklausomi kintamieji yra įmonių 45 santykiniai finansiniai rodikliai ( $x_1, x_2, \dots, x_{45}$ ), o priklausomas kintamasis – įmonės būklė (veikianti:  $y = 0$ ; bankrutavusi:  $y = 1$ ). Dirbtiniai neuronų tinklai pasižymi galimybe apdoroti didelius informacijos kiekius, todėl šiems modeliams duomenų apimties mažinimas taikant papildomus statistinius duomenų

analizės metodus nebuvo atliktas. Sudaryto DNT struktūra (2 pav.) yra:

$$MLP\ 28:28-20-1:1 \quad (6)$$

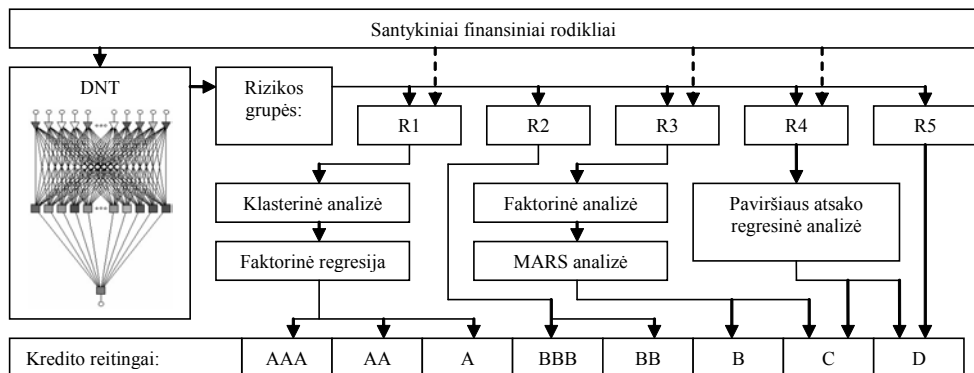
Ši DNT struktūra aprašyta taip:

$$DNT\ I:N-H-C:O \quad (7)$$

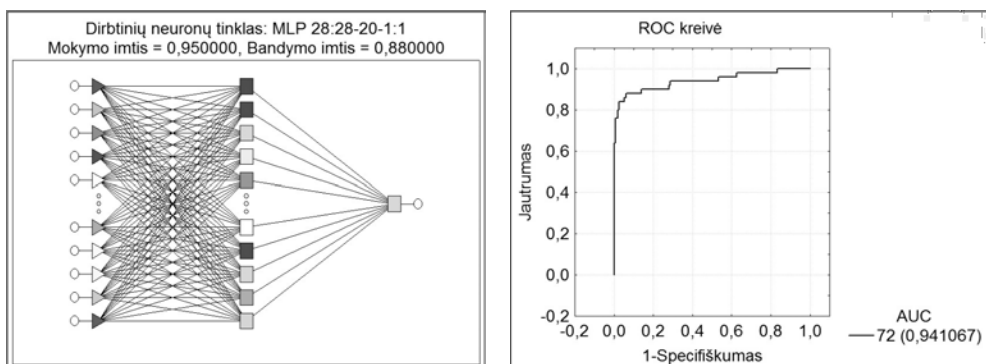
DNT – dirbtinių neuronų tinklo tipas (MLP – daugiasluoksnis perceptronas);  
I – įvedamų į tinklą kintamųjų skaičius (28 kintamieji);

N – neuronų skaičius įvesčių sluoksnyje (28);  
H – neuronų skaičius vidiniame sluoksnyje (20);

C – neuronų skaičius išvesčių sluoksnyje (1);  
O – išvesčių skaičius (1).



1 pav. Įmonių kredito reitingų nustatymo modelio formavimo schema



2 pav. DNT struktūra ir ROC kreivė

Įmonių klasifikavimui reikšmingi nepriklausomi kintamieji buvo nustatyti paties DNT, priskiriant jiems reikšmingumo rangus, kurių intervalas yra 0 – 100, t. y. 0 – kintamasis analizei nereikšmingas, 100 – kintamasis labai reikšmingas. DNT analizei reikšmingi 28 kintamieji ir jų reikšmingumo rangai yra:  $UBA_2$  (28),  $UBA_3$  (27),  $LDR_2$  (26),  $ROA_3$  (25),  $APM_2$  (24),  $CSR_2$  (23),  $CSR_1$  (22),  $CR_2$  (21),  $QR_3$  (20),  $WCA_1$  (19),  $NPM_1$  (18),  $UBA_1$  (17),  $ROE_1$  (16),  $AT_1$  (15),  $CR_3$  (14),  $GPM_2$  (13),  $APM_1$  (12),  $NPM_2$  (11),  $AT_3$  (10),  $ROE_3$  (9),  $ROE_2$  (8),  $GPM_3$  (7),  $AT_2$  (6),  $ROA_1$  (5),  $ROA_2$  (4),  $NPM_3$  (3),  $DR_1$  (2),  $APM_3$  (1).

DNT sudarymui naudotos įmonių imties klasifikavimo tikslumas yra 95 %, o sudaryto tinklo bandymo imties klasifikavimo tikslumas – 88 % (2 pav. *Mokymo imtis* = 0,95; *Bandymo imtis* = 0,88). DNT priklausomo kintamojo  $y$  vertės gautos intervale [0; 1], o DNT nustatytas įmonių klasifikavimo slenkstis yra  $y_s = 0,5185405$ . Įmonių klasifikavimo matrica pateikta 1 lentelėje.

