

## LIETUVOS KREDITO UNIJŲ VEIKLOS RIZIKINGUMO VERTINIMAS

Vytautas Kėdaitis<sup>1</sup>, Evaldas Žilinskas<sup>2</sup>

<sup>1</sup>Vilniaus universitetas, Ekonomikos fakultetas, Kiekybinių metodų ir modeliavimo katedra  
Adresas: Saulėtekio al. 9, LT-10222 Vilnius, Lietuva. El. paštas: vytautas.kedaitis@ef.vu.lt

<sup>2</sup>AB DNB Bankas. Adresas: J. Basanavičiaus g. 26, LT-03601 Vilnius, Lietuva  
El. paštas: zevaldas@gmail.com

Gauta: 2013 m. birželis

Pataisyta: 2013 m. rugsėjis

Paskelbta: 2013 m. lapkritis

**Santrauka.** Straipsnyje apibūdinamos Lietuvos kredito unijų veiklos rizikingumo vertinimo galimybės taikant skirtingus daugiamatės analizės metodus (sprendimų medžių CART, CHAID ir išsamiojo CHAID bei dirbtinių neuroninių tinklų modelių), atliekamas jų lyginimas, pagrindžiamas patikimumas ir tikslingumas vertinant gautus rezultatus, taip pat tikrinamas modelių stabilumas laiko požiūriu, įvertinamas gautų rezultatų patikimumas ir pagrindžiamas šių modelių tinkamumas tiriant Lietuvos kredito unijų bankroto galimybes.

**Reikšminiai žodžiai:** kredito unijos, sprendimų medis, dirbtiniai neuroniniai tinklai, rizikingumas, vertinimas.

### 1. Įvadas

Kredito unijos pagrindinis tikslas – suburti dvi grupes žmonių: turinčių laisvų lėšų ir norinčių jas tikslingai panaudoti bei norinčių pasiskolinti pinigų ir taip įgyvendinti savo siekius. Kredito unijos veikla turėtų būti skirta kuo labiau padidinti savo narių naudą, t. y. indėlininkai turėtų gauti kuo didesnes palūkanas už indėlius, o skolininkai mokėti kuo mažesnes palūkanas už paskolas. Tačiau dėl spartaus kredito unijų augimo pastaraisiais metais (per 2011 metus jų turtas padidėjo 27,5 procento, o per 2012 metus – 26,4 procento) ir kai kurių kredito unijų atitolimo nuo klasikinio kredito unijų apibrėžimo Lietuvos rinkoje susidarė unikali situacija [22]. Lietuvos banko teigimu, kredito unijos, didesnėmis negu vidutinės rinkoje terminuotųjų indėlių metinėmis palūkanų normomis priimdamos indėlius iš neprofesionalių rinkos dalyvių, siekė pritraukti kuo daugiau lėšų, kurios vėliau buvo investuojamos į rizikingus aktyvus, tinkamai neįvertinus prisiimamos kredito rizikos ir neturint pakankamai kapitalo galimybės nuostoliams dengti. Dėl šių priežasčių reikalavimai kredito unijoms buvo griežtinami siekiant išvengti galimų problemų. Vien per 2012 metus jie buvo griežtinami kelis kartus, visų pirma, įvedant kvalifikacinius egzaminus kredito unijų vadovams. Sparčiai augančioms kredito unijoms nuspręsta taikyti didesnius likvidumo rodiklio reikalavimus, be to, įvesti papildomus didžiausios paskolos vienam skolininkui apribojimus ir didesnius kapitalo pakankamumo rodiklius, daugiau paskolų asocijuotiesiems nariams (paprastai juridiniams asmenims) išdavusioms kredito unijoms. Nors kredito unijų pagrindinis tikslas nėra pelningumas, jau keletą metų iš eilės didėja jų nuostolingumas (2010 metais jis buvo 5,4 mln. litų, 2011 metais – 14 mln. litų, o 2012 metais – 55,1 mln. litų) [22].

Susidarius tokiai situacijai tapo aktualu nustatyti kredito unijas, kurios kelia daugiausia problemų, t. y. turi didžiausią riziką ar net gali bankrotuoti. Žinoti tokias kredito unijas gali būti naudinga ne tik priežiūros institucijoms, bet ir esamiems bei būsimiems kredito unijų nariams, norintiems įvertinti kredito unijos patikimumą.

Kredito unijų rizikingumui nustatyti nagrinėjami bankroto prognozės modeliai. Tokie modeliai pasirinkti todėl, kad kredito unijos, prisiimančios didelę riziką, anksčiau ar vėliau gali tapti nemokiomis ir bankrotuoti.

### 2. Bankroto prognozės modeliai

Tyrimų, susijusių su kredito unijų bankrotu ar nemokumu, atlikta labai nedaug, o tyrimams naudojamų modelių skaičius taip pat nedidelis. Daug daugiau tyrimų atlikta kitose srityse, pavyzdžiui, taip buvo vertinami bankai ar vienoje šalyje veikiančios įmonės. Todėl jau galima atlikti tam tikrus palyginimus ir daryti išvadą, kuris modelis yra tinkamesnis, ir pasiekti geresnių prognozavimo rezultatų.

Lietuvoje taip pat buvo atlikta keletas įmonių bankroto prognozės tyrimų, bet daugiausia dėmesio buvo skiriama klasikiniais modeliais. Viena iš tyrimų buvo lyginami Altmano (pirmasis – dviejų rodiklių modelis, antrasis – įmonių, kurių akcijos kotiruojamos vertybinių popierių biržoje, modelis, trečiasis – įmonių, kurių akcijos nekotiruojamos biržoje, modelis), Liso, Tafflerio, Springate'o modeliai ir padarytos analogiškos išvados – modeliais grįstos prognozės beveik atitinka realią Lietuvos įmonių padėtį. [1; 2; 3; 9]. Tačiau paminėtų straipsnių autoriai įspėja, kad visiškai pasitikėti kiekvienu bankroto prognozavimo modeliu ir jo tinkamumu Lietuvos įmonių bankrotui prognozuoti nevertėtų. Tokias pat išvadas patvirtina ir kitas tyrimas, kuriame nagrinėti modernieji bankroto diagnozavimo modeliai. Juos praktiškai pritaikius Lietuvos įmonės bankroto tikimybei prognozuoti, buvo patvirtintas atitinkamų bankroto prognozavimo modelių tinkamumas [11; 13; 14; 19]. Lietuvoje įmonių kreditingumui vertinti tinka ir logistinės regresinės analizės modelis [12].

Turint omenyje kredito unijų unikalumą (jos yra ne pelno organizacijos) ir jų gausą (2013 metų pradžioje šalyje buvo 74 kredito unijos), straipsnyje naudojami tokie statistiniai modeliai ir metodai: sprendimų medis ir dirbtiniai neuroniniai tinklai [22]. Skaičiavimų rezultatai pasiekti tikrai geri.

## 2.1. Sprendimų medis

Sprendimų medis – hierarchinė duomenų struktūra, grįsta tam tikromis duomenų ypatybėmis. Šakų viršūnės apima visus atvejus, o žemesni mazgai laipsniškai dalija atvejus į pogrupius. Tai aiškus ir lengvai suprantamas sprendimo priėmimo grafinio vaizdavimo būdas, kuris susideda iš mazgų ir šakų. Mazgai rodo vietas, kur priimami sprendimai, o šakos nurodo, kur toliau keliaujama priėmus atitinkamą sprendimą. Mazgai, iš kurių neišeina nė viena šaka, yra vadinami lapais ir rodo sprendimo rezultatus.

Pagrindinė problema – teisingai segmentuoti turimus objektus ir sukurti sprendimų medį. Šią problemą sprendžia tokie metodai: CART (angl. *Classification and Regression Tree*), CHAID (angl. *Chi-Squared Automatic Interaction detection*), C4.5 ir Quest (angl. *Quick, Unbiased and Efficient Statistical Tree*).

**CART metodas.** Klasifikacijos ir regresijos medžio sudarymas (CART) yra neparametrinis statistinio modeliavimo metodas, naudojamas kintamojo reikšmei prognozuoti, atsižvelgiant į kitų kintamųjų reikšmes. Sprendimų medis, naudojamas objektams klasifikuoti, vadinamas klasifikacijos medžiu, o sprendimų medis, naudojamas prognozuoti, – regresijos medžiu. Vienas iš pagrindinių CART autorių yra L. Breimanas [7].

CART medžio kūrimas susideda iš trijų etapų: medžio kūrimo, medžio genėjimo ir optimalaus medžio parinkimo.

Kuriant sprendimų medį turima  $n$  stebinių, kurie susideda iš  $p$  įvesties kintamųjų. Matematiškai duomenis galima užrašyti  $(x_i, y_i)$ , čia  $i = 1, 2, \dots, n$  ir  $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})$ . Sukurtas CART algoritmas gali spręsti, kuriuos kintamuosius naudoti mazguose, ties kuriomis reikšmėmis išskirti šakas ir kaip tipologiškai nubraižyti medį.

Sukūrus algoritmą tenka nuspręsti, kuriuos kintamuosius naudoti mazguose, ties kuriomis reikšmėmis išskirti šakas ir kaip nubraižyti medį. Tarkime, kad turimas padalijimas į  $M$  duomenų rinkinius  $R_1, R_2, \dots, R_M$  ir modeliuojamas atsakymas kaip konstanta  $c_m$  kiekviename duomenų rinkinyje:

$$f(x) = \sum_{m=1}^M c_m I(x \in R_m),$$

čia  $I$  – indikatorinė funkcija. Pritaikius minimizavimo kriterijų kvadratų sumai  $\sum (y_i - f(x_i))^2$ , galima matyti, kad geriausia  $\hat{c}_m$  yra tiesiog  $y_i$  vidurkis duomenų rinkinyje  $R_m$ :

$$\hat{c}_m = \text{vidurkis}(y_i | x_i \in R_m).$$

Toliau yra naudojamas glodusis algoritmas. Naudojant visus stebinius, padalijamas kintamasis  $x_j$  dalijimo taške  $s$ . Skaičiavimo algoritmą galima užrašyti taip:

$$R_1(j, s) = \{X | X_j \leq s\} \quad \text{ir} \quad R_2(j, s) = \{X | X_j > s\}$$

Tada ieškoma kintamojo  $x_j$  ir dalijimo taško  $s$ :

$$\min_{j,s} \left[ \min_{c_1} \sum_{x_i \in R_1(j,s)} (y_i - c_1)^2 + \min_{c_2} \sum_{x_i \in R_2(j,s)} (y_i - c_2)^2 \right].$$

Kiekvieną  $x_j$  ir  $s$  minimizaciją galima užrašyti taip:

$$\hat{c}_1 = \text{vidurkis}(y_i | x_i \in R_1(j,s)) \quad \text{ir} \quad \hat{c}_2 = \text{vidurkis}(y_i | x_i \in R_2(j,s))$$

Kiekvieno padalijimo kintamojo padalijimo taškas  $s$  gali būti nustatytas perskaičiavus visus duomenis ir nustačius panašiausią porą  $(j, s)$ . Tada, radus geriausią padalijimą, duomenys dalijami į dvi, tris (keturias) grupes ir t. t. Kyla klausimas, kada nustoti dalyti. Aišku, kad labai didelis medis gali per daug prisitaikyti prie duomenų, o per mažas medis – neužfiksuoti esamos duomenų struktūros. Optimalus medžio dydis turi būti nustatytas pagal tam tikrus kriterijus. Vienas iš būdų – dalyti į medžio mazgus, jei tik kvadratų suma sumažėja – nustoti toliau dalyti.