DNT modelio bendrasis įmonių klasifikavimo tikslumas yra 93 %. Modelio

jautrumas – 80 %, specifiskumas – 97,3 %. Tai reiškia, kad modeliu teisingai klasifikuojama 80 % bankrutavusių ir 97,3 % veikiančių įmonių. Modelio kokybei įvertinti 2 pav. taip pat pateikta DNT modelio ROC kreivė ir skaitinė ploto po ROC kreive reikšmė AUC. Galima teigti, kad modelio diskriminacinė galia yra labai didelė, nes  $AUC = 0,941067$ , t. y. ši reikšmė artima vienetui.

Pagal Bazelio bankų priežiūros komiteto rekomendacijas, įmonių kredito rizikos vertinimui komerciniuose bankuose klientus suskirstyti tik į dvi rizikos grupes nepakanka. Kredito reitingų skalėje turi būti sudarytos ne mažiau kaip 7 patikimų klientų grupės ir ne mažiau kaip 1 nepatikimų klientų grupė. Todėl toliau, remiantis DNT modelio priklausomo kintamojo reikšmėmis  $y$ , įmonės buvo suskirstytos į 5 rizikos grupes R1 – R5 (2 lentelė).

2 lentelėje taip pat suskaičiuotos į rizikos grupes patenkančių įmonių finansinių įsipareigojimų neįvykdymo tikimybės (PD). R5 grupėje visos įmonės yra bankrutavusios, todėl į šią grupę patekusioms įmonėms priskiriamas kredito reitingas

1 lentelė

Įmonių klasifikavimo matrica

DNT rezultatai	Tikrosios reikšmės	
	0	1
0	146	10
1	4	40

2 lentelė

Įmonių rizikos grupės R1 – R5

Rizikos grupė	$y$ (DNT)	Įmonių sk.	Bankrutavusių įmonių sk.	PD (%)
R1	[0 – 0,1]	50	0	0
R2	(0,1 – 0,4]	43	2	4,7
R3	(0,4 – 0,6]	71	13	18,3
R4	(0,6 – 0,8]	8	7	87,5
R5	(0,8 – 1]	28	28	100



D (28 įmonės imtyje). Grupės R4 įmonės paviršiaus atsako regresijos (angl. *response surface regression*) modeliu klasifikuojamos į reitingų C ir D grupes. Regresijos modeliui sudaryti nepriklausomų kintamųjų skaičius buvo sumažintas programų paketu „Statistica“ skaičiuojant jiems  $F$ -įverčius (3 pav.). Buvo atrinkti 5 santykiniai finansiniai rodikliai, kurių  $F$ -įverčiai didžiausi.

Regresijos lygtis:

$$RSR = -6,81381 - 8,16731 \cdot CSR_1 + 13,87079 \cdot CSR_1^2 + 14,38068 \cdot LDR_1 - 7,52749 \cdot LDR_1^2 + 0,39675 \cdot FTA_1 - 0,00472 \cdot FTA_1^2 - 0,39707 \cdot ROE_2 - 0,00081 \cdot FTA_2 - 0,91730 \cdot CSR_1 \cdot ROE_2 \quad (8)$$

Rizikos grupės R4 įmonės klasifikuojamos taip:

- Jei  $RSR < 0,5$ , įmonei priskiriamas reitingas C (1 įmonė imtyje).
- Jei  $RSR \geq 0,5$ , įmonei priskiriamas reitingas D (7 įmonės imtyje).

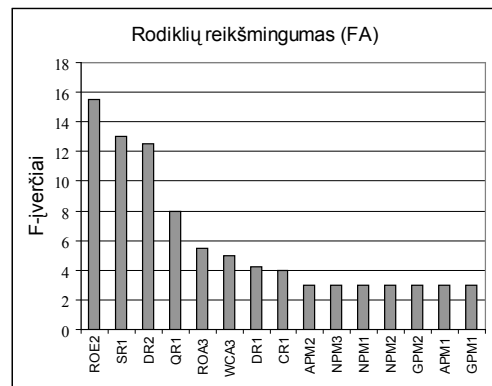
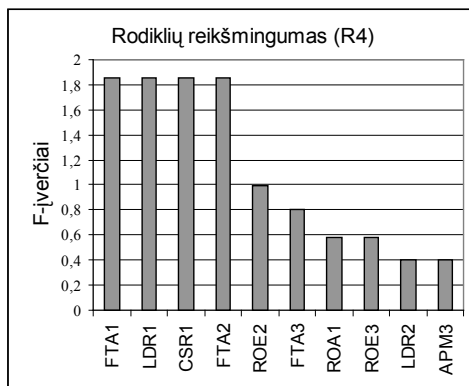
Analizuotoje imtyje reitingas D buvo priskirtas 35 bankrutavusioms įmonėms, todėl šio reitingo įmonių finansinių įsipareigojimų neįvykdymo tikimybė yra 100 %:

$$PD_D = \frac{N_D}{I_D} \times 100\% = \frac{35}{35} \times 100\% = 100\% \quad (9)$$

Rizikos grupės R3 įmonės klasifikuojamos į reitingų B ir C grupes daugiamatės adaptyviosios regresijos (angl. *multivariate adaptive regression splines – MARS*) modeliu. MARS modelio nepriklausomi kintamieji yra duomenų faktorišės analizės metu gauti faktorių įverčiai. Faktorišnei analizei iš pradinių 45 buvo atrinkta 15 santykinų finansinių rodiklių, kurių  $F$ -įverčiai įgyja didžiausias reikšmes (3 pav.). Faktorišės analizės metu buvo išskirti 5 faktoriai  $F_1 - F_5$ , kurių įverčių koeficientai, gauti atlikus sukimą *Varimax raw*, pateikti 3 lentelėje. Faktorių įverčiai gaunami įmonių santykinus finansinius rodiklius dauginant iš faktorių įverčių koeficientų ir sandaugas sudedant.