Paprastai šiuo atveju naudojama toliau aprašyta strategija. Užauginamas didelis medis  $T_0$ , sustojant tik tada, kai dalijimo procesas pasiekia nustatytą minimalų mazgo dydį. Tada medis genėjamas naudojant kainos sudėtingumo genėjimo algoritimą.

Taigi antras etapas yra medžio genėjimas. Apibrėžiamas pomedis  $T \subset T_0$ , kuris gali būti gautas nugėjęs medį  $T_0$ , t. y. panaikinus bent kokį skaičių vidinių (turima omenyje ne lapų) mazgų. Lapams priskiriami indeksai  $m$ , čia mazgas  $m$  atitinka duomenų rinkinį  $R_m$ . Tarkime,  $|T|$  reiškia, kiek lapų turi medis  $T$ . Tada, jei

$$N_m = \{x_i \in R_m\},$$

tai

$$\hat{c}_m = \frac{1}{N_m} \sum_{x_i \in R_m} y_i.$$

Pažymėkime, kad:

$$Q_m(T) = \frac{1}{N_m} \sum_{x_i \in R_m} (y_i - \hat{c}_m)^2.$$

Iš čia:

$$C_\alpha(T) = \sum_{m=1}^{|T|} N_m Q_m(T) + \alpha |T|.$$

Pagrindinė idėja yra rasti kiekvienam  $\alpha$  pomeđį  $T_\alpha \subseteq T_0$ , kad būtų minimizuotas  $C_\alpha(T)$ . Parametras  $\alpha \geq 0$  lemia kompromisą tarp medžio dydžio ir jo prisitaikymo prie duomenų. Didelė  $\alpha$  reikšmė lemia mažesnę medį  $T_\alpha$  ir atvirkščiai. Kai  $\alpha = 0$ , tada turimas medis yra baigtas  $T_0$ .

Buvo įrodyta, kad kiekvienam  $\alpha$  yra vienintelis medis  $T_\alpha$ , minimizuojantis  $C_\alpha(T)$ . Norint rasti tokį  $T_\alpha$ , naudojamas silpniausios grandies genėjimas: sėkmingai pašalinami vidiniai mazgai, kurie duoda mažiausią padidėjimą  $\sum_m N_m Q_m(T)$ , kol gaunamas vieno mazgo medis. Taip gaunama baigtinė pomedžių seka.

Susipažinus detaliau su CART metodu, galima išskirti šias pagrindines jo ypatybes ir pranašumus [25; 26; 27; 31; 32]:

1. Metodas neparametrinis ir nereikia normaliojo kintamųjų skirstinio.
2. Nėra reikalo transformuoti duomenis į kokias nors matematinės funkcijas. Monotoninės transformacijos – logaritmas, kvadratas ar kvadratinė šaknis – neturės įtakos medžio formavimui.
3. Metodas leidžia suklasifikuoti sudėtingos struktūros duomenis. Kitaip nei parametriniai modeliai, skirti vienos dominuojančios struktūros duomenims atskleisti, CART leidžia dirbti su skirtingų struktūrų duomenimis.
4. Metodas atsparus išskirčių įtakai. Nepriklausomų kintamųjų išskirtys paprastai neturi įtakos CART, kitaip nei parametriniais statistiniais modeliais, pavyzdžiui, pagrindinių komponentų analizei ar tiesinei regresijai. CART algoritmas leidžia ekstremalias reikšmes priskirti atskiram mazgui ir taip išvengiama įtakos likusiam medžiui.

5. CART medžiui sudaryti tinka tiek kokybinių, tiek kiekybinių kintamųjų deriniai.

6. CART gali būti efektyviai panaudotas duomenų, kuriuose trūksta tam tikrų reikšmių, medžiui formuoti.

7. CART algoritmas sudarytas taip, kad sprendimų medis „neperaugtų“, t. y. jis apkarpo iki optimalaus dydžio. Be to, padeda minimizuoti tikimybę, kad svarbi duomenų struktūra bus nepastebėta per anksti nutraukus medžio auginimą.

8. CART gali naudoti tuos pačius kintamuosius skirtingose medžio vietose. Tai leidžia atskleisti tam tikrų kintamųjų kitimo konstrukcijas ir jų tarpusavio sąveiką.

9. CART medis gali būti įtrauktas į hibridinius modelius, kur CART teiktų įvesties duomenis dirbtiniam neuroniniam tinklui, kuris pats negali pasirinkti kintamųjų.

Aišku, CART, kaip ir kiekvienas metodas, turi trūkumų, bet jų nedaug ir daugumai jų pasiūlyti sprendimai [15; 17; 20; 21]:

1. CART gali turėti nestabilių sprendimų medį. Nereikšmingi duomenų pakeitimai, pavyzdžiui, dalies stebinių pašalinimas, gali iš esmės pakeisti sprendimų medį (gali padidėti ar sumažėti medžio sudėtingumas, pasikeisti naudojami kintamieji ar jų reikšmės).