MARS modelis (analizei reikšmingi faktoriai  $F_2, F_4$  ir  $F_5$ ):

$$ST = 0,0214155646660226 + 6,99514538344111 \cdot \max(0; F_4 - 0,125529749756346) - 0,0809886664055308 \cdot \max(0; F_2 + 0,420087137121545) + 1,23132488857647 \cdot \max(0; -0,0726115293610564 - F_5) \quad (10)$$



3 pav.  $F$ -įverčiai R4 grupėje ir faktorišės analizės (FA) kintamieji

## Faktorių įverčių koeficientai

Rodikliai	Faktoriai				
	F <sub>1</sub>	F <sub>2</sub>	F <sub>3</sub>	F <sub>4</sub>	F <sub>5</sub>
GPM <sub>1</sub>	0,270876	-0,005395	-0,086423	-0,075359	0,022749
APM <sub>1</sub>	0,236285	-0,007843	0,023722	-0,060514	0,002626
NPM <sub>1</sub>	0,205522	0,013795	0,018373	-0,067863	-0,005610
CR <sub>1</sub>	-0,005086	0,344653	-0,016875	-0,006614	-0,013528
QR <sub>1</sub>	-0,003677	0,350330	-0,019505	-0,016476	-0,034084
SR <sub>1</sub>	0,000319	0,337103	-0,018697	-0,009205	-0,040267
DR <sub>1</sub>	0,029214	0,027853	-0,440422	0,066809	0,188925
GPM <sub>2</sub>	0,260284	-0,004364	-0,073856	-0,104879	-0,006379
APM <sub>2</sub>	0,159836	-0,003075	0,024698	0,333569	-0,059948
NPM <sub>2</sub>	-0,055020	-0,009152	-0,015072	0,748555	-0,040727
ROE <sub>2</sub>	0,044545	0,005352	0,135412	-0,365557	-0,235489
DR <sub>2</sub>	0,037369	0,014877	-0,425045	0,002052	0,138239
NPM <sub>3</sub>	0,011421	-0,029438	-0,173252	-0,057365	0,640951
ROA <sub>3</sub>	0,001656	-0,026282	0,079357	0,000945	0,375931
WCA <sub>3</sub>	-0,063196	0,026004	0,170719	0,025936	0,274663

Modeliu skaičiuojant priklausomo kintamojo ST reikšmę, MARS funkcijas  $\max(0; F_4 - 0,125529749756346)$ ,  $\max(0; F_2 + 0,420087137121545)$  ir  $\max(0; -0,0726115293610564 - F_5)$  pažymėjus  $BF_1$ ,  $BF_2$  ir  $BF_3$ , tenkinant žemiau nurodytas sąlygas gaunami lygties nepriklausomi kintamieji:

- Jei  $F_4 - 0,125529749756346 > 0$ , tai  $BF_1 = F_4 - 0,125529749756346$ ; priešingu atveju, jei  $F_4 - 0,125529749756346 \leq 0$ , tai  $BF_1 = 0$ .

- Jei  $F_2 + 0,420087137121545 > 0$ , tai  $BF_2 = F_2 + 0,420087137121545$ ; priešingu atveju, jei  $F_2 + 0,420087137121545 \leq 0$ , tai  $BF_2 = 0$ .

- Jei  $-0,0726115293610564 - F_5 > 0$ , tai  $BF_3 = -0,0726115293610564 - F_5$ ; priešingu atveju, jei  $-0,0726115293610564 - F_5 \leq 0$ , tai  $BF_3 = 0$ .

Rizikos grupės R3 įmonėms kredito reitingas priskiriamas taip:

- Jei  $ST < 0,5$ , įmonei priskiriamas reitingas B (14 įmonių imtyje).

- Jei  $ST \geq 0,5$ , įmonei priskiriamas reitingas C (57 įmonės imtyje).

B ir C reitingų įmonių finansinių įsipareigojimų neįvykdymo tikimybės:

$$PD_B = \frac{N_B}{I_B} \times 100\% = \frac{1}{14} \times 100\% = 7,1\% \quad (11)$$

$$PD_C = \frac{N_C}{I_C} \times 100\% = \frac{12}{58} \times 100\% = 20,7\% \quad (12)$$

Rizikos grupės R2 įmonėms priskiriami kredito reitingai BBB ir BB remiantis DNT priklausomo kintamojo reikšmėmis, esant klasifikavimo slenksčiui  $y_{BBB-BB} = 0,221$ :

Jei  $y \in (0,1; 0,221]$ , įmonei priskiriamas reitingas BBB (23 įmonės imtyje).

Jei  $y \in (0,221; 0,4]$ , įmonei priskiriamas reitingas BB (20 įmonių imtyje).