2. Norint sukurti gerą medį reikia didelių duomenų rinkinių. Tokiais atvejais problemą rekomenduojama spręsti atsitiktinių miškų (angl. *Random Forests*) metodu.

**CHAID metodas.** CHAID (angl. *Chi-Squared Automatic Interaction Detection*) metodas – tai rekursinio dalijimo metodas, kuris padeda įvertinti, ar mazgo dalijimas efektyvus. Čia naudojamos gerai žinomu Chi-kvadrato statistiniu testu siekiant įvertinti, ar mazgo dalijimas padidina reikšmingumą. Ryšio reikšmingumas matuojamas  $p$ . Šis metodas tinkamesnis diskretiems kintamiesiems prognozuoti, bet gali būti taikomas ir tolydiems kintamiesiems prognozuoti, suskirstant juos į grupes.

SPSS programų paketas remiasi G. V. Kasso [12] darbe pateiktu CHAID algoritmu. CHAID algoritmą sudaro trys etapai: sujungimas, padalijimas ir sustojimas. Medis auginamas pakartojant šiuos tris žingsnius kiekviename mazge.

CHAID metodas, kaip ir CART metodas, turi dalį anksčiau aptartų pranašumų ir trūkumų, būdingesnių sprendimų medžiams. Todėl reikėtų aptarti tik išskirtinius CHAID bruožus. CHAID segmentavimo pranašumai:

1. Galima mazgą dalyti į daugiau nei du poabičius. Priklausomai nuo duomenų toks dalijimas gali būti labai patogus ir vizualiai suprantamesnis.

2. Skaičiavimais galima nustatyti, kurie kintamieji gali daryti įtaką tiriamam dydžiui, o kurie negali.

3. Galima pastebėti pagrindines duomenų tendencijas.

4. CHAID trūkumai:

5. Nepriklausomi kintamieji negali būti tolydūs. Ši problema sprendžiama tolydžius kintamuosius transformuojant eile.

6. CHAID analizė mažam stebinių skaičiui nėra efektyvi, t. y. per mažos imties analizė dažnai neduoda patikimos informacijos.


7. Gali būti sudėtinga nustatyti, ar CHAID metodas yra tinkamiausias.

**Išsamus CHAID metodas.** CHAID metodas nuo jo sukūrimo evoliucionavo ir dabar dažniau naudojamas D. Biggso pasiūlytas variantas [5]. Jis turi tiek pat etapų, kaip ir CHAID metodas, skiriasi tik sujungimo etapu, kur naudojama išsami paieškos procedūra, sujungianti panašias tiriamų kintamųjų poras, kol lieka tik viena jų pora. Pagrindinis išsamiojo CHAID metodo pranašumas yra toks: naudojamas išsamesnis euristinis paieškos algoritmas kiekviename mazge leidžia optimaliai grupuoti prognozuojamo kintamojo kategorijas. Taip pat labiau tinkamas Bonferroni korekcijos daugiklis leidžia išvengti kintamojo, turinčio didelį kategorijų skaičių, diskriminavimo [5].

## 2.2. Dirbtiniai neuroniniai tinklai

Dirbtiniai neuroniniai tinklai – tai iš adaptyvių elementų, imituojančių gyvų organizmų smegenų ląstelių, vadinamų neuronais, veiklą, sudaryta informaciją apdorojanti sistema. Vienas iš geriausiai žinomų ir daugiausia tirtų yra daugiasluoksnis perceptronas – tai daugybės vienasluoksnų perceptronų, išdėstytų sluoksniais, tinklas, kur informacija iš vieno sluoksnio perceptrono perduodama kito sluoksnio perceptronams [18]. Daugiasluoksnis perceptronas (angl. *Multilayer perceptron* – MLP) yra sudarytas iš daug neuronų, kurie yra suskirstyti į įėjimo ir išėjimo sluoksnius bei tarp šių esantį vieną ar daugiau vidinių paslėptų sluoksnių. Tinklo pavyzdys pateikiamas 1 pav. Pirmiausia įėjties signalai patenka į įėjimo sluoksnį ir iš ten keliauja į pirmą paslėptą sluoksnį, paskui pirmo paslėpto

sluoksniu išėjies signalai keliauja į antrą paslėptą sluoksnį, tada antro sluoksniu išėjies signalai keliauja į išėjimo sluoksnį ir tada gaunami išėjies signalai. Neuroninis tinklas gali turėti daug įėjies ir išėjies signalų, taip pat gali turėti kelis paslėptus sluoksnius su skirtingu neuronų skaičiumi.



1 pav. Dirbtinio neuroninio tinklo schema

Perceptronas apskaičiuojamas vieną išėjies signalą formuojant iš keleto įėjimo signalų naudojant tiesinę kombinaciją, kuri remiasi įėjimo svoriais, ir tada gautam rezultatui gali būti panaudota tam tikra netiesinė aktyvacijos funkcija. Matematiškai tai galima aprašyti taip:

$$h_i = \sum_{j=1}^n x_j w_{ij} + b_i \text{ ir } y_i = \varphi(h_i),$$

čia,  $x$  – įėjies signalų vektorius,  $w$  – svoriai,  $b$  – papildomas poslinkis,  $\varphi$  – aktyvacijos funkcija,  $h_i$  – svorinių neurono įėjies duomenų suma. Šiuo atveju turime tiesinę funkciją, bet norint modeliui suteikti daugiau galimybių naudojama aktyvacijos funkcija, kuri gali būti ir netiesinė. Kiekviename sluoksnyje gali būti naudojamos skirtingos aktyvacijos funkcijos.