BBB ir BB reitingų įmonių finansinių įsipareigojimų neįvykdymo tikimybės:

$$PD_{BBB} = \frac{N_{BBB}}{I_{BBB}} \times 100\% = \frac{1}{23} \times 100\% = 4,3\% \quad (13)$$

$$PD_{BB} = \frac{N_{BB}}{I_{BB}} \times 100\% = \frac{1}{20} \times 100\% = 5,0\% \quad (14)$$

Rizikos grupės R1 įmonėms priskiriami kredito reitingai AAA, AA ir A pagal jų finansinę būklę. Atlikus R1 grupės įmonių klasterinę analizę  $k$ -vidurkių metodu, buvo išskirti 3 įmonių klasteriai (4 lentelė). Analizė atlikta remiantis įmonių paskutiniųjų metų 8 finansiniais rodikliais.

4 lentelėje pateikti santykinų finansinių rodiklių klasteriuose vidurkiai. Visi klasteriai pasižymi aukštais rodikliais, kas parodo gerą rizikos grupės R1 įmonių finansinę būklę ir patikimumą kreditoriams. Aukščiausi pelningumo, mokumo ir kapitalo struktūros rodikliai yra 1 klasteryje, o 2 ir 3 klasteriuose jie tolygiai kinta blogėjimo kryptimi. Visų klasterių įmonių veikla yra pelninga ( $GPM_1 > 0$  ir  $NPM_1 > 0$ ), taip pat visų klasterių įmonės yra mokios ( $CR_1 > 1$ ,  $QR_1 > 1$  ir  $WCA_1 > 0$ ). Ypačingai aukštą mokumą R1 grupėje parodo padengimo gryniaisiais pinigais koeficientas ( $CSR_1$ ), t. y. 1-ojo klasterio įmonės vidutiniškai gali turimais pinigais padengti 2,6 karto daugiau trumpalaikių įsipareigojimų, nei jų turi. 2-ojo ir 3-iojo klasterių įmonės savo turimais pinigais vidutiniškai gali padengti atitinkamai 37,5 % ir 25,7 % trumpalaikių įsipareigojimų. Esminių skirtumų yra įmonių kapitalo struktūroje:

1-ojo klasterio įmonių nuosavas kapitalas yra vidutiniškai 11,3 karto didesnis už įsipareigojimus, 2-ojo klasterio – 1,3 karto. Didesniais įsipareigojimais pasižymi 3-iojo klasterio įmonės, kurių nuosavas kapitalas sudaro 80,7 % įsipareigojimų ( $SR_1 = 0,807$ ). Įsiskolinimo koeficiento reikšmės parodo, kad 1-ojo klasterio įmonėse vidutiniškai tik 10,2 % turto įsigyta už skolintas lėšas. 2-ojo ir 3-iojo klasterio įmonės visiškai saugią kreditoriams įsiskolinimų ribą peržengia ( $DR_1 > 0,5$ ), nes čia skolintu kapitalu finansuota atitinkamai 55,5 % ir 60,3 % įmonių turto.

Įmonių reitingavimo procese reitingų AAA, AA ir A priskyrimui sudarytas faktorinės regresijos modelis (angl. *factorial regression*). Modeliu analizuojami 8 santykiniai finansiniai rodikliai (nepriklausomi kintamieji), o įmonių klasterių atskyrimui nurodytos 3 priklausomo kintamojo  $Z_i$  reikšmės:  $Z_{AAA} = 100$ ,  $Z_{AA} = 200$  ir  $Z_A = 300$ .

Faktorinės regresijos lygtis:

$$Z = -4,332 + 8,239 \cdot GPM_1 + 433,265 \cdot NPM_1 + 11,760 \cdot CR_1 + 6,337 \cdot QR_1 - 0,648 \cdot CSR_1 - 37,413 \cdot WCA_1 - 2,048 \cdot SR_1 - 2,803 \cdot DR_1 - 426,497 \cdot GPM_1 \cdot NPM_1 - 23,449 \cdot GPM_1 \cdot CR_1 - 242,576 \cdot NPM_1 \cdot CR_1 - 11,078 \cdot GPM_1 \cdot QR_1 - 27,947 \cdot NPM_1 \cdot QR_1 - 6,078 \cdot CR_1 \cdot QR_1 - 32,182 \cdot GPM_1 \cdot CSR_1 - 56,959 \cdot$$

4 lentelė

Rizikos grupės R1 įmonių klasterinės analizės rezultatai

Rodiklis	1 klasteris	2 klasteris	3 klasteris
$GPM_1$	0,49530	0,333642	0,118494
$NPM_1$	0,24180	0,089676	0,018243
$CR_1$	8,61270	1,938323	1,437640
$QR_1$	8,33956	1,281780	1,276664
$CSR_1$	2,61930	0,374844	0,257425
$WCA_1$	0,54777	0,313375	0,200320
$SR_1$	11,29313	1,335889	0,806665
$DR_1$	0,10233	0,555025	0,602634