Sprendžiant prognozavimo ar klasifikavimo uždavinius pagrindinis tikslas yra įvertinti svorius  $w$  ir poslinkius  $b$ , naudojamus neuroniniame tinkle. Toks procesas vadinamas mokymu ir susideda iš trijų etapų: pradinių svorių nustatymas, dirbtinio neuroninio tinklo mokymas, mokymo stabdymas.

Norint pradėti neuroninio tinklo mokymą pirmiausia reikia turėti tam tikrus pradinius svorius. Šiems svoriams nustatyti gali būti naudojami įvairūs algoritmai. Vienas iš paprasčiausių algoritmų yra toks: pradiniam svoriams priskiriamos mažos atsitiktinės reikšmės. Neuroninio tinklo mokymas vyksta iteracijomis ir po kiekvienos iteracijos svoriai ir poslinkiai koreguojami.

Pagal tam tikrą algoritmą, judant atgal nuo išėjimo sluoksniu link įėjimo sluoksniu, galima apskaičiuoti visus pokyčius. Šis algoritmas ir vadinamas atgaliniu klaidos sklidimu. Svoriai gali būti koreguojami iš karto nustačius svorio pokyčius – toks mokymas vadinamas tiesioginiu, arba po tam tikro iteracijų skaičiaus, kai iš karto pridedami visi svorių pokyčiai, – toks mokymas vadinamas nuosekliu.

Kitame etape sprendžiamas sustojimo klausimas, t. y. kada reikia baigti mokyti neuroninį tinklą. Paprastai mokymas baigiamas tada, kai gauta klaidos funkcijos reikšmė su naujais svoriais santykinai, palyginti su prieš tai buvusia klaidos funkcijos reikšme, yra maža, t. y. mažesnė už tam tikrą iš anksto nustatytą dydį. Mokymas gali būti baigiamas iš anksto nustačius tam tikrą mokymo iteracijų skaičių, mokymo trukmę ar mokymo duomenų kiekį. Vienas iš būdų išvengti permokymo (pritaikymo) – ankstyvasis sustojimas. Turimi duomenys padalijami į tris duomenų rinkinius. Pirmas rinkinys naudojamas dirbtinio neuroninio tinklo mokymui. Antras rinkinys skirtas tinkamumui tikrinti, o trečiasis – testavimui.

Norint išspręsti tam tikrą problemą, visada yra keli sprendimo būdai. Kiekvienas būdas turi savo pranašumų ir trūkumų, ne išimtis ir dirbtiniai neuroniniai tinklai. Dirbtinių neuroninių tinklų pranašumai [4; 6; 8]:

1. Neuroninio tinklo mokymas nereikalauja perprogramavimo sprendžiant kitą uždavinį.
2. Dirbtiniams neuroniniams tinklams nereikia prielaidų apie duomenų pasiskirstymą, nereikia ir prielaidų apie įėjimo ir išėjimo duomenų ryšį.
3. Greitas mokymo procesas (jei tinklas turi mažiau nei 50 neuronų).
4. Neuroninių tinklų modelis gali būti naudojamas tiek tiesiniams, tiek netiesiniams uždaviniams spręsti.
5. Didelis tikslumas. Dirbtiniais neuroniniais tinklais galima įvertinti sudėtingus netiesinius ryšius.
6. Triukšmo toleravimas. Dirbtiniai neuroniniai tinklai labai lankstūs dirbant su nevisais, trūkstamais arba turinčiais triukšmų duomenimis.
7. Nesudėtingas palaikymas. Dirbtinius neuroninius tinklus galima atnaujinti pagal naujus duomenis – tai leidžia juos naudoti dinamiškoje aplinkoje
8. Trūkumai:
9. Neuroniniais tinklais gautą informaciją dažnai sunku interpretuoti.
10. Sudėtinga įtraukti su tam tikra problema susijusias žinias.
11. Tam, kad neuroninis tinklas veiktų, reikia jį mokyti. Netinkamai tinklą apmokius bus gauti neteisingi rezultatai.
12. Sudėtinga sukonstruoti tinkamą dirbtinių neuronų architektūrą, t. y. nustatyti optimalų paslėptų sluoksnių skaičių, neuronų kiekį juose, parinkti aktyvacijos funkcijas ir kita.
13. Už mokymo duomenų režijų neuroniniai tinklai yra neprognozuojami, nes neuroninis tinklas prisitaiko prie mokymo duomenų.

### 3. Kredito unijų veiklos tyrimas

Visiems modeliams sudaryti buvo naudota *IBM SPSS Statistics* programinė įranga. Atliekant tyrimą nagrinėti 2009–2010 metų kredito unijų duomenys [22]. Tyrimui parinkta 47 finansinių rodiklių sistema. Kredito unijų rizikingumui nustatyti naudotas Lietuvos centrinės kredito unijos apskaičiuotas finansinis indeksas.

Kredito unijos suklasifikuotos pagal rizikingumą į tris grupes, remiantis Lietuvos centrinės kredito unijos pateiktu finansiniu indeksu. Finansinis indeksas padeda įvertinti kredito unijos finansinę padėtį. Jis išvedamas įvertinus pagrindinius finansų institucijos veiklos rodiklius ir gali būti nuo A iki E. A reiškia geriausią įvertinimą. Tai tarsi tam tikra reitingavimo sistema. Nagrinėjamu laikotarpiu kredito unijų finansiniai indeksai kito, todėl nėra bendro kredito unijų priskyrimo kuriai nors rizikingumo grupei tam tikrais metais taisyklių. Bendri principai buvo panašūs: turinčios geriausią finansinį indeksą kredito unijos patekdavo į mažesnės rizikos grupes, o turinčios prasčiausią – į didesnės rizikos grupes. Kredito unijų pasiskirstymas pagal metus pateikiamas 1 lentelėje.

1 lentelė. Kredito unijų (KU) reitingai 2009–2012 metais

Reitingas	KU 2009 m.	KU 2010 m.	KU 2011 m.	KU 2012 m.	Procentais 2009 m.	Procentais 2010 m.	Procentais 2011 m.	Procentais 2012 m.
Mažesnė rizika	15	18	19	18	25	29,5	31	29,5
Vidutinė rizika	25	25	26	28	41	41	43	46
Didesnė rizika	21	18	16	15	34	29,5	26	24,5


Iš 1 lentelės duomenų matoma, kad per metus kredito unijų pasiskirstymas pasikeitė gana nedaug, bet iš tikrųjų net 29 kredito unijų reitingas pasikeitė [22]. Tai rodo, kad kredito unijos yra dinamiškos ir jų reitingai pagal riziką nuolat keičiasi.

CART analizės metu mazgams vertinti buvo naudojamas Gini koeficientas.

### 4. Statistiniai tyrimo rezultatai

2009 metų tyrimo duomenys buvo naudojami modeliui konstruoti, o 2010 metų duomenys – sukonstruotam modeliui patikrinti. Šio tyrimo tikslas – išnagrinėti, ar su turimu finansinių rodiklių rinkiniu galima pakankamai tiksliai įvertinti Lietuvos kredito unijos rizikingumą, taip pat patikrinti, ar įmanoma vienais metais sudarytą modelį pritaikyti kitais metais vertinant kredito unijų rizikingumą.

Sprendimų medis sukurtas naudojant CART analizę (2 pav.), pirmasis padalijimas atliekamas pagal kintamąjį (Pajamos / Kapitalas). Jeigu pajamų ir kapitalo santykis yra mažesnis nei 77 proc., kredito unijos priskiriamos prie mažiau rizikingų, priešingu atveju – prie rizikingesnių. Tai galima matyti iš kredito unijų, patekusių į pirmąjį ir antrąjį mazgus. Šį rodiklį galima interpretuoti keliais aspektais. Pirmiausia, kuo didesnė rodiklio reikšmė, tuo daugiau generuojama pajamų su mažesniu kapitalu. Pelningumo požiūriu, tokį rezultatą galima interpretuoti teigiamai. Vertinant riziką didelė šio rodiklio reikšmė nėra geras dalykas. Didžiąją kredito unijų pajamų dalį sudaro pajamos, gautos iš palūkanų, vadinasi, didesnes pajamas turinti kredito unija už savo turtą (paskolas, vertybinius popierius ir kt.) gauna didesnes palūkanas. O didesnės palūkanos paprastai mokamos už rizikingesnį turtą. Todėl kredito unijas, turinčias didesnį pajamų ir kapitalo santykį, galima vadinti rizikingesnėmis.



2 pav. Sprendimų medis, sukurtas naudojant CART analizę

Atlikus anksčiau aptartą padalijimą, toliau kredito unijos dalijamos pirmame ir antrame mazge. Į pirmą mazgą patekusios mažiau rizikingos kredito unijos toliau dalijamos pagal kintamąjį (Kapitalas / Turtas). Turinčios didesnį nei 14 procentų rodiklį kredito unijos šiame mazge klasifikuojamos kaip rizikingesnės. Tokį padalijimą galima aiškinti tuo, kad kredito unijoms, turinčioms daugiau rizikingo turto, taikomi didesni kapitalo reikalavimai, todėl šis rizikingesnių kredito unijų rodiklis yra didesnis. Taip pat didesnis santykis gali rodyti, kad kredito unija neefektyviai išnaudoja turimą kapitalą ir dėl neefektyvios veiklos patiria nuostolių. Į antrą mazgą patekusios rizikingesnės kredito unijos

reitinguojamos pagal kintamąjį (Grynasis pelnas / Pajinis kapitalas). Jei šis santykis yra mažesnis negu 2,9 procento, kredito unijos priskiriamos rizikingesnėms. Toks padalijimas rodo, kad kredito unijos turi dirbti pelningai (šioje vietoje galimas ir nedidelis nuostolis iki 2,9 procento pajinio kapitalo), kad jos būtų mažiau rizikingos. Jei kredito unija patiria nuostolių, vadinasi, kažkas jos veikloje vyksta ne taip. Gali būti daug priežasčių, dėl ko patiriama nuostolių: neefektyviai valdomos lėšos, išduota per daug rizikingų paskolų ir kita. Visa neefektyvi ir netinkamai įvertinta veikla daro kredito uniją rizikingesnę ir gali jai atnešti nuostolių.

Pirmame mazge prie mažiau rizikingų priskirtos kredito unijos toliau dalijamos trečiame mazge. Šiame mazge kredito unijos dalijamos pagal kintamąjį (Pajinio kapitalo augimas). Pagal šį dalijimą pajinis kapitalas turi augti daugiau negu 4,3 procento, kad kredito unijos būtų priskiriamos mažesnės rizikos grupei. Toks dalijimas reiškia, kad kredito unijos pajinis kapitalas turi nuolat didėti. Jei kredito unijos pajinis kapitalas didėja nepakankamai arba net mažėja, tai gali reikšti, kad susiduriama su tam tikromis problemomis, pvz. pasitikėjimo kredito unija problema, kai neatsiranda naujų narių, kurie suneštų pajinį kapitalą.