$$\begin{aligned}
& NPM_1 \cdot CSR_1 + 17,008 \cdot CR_1 \cdot CSR_1 - 3,144 \\
& \cdot QR_1 \cdot CSR_1 + 56,081 \cdot GPM_1 \cdot WCA_1 + \\
& 134,843 \cdot NPM_1 \cdot WCA_1 - 0,677 \cdot CR_1 \cdot \\
& WCA_1 + 10,683 \cdot QR_1 \cdot WCA_1 - 21,540 \cdot \\
& CSR_1 \cdot WCA_1 + 10,043 \cdot GPM_1 \cdot SR_1 - 67,773 \\
& \cdot NPM_1 \cdot SR_1 + 0,538 \cdot CR_1 \cdot SR_1 - 1,263 \cdot QR_1 \\
& \cdot SR_1 - 1,832 \cdot CSR_1 \cdot SR_1 + 10,969 \cdot WCA_1 \\
& \cdot SR_1 + 28,071 \cdot GPM_1 \cdot DR_1 - 184,869 \cdot \\
& NPM_1 \cdot DR_1 - 1,497 \cdot CR_1 \cdot DR_1 + 1,524 \\
& \cdot QR_1 \cdot DR_1 - 7,346 \cdot CSR_1 \cdot DR_1 + 19,314 \\
& \cdot WCA_1 \cdot DR_1 + 355,597 \cdot GPM_1 \cdot NPM_1 \cdot \\
& CR_1 + 22,383 \cdot GPM_1 \cdot NPM_1 \cdot QR_1 - 0,127 \\
& \cdot GPM_1 \cdot CR_1 \cdot QR_1 + 39,247 \cdot NPM_1 \cdot CR_1 \\
& \cdot QR_1 + 204,080 \cdot GPM_1 \cdot NPM_1 \cdot CSR_1 - \\
& 17,867 \cdot GPM_1 \cdot CR_1 \cdot CSR_1 - 18,460 \cdot NPM_1 \\
& \cdot CR_1 \cdot CSR_1 + 32,294 \cdot GPM_1 \cdot QR_1 \cdot CSR_1 - \\
& 1,215 \cdot CR_1 \cdot QR_1 \cdot CSR_1 - 737,909 \cdot GPM_1 \\
& \cdot NPM_1 \cdot WCA_1 - 12,926 \cdot GPM_1 \cdot CR_1 \cdot \\
& WCA_1 + 173,517 \cdot NPM_1 \cdot CR_1 \cdot WCA_1 + \\
& 32,649 \cdot GPM_1 \cdot QR_1 \cdot WCA_1 - 117,954 \cdot \\
& NPM_1 \cdot QR_1 \cdot WCA_1 - 3,025 \cdot CR_1 \cdot CSR_1 \cdot \\
& WCA_1 \quad (15)
\end{aligned}$$


Rizikos grupės R1 įmonėms kredito reitingas priskiriamas taip:

- Jei  $Z < 150$ , įmonei priskiriamas reitingas AAA (3 įmonės imtyje).
- Jei  $Z \in [150; 250]$ , įmonei priskiriamas reitingas AA (43 įmonės imtyje).
- Jei  $Z > 250$ , įmonei priskiriamas reitingas A (4 įmonės imtyje).

Faktorinės regresijos modeliu buvo

teisingai klasifikuota 100 % rizikos grupės R1 įmonių. Kadangi šioje grupėje nėra bankrutavusių įmonių, tai reitingų AAA, AA ir A finansinių įsipareigojimų neįvykdymo tikimybės yra 0. Tačiau Bazelio bankų priežiūros rekomendacijose nurodyta, kai pozicijos priskiriamos institucijų, įmonių ir mažmeninių pozicijų grupėms, PD negali būti mažesnė kaip 0,03 % (Lietuvos bankas, 2006). Pasauliniu mastu analizuojant dideles įmonių imtis įrodyta, kad net ir aukščiausių reitingų įmonėms statistiškai egzistuoja 0,03 % tikimybė neįvykdyti įsipareigojimų kreditoriams. Visų reitingų įmonių finansinių įsipareigojimų neįvykdymo tikimybės pavaizduotos 4 pav.

Tyrimo rezultatai rodo, kad didėjant įmonių kredito reitingui, jų finansinių įsipareigojimų neįvykdymo tikimybė mažėja, todėl sudarytas modelis yra tinkamas įmonių kredito rizikos vertinimui. Remiantis atliktu įmonių reitingavimu, bankui tikslinga finansuoti įmones, turinčias reitingus AAA – C, ir netikslinga finansuoti įmonių, kurių reitingas yra D. Analizuotų įmonių imties ilgalaikės ir trumpalaikės finansinės skolos sudaro 294 534 203 Lt. Reitingo D įmonėms nebūtų suteikta 19 712 102 Lt paskolų, o banko paskolų portfelis reitingų AAA – C įmonėms sudarytų 274 822 101 Lt (5 lentelė).



4 pav. Kredito reitingai ir finansinių įsipareigojimų neįvykdymo tikimybės (PD)

5 lentelė

Įmonių reitingavimo rezultatai

Kredito reitingas	Paskolų portfelis (P), Lt	Neįvykdyti įsipareigojimai (N <sub>i</sub> ), Lt	Neįvykdytų įsipareigojimų dalis, %	Paskolos palūkanų norma (r <sub>i</sub> ), %
AAA	392 759	0	0	10
AA	141 609 210	0	0	10
A	9 129 215	0	0	10
BBB	33 055 144	34 935	0,105687	10,01058
BB	5 612 844	54 965	0,979272	10,0989
B	35 837 180	1 104 830	3,082916	10,3181
C	49 185 749	7 066 658	14,36729	11,67778
Iš viso	274 822 101	8 261 388	3,006086	-