Antrame mazge prie mažiau rizikingų priskirtos kredito unijos toliau dalijamos šeštame mazge. Šiame mazge kredito unijos klasifikuojamos pagal kintamąjį (Privalomasis rezervas arba rezervinis kapitalas / Turtas). Privalomasis rezervas arba rezervinis kapitalas sudaromas iš kredito unijos grynojo pelno atskaitymų. Atskaitymai į privalomąjį rezervą arba rezervinį kapitalą, vadovaujantis Lietuvos Respublikos kredito unijų įstatymu, yra privalomi ir negali būti mažesni kaip 20 procentų kredito unijos grynojo pelno, kol privalomasis rezervas arba rezervinis kapitalas sudarys 1/5 kredito unijos nuosavo kapitalo. Jei šio rodiklio santykis yra didesnis nei 0,9 procento, kredito unijos traktuojamos kaip didesnės rizikos. Toks dalijimas iš pirmo žvilgsnio gali atrodyti keistai, nes kuo didesnis privalomasis rezervas arba rezervinis kapitalas, tuo kredito unijos turėtų būti laikomos mažiau rizikingos, bet šiuo atveju yra priešingai. Tokį padalijimą būtų galima aiškinti tuo, kad turinčioms daugiau rizikingo turto kredito unijoms reikia daugiau kapitalo. Taip pat toks požymis gali būti neefektyvaus kapitalo panaudojimo problemų ženklas.

Klasifikavimo (žr. 2 lentelę) rezultatai, gauti atlikus CART analizę, pateikiami 2 paveiksle. Remiantis mokymo duomenimis pasiekti geri rezultatai – teisingai suklasifikuota 83,6 procento stebinių ir net 90,5 procento tikslumu suklasifikuota tikslinė, didesnės rizikos kredito unijų, grupė. Testavimo duomenimis, gauti prastesni rezultatai. Teisingai suklasifikuota 57,4 procento stebinių, bet teisingai identifikuota 72,2 procento tikslinės grupės kredito unijų.

**2 lentelė.** Kredito unijų klasifikavimo, naudojant CART analizės metu gautą sprendimų medį, rezultatai, procentais

Stebiniai		Prognozė			
		Mažesnė rizika	Vidutinė rizika	Didesnė rizika	Tikslumas
Mokymo duomenys	Mažesnės rizikos	12	3	0	80,0
	Vidutinės rizikos	2	20	3	80,0
	Didesnės rizikos	0	2	19	90,5
	Iš viso	23,0	41,0	36,1	83,6
Testavimo duomenys	Mažesnės rizikos	11	7	0	61,1
	Vidutinės rizikos	11	11	3	44,0
	Didesnės rizikos	3	2	13	72,2
	Iš viso	41,0	32,8	26,2	57,4


Remiantis CHAID analize sukurtame sprendimų medyje (3 pav.) kredito unijos grupuojamos pagal beveik tokius pat finansinius rodiklius, kaip ir atlikus pagal CART analizę sukurtame sprendimų medyje. Pirmiausia kredito unijos dalijamos pagal kintamąjį (Pajamos / Kapitalas). Toks pat dalijimas buvo atliktas ir pasitelkus pagal CART analizę gautą medį, tik jis atliekamas kitoje vietoje, t. y. kredito unijos, kurių pajamų ir kapitalo santykis yra didesnis nei 75 procentai, buvo traktuojamos kaip rizikingesnės.

Atlikus aptartą dalijimą toliau kredito unijos dalijamos pirmame ir antrame mazge. Pirmame mazge kredito unijos dalijamos pagal kintamąjį (Paskolų augimas). Jeigu kredito unijų paskolos mažėja daugiau nei 25,8 procento, jos priskiriamos rizikingesnei grupei. Šioje vietoje kredito unijos skirstomos pagal gana didelį paskolų portfelio susitraukimą, toks didelis paskolų portfelio mažėjimas – signalas, kad kredito unijoms kažkas negerai. Detaliau panagrinėjus kredito unijas, kurios patyrė tokį didelį paskolų portfelio mažėjimą, buvo pastebėta, kad absoliučia reikšme tie portfelių svyravimai yra gana nedideli (iki 1 mln. litų). Galima teigti, kad dalis kredito unijų susiduria su santykinai didelėmis paskolomis, skaičiuojamomis nuo viso paskolų portfelio, vienam asmeniui ar susijusių asmenų grupei. Tokia situacija, kai didelė kredito unijos paskolų portfelio dalis sutelkta vieno skolininko rankose, ypač



pavojinga. Ne veltui vienas iš Lietuvos banko taikomų normatyvų yra maksimalios paskolos vienam skolininkui limitas. Antrame mazge kredito unijos reitinguojamos pagal kintamąjį (Grynasis pelnas / Pajinis kapitalas). Jei šis santykis mažesnis nei  $-5,6$  procento, kredito unijos traktuojamos kaip rizikingesnės, priešingu atveju – atvirksčiai. Toks pat dalijimas buvo atliekamas ir remiantis CART analize gautame sprendimų medyje, tik jis buvo atliekamas šiek tiek kitoje vietoje – ties  $-2,9$  procento. Taigi šio dalijimo priežastys yra lygiai tokios pat kaip prieš tai aptartu CART analizės būdu sukurtu modelio atveju.