Bankas gali būti nustatęs pageidaujamą paskolų portfelio pelningumą (pvz.,  $S = 10\%$ ). Tokiu atveju, esant visiškam klientų mokumui, per metus banko palūkanų pajamos sudarytų 27 482 210 Lt. Tačiau kredito rizikos vertinimo modeliu nebuvo pasiektas 100 % įmonių klasifikavimo tikslumas, todėl neįvykdyti įsipareigojimai paskolų portfelyje sudarytų 8 261 388 Lt, t. y. 3 %. Šiuos banko nuostolius turi kompensuoti įsipareigojimus vykdantys klientai, į kurių paskolų palūkanų normą būtų įskaičiuotas ir reitingo rizikos priedas. Norint išlaikyti banko paskolų portfelio pelningumą esant įsipareigojimų nevykdymui turi būti tenkinama sąlyga:

$$r_i \times (P_i - N_i) = S \times P_i \quad (16)$$

Atsižvelgiant į sudaryto kredito rizikos vertinimo modelio rezultatus galima nustatyti paskolų palūkanų normą įmonėms, turinčioms skirtingus kredito reitingus:

$$r_i = \frac{S \times P_i}{P_i - N_i} \quad (17)$$

Paskolų palūkanų normos, kurios įvertina banko pageidaujamą pelningumą ir rizikos priedą, suskaičiuotos 5 lentelėje.

Didžiausios rizikos grupės (reitingas C) paskolų palūkanų norma yra 1,68 % didesnė nei mažiausios rizikos įmonių grupėje. Taigi, sudarytas įmonių kredito reitingų modelis gali padėti bankams priimti sprendimą dėl paskolos suteikimo atsižvelgiant į įmonės finansinių įsipareigojimų neįvykdymo tikimybę. Taip pat atsižvelgiant į paskolos dydį ir įmonės kredito rizikos lygį bankas gali suskaičiuoti suteikiamai paskolai būtiną rizikos kapitalo dydį. Siekiant pageidaujamo paskolų portfelio pelningumo, modelio rezultatai padeda nustatyti paskolos palūkanų normą skirtingo rizikos lygio įmonėms. Jei banko paskolų fondas ribotas, o bankas dėl tam tikrų priežasčių nori finansuoti didesnės rizikos įmonę, turi būti laikomasi (3) formulėje nurodytos sąlygos, padidinant 5 lentelėje nurodytas paskolų palūkanų normas.

## Išvados

Įgyvendinant Bazelio bankų priežiūros komiteto rekomendacijas komerciniams bankams aktualu ieškoti metodų ir rodiklių, kuriais remiantis galima sudaryti vidaus reitingų modelius ir vertinti įmonių

kredito riziką. Tikslusis kredito rizikos vertinimas sudaro galimybę sumažinti banko nuostolius bei kapitalo poreikį, o taip pat ir palūkanų normas skolininkams, jei paskolos suteikiamos daugiausiai finansinius įsipareigojimus vykdantiems klientams. Tačiau egzistuoja patikimo kredito rizikos modelio sudarymo problema, kuri dažniausiai sprendžiama pasitelkiant daugiamacių statistinius ir dirbtinio intelekto metodus. Dėl analizuojamų duomenų sudėtingumo vieno metodo pritaikymas dažnai sudaro galimybę tik atskirti įsipareigojimus gebančius vykdyti banko klientus nuo nemokių klientų. Remiantis tokių modelių rezultatais negalima įvertinti banko kapitalo pakankamumo, objektyviai nustatyti paskolų palūkanų normų ir įgyvendinti kitų Bazelio bankų priežiūros komiteto rekomendacijų. Todėl norint įmones klasifikuoti į 8 ar daugiau rizikos grupių, tenka pasitelkti kelių duomenų analizės metodų kombinaciją, o duomenų analizės procesas tampa sudėtingesnis ir apima didesnę etapų skaičių.

Tyrimo rezultatai parodė, kad taikant dirbtinių neuronų tinklus kartu su kitais statistiniais duomenų analizės metodais galima suformuoti veiksmingą įmonių kredito rizikos vertinimo modelį, kuriuo nustatomas įmonės kredito reitingas

ir įvertinama finansinių įsipareigojimų neįvykdymo tikimybė per ateinančius finansinius metus. Modelis tinkamas vertinti įmonių kredito rizikai, kurių veiklos trukmė yra ne trumpesnė kaip 3 metai. Statistinių duomenų analizės metodų taikymas gali sumažinti banko darbuotojų darbo apimtis vertinant kredito riziką ir su tuo susijusius paskolų administravimo kaštus. Tai sutrumpina bendrą kredito rizikos vertinimo proceso trukmę. Rezultatas apie kliento kredito riziką gaunamas į modelį įvedus reikalingus duomenis apie klientą.

Sudaryto įmonių kredito reitingų modelio skalėje mažėjant kredito reitingui, įmonių finansinių įsipareigojimų neįvykdymo tikimybė tolygiai didėja. Remiantis modelio rezultatais, AAA – C reitingų įmonės būtų finansuojamos, o D reitingo įmonėms paskolos nebūtų suteikiamos. Modeliu nustatyta įmonių finansinių įsipareigojimų neįvykdymo tikimybė gali padėti suskaičiuoti rizikos kapitalo poreikį bankuose ir nustatyti finansuojamų įmonių paskolų palūkanų normą. Bankams, siekiantiems didesnių pajamų ir prisiimantiems didesnę kredito riziką, straipsnyje nurodyta sąlyga, kurios laikantis gali būti finansuojamos rizikingesnės įmonės.

## Literatūra

1. Antao, P., Lacerda, A. (2011). Capital Requirements under the Credit Risk-Based Framework // *Journal of Banking & Finance*. Vol. 35, pp. 1380-1390. doi: [10.1016/j.jbankfin.2010.10.003](https://doi.org/10.1016/j.jbankfin.2010.10.003).
2. Brown, I., Mues, C. (2012). An Experimental Comparison of Classification Algorithms for Imbalanced Credit Scoring Data Sets // *Expert Systems with Applications*. Vol. 39, pp. 3446-3453. doi: [10.1016/j.eswa.2011.09.033](https://doi.org/10.1016/j.eswa.2011.09.033).
3. Chen, Y. S., Ho, P. H., Lin, C. Y., Tsai, W. C. (2012). Applying Recurrent Event Analysis to Understand the Causes of Changes in Firm Credit Ratings // *Applied Financial Economics*. Vol. 22, pp. 977-988. doi: [10.1080/09603107.2011.633888](https://doi.org/10.1080/09603107.2011.633888).
4. Chen, W., Xiang, G., Liu, Y., Wang, K. (2012). Credit Risk Evaluation by Hybrid Data Mining Technique // *Systems Engineering Procedia*. Vol. 3, pp. 194-200. doi: [10.1016/j.sepro.2011.10.029](https://doi.org/10.1016/j.sepro.2011.10.029).

5. Czarnitzki, D., Kraft, K. (2007). Are Credit Ratings Valuable Information? // *Applied Financial Economics*. Vol. 17, pp. 1061-1070. doi: [10.1080/09603100600749220](https://doi.org/10.1080/09603100600749220).
6. Derelioglu, G., Gurgun, F. (2011). Knowledge Discovery Using Neural Approach for SME's Credit Risk Analysis Problem in Turkey // *Expert Systems with Applications*. Vol. 38, pp. 9313-9318. doi: [10.1016/j.eswa.2011.01.012](https://doi.org/10.1016/j.eswa.2011.01.012).
7. Drakos, K., Giannakopoulos, N. (2011). On the Determinants of Credit Rationing: Firm-Level Evidence from Transition Countries // *Journal of International Money and Finance*. Vol. 30, pp. 1773-1790. doi: [10.1016/j.jimonfin.2011.09.004](https://doi.org/10.1016/j.jimonfin.2011.09.004).
8. Fei, F., Fuertes, A. M., Kalotychou, E. (2012). Credit Rating Migration Risk and Business Cycles // *Journal of Business Finance & Accounting*. Vol. 39, No. 1, pp. 229-263. doi: [10.1111/j.1468-5957.2011.02272.x](https://doi.org/10.1111/j.1468-5957.2011.02272.x).
9. Hovakimian, A., Kayhan, A., Titman, S. (2012). Are Corporate Default Probabilities Consistent with the Static Trade-off Theory? // *The Review of Financial Studies*. Vol. 25, No. 2, pp. 315-340. doi: [10.1093/rfs/hhr101](https://doi.org/10.1093/rfs/hhr101).
10. Khashman, A. (2011). Credit Risk Evaluation Using Neural Networks: Emotional Versus Conventional Models // *Applied Soft Computing*. Vol. 11, pp. 5477-5484. doi: [10.1016/j.asoc.2011.05.011](https://doi.org/10.1016/j.asoc.2011.05.011).
11. Kubo, H., Sakai, Y. (2011). On Long-Term Credit Risk Assessment and Rating: Towards a New Set of Models // *Journal of Risk Research*. Vol. 14, No. 9, pp. 1127-1141. doi: [10.1080/13669877.2011.571793](https://doi.org/10.1080/13669877.2011.571793).
12. Lietuvos bankas (2006). Kapitalo pakankamumo skaičiavimo bendrosios nuostatos.
13. Odeh, O., Koduru, P., Featherstone, A., Das, S., Welch, S. M. (2011). A Multi-Objective Approach for the Prediction of Loan Defaults // *Expert Systems with Applications*. Vol. 38, pp. 8850-8857. doi: [10.1016/j.eswa.2011.01.096](https://doi.org/10.1016/j.eswa.2011.01.096).
14. Pu, X., Zhao, X. (2012). Correlation in Credit Risk Changes // *Journal of Banking & Finance*. Vol. 36, pp. 1093-1106. doi: [10.1016/j.jbankfin.2011.11.002](https://doi.org/10.1016/j.jbankfin.2011.11.002).
15. Ramanauskas, T. (2011). A Macroeconometric Model with the Financial Sector for the Case of the Lithuanian Economy // *Pinių studijos*. Vol. 15, No. 1, pp. 5-30.
16. Thomas, L. C., Matuszyk, A., Moore, A. (2012). Comparing Debt Characteristics and LGD Models for Different Collections Policies // *International Journal of Forecasting*. Vol. 28, pp. 196-203. doi: [10.1016/j.ijforecast.2010.11.004](https://doi.org/10.1016/j.ijforecast.2010.11.004).
17. Truck, S. (2008). Forecasting Credit Migration Matrices with Business Cycle Effects – a Model Comparison // *The European Journal of Finance*. Vol. 14, No. 5, pp. 359-379. doi: [10.1080/13518470701773635](https://doi.org/10.1080/13518470701773635).
18. Wang, G., Ma, J. (2012). A Hybrid Ensemble Approach for Enterprise Credit Risk Assessment Based on Support Vector Machine // *Expert Systems with Applications*. Vol. 39, pp. 5325-5331. doi: [10.1016/j.eswa.2011.11.003](https://doi.org/10.1016/j.eswa.2011.11.003).
19. Wigan, D. (2010). Credit Risk Transfer and Crunches: Global Finance Victorious or Vanquished? // *New Political Economy*. Vol. 15, No. 1, pp. 109-125. doi: [10.1080/13563460903553673](https://doi.org/10.1080/13563460903553673).
20. Wozabal, D., Hochreiter, R. (2012). A Coupled Markov Chain Approach to Credit Risk Modeling // *Journal of Economic Dynamics & Control*. Vol. 36, pp. 403-415. doi: [10.1016/j.jedc.2011.09.011](https://doi.org/10.1016/j.jedc.2011.09.011).

Straipsnis įteiktas: 2012 08 20

Parengtas publikuoti: 2012 12 01

**Ričardas MILERIS**

## **ASSESSMENT OF ENTERPRISE DEFAULT PROBABILITY BY CREDIT RATING MODEL**

### **S u m m a r y**

The banks have an important influence on the whole economic development of countries so their activity is regulated. The recommendations of the Basel Committee on Banking Supervision (BCBS) for the credit risk management are rewritten in

the national law that banks must follow. The main credit risk parameter is credit rating that reflects the default probability of a company. In recent years banks reduce the credit risk assessment by the expert evaluation and develop the statistical

models that enable to analyze the high amount of information and to transform it into the quantitative credit risk measure. Banks develop the internal credit risk assessment models seeking for the higher classification accuracy. Implementing the recommendations of the BCBS it is important to look for the methods and variables that allow to assess the credit risk in banks. The exact credit risk assessment enables to reduce the loss and the demand of capital in banks. Also it makes opportunity to reduce the interest rates for debtors if bank finances mostly the solvent clients. In the scientific literature mostly the research results are published about the classification of companies into two risk groups. However, there is a lack in publications how to classify companies into 8 risk groups according to the BCBS recommendations. So in this research such model was developed.

The **object** of this research is the default probability of companies. The **aim** of this research is to develop the credit risk assessment model for the attribution of credit ratings for companies and the evaluation of their default probability. The two **tasks** were set in this research. First, to subject the main credit risk parameters and their assessment peculiarities. Second, to develop the credit risk assessment model applying the statistical and artificial intelligence techniques. For the development of credit risk assessment model the data sample of 150 profitable and 50 bankrupted companies was used. The 15 financial ratios were calculated from the financial reports of 3 years. The **methods** of this research consist of the analysis of scientific publications and the statistical analysis of financial data. The artificial neural networks (ANN), response surface regression, multivariate adaptive regression splines (MARS), factorial regression and cluster analysis were employed for the solving of companies classification problem. The data reduction was accomplished by factor analysis and calculating the *F*-values. The objects classification matrix was compounded to estimate the classification accuracy of ANN. The overall accuracy, sensitivity and specificity were measured. The discrimination power of ANN model also was estimated by the ROC curve and the area under ROC curve (AUC). The default probabilities of every credit rating were calculated dividing the number of bankrupted companies by the number of companies in the particular rating group.

For the prediction of bankruptcy possibility the artificial neural networks model was developed that analyzes the initial 45 financial ratios. The overall accuracy of ANN model was 93 %, sensitivity – 80 %, specificity – 97,3 %. According to the ANN result  $y \in [0; 1]$ , the companies were separated into 5 risk groups R1 – R5. In group R5 all companies bankrupted, so for this group the rating D was attributed. The data of companies in risk group R4 was analyzed by the response surface regression model and these companies were classified into C and D rating groups. The data reduction for the response surface regression model was accomplished selecting the independent variables with the highest *F*-values. The companies of risk group R3 were classified into B and C rating groups by the MARS model. The independent variables in the MARS model are the factor scores estimated by factor analysis. The ratings BBB and B were attributed for the companies of risk group R2 according to the value of the ANN dependent variable. The ratings AAA, AA and A were attributed for companies of the risk group R1 depending on their financial condition. The 3 clusters were extracted in this group by the *k*-means cluster analysis and the significant differences of financial ratios in clusters were observed. For the attribution of credit ratings the factorial regression model was developed that analyzes 8 financial ratios of the last year.

The results of this research have shown that combining the artificial neural networks with other statistical analysis techniques it is possible to develop the workable credit risk assessment model. It allows to attribute the credit ratings for companies and evaluate their default probability in the next financial year. The model is valid to assess the credit risk of companies that work 3 years and longer. In the rating scale of the developed model, the probability of default increases from 0,03 % to 100 % when the credit ratings decrease. According to the credit risk assessment results a bank should finance the companies with ratings AAA – C and not finance the D rating companies. The developed model allows not only to make a decision about a company's creditworthiness and to calculate the risk capital of a bank, but also helps to set the loan interest rate for the companies with different ratings. For banks that seek to increase the interest income and to take the higher risk, the condition in this paper was explained, when it is worth to finance companies with the higher credit risk level.