Pirmame mazge prie rizikingesnių priskirtos kredito unijos toliau dalijamos ketvirtame mazge. Šiame mazge kredito unijos dalijamos pagal kintamąjį (Kapitalas / Turtas). Turinčios didesnę nei  $12,4$  procento rodiklį kredito unijos šiame mazge klasifikuojamos kaip rizikingesnės. Pagal šį kintamąjį buvo dalijama ir CART analizės atveju.



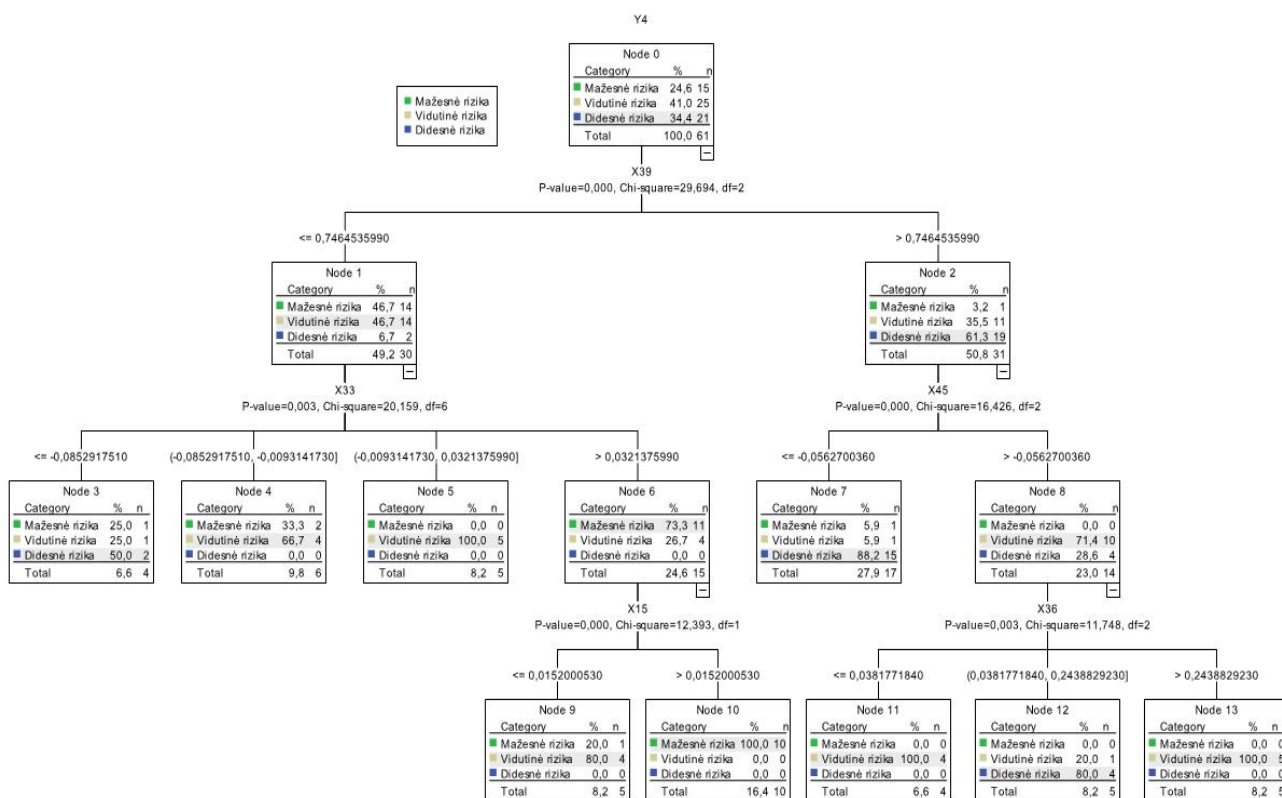
3 pav. Remiantis CHAID analize sukurtas sprendimų medis

**3 lentelė.** Kredito unių klasifikavimo, naudojant CHAID analizės metu gautą sprendimų medį, rezultatai, procentais

Stebiniai		Prognozės			
		Mažesnė rizika	Vidutinė rizika	Didesnė rizika	Tikslumas
Mokymo duomenys	Mažesnės rizikos	11	3	1	73,3
	Vidutinės rizikos	3	20	2	80,0
	Didesnės rizikos	0	4	17	81,0
	Iš viso	23,0	44,3	32,8	78,7
Testavimo duomenys	Mažesnės rizikos	13	5	0	72,2
	Vidutinės rizikos	10	12	3	48,0
	Didesnės rizikos	2	4	12	66,7
	Iš viso	41,0	34,4	24,6	60,7

3 lentelėje pateikiami klasifikavimo rezultatai, gauti naudojant sprendimų medį, sudarytą CHAID analizės metu (3 pav.). Remiantis mokymo duomenimis, pasiekti geri rezultatai – teisingai suklasifikuota 88,7 procento stebinių ir 81 procento tikslumu klasifikuota tikslinė, t. y. didesnės rizikos kredito unių, grupė. Pagal testavimo duomenis rezultatai prastesni – teisingai suklasifikuota 60,7 procento stebinių, bet teisingai identifikuota 66,7 procento tikslinės grupės kredito unių.

Išsamiosios CHAID analizės metu sukurtame sprendimų medyje (4 pav.) pirmiausia kredito unijos dalijamos pagal kintamąjį (Pajamos / Kapitalas). Toks pat dalijimas atliekamas ir pasitelkus pagal CART ir CHAID analizę gautuose medžiuose. Kredito unijos, kurių pajamų ir kapitalo santykis didesnis nei 75 procentai, priskiriamos prie rizikingesnių kredito unių grupės.



**4 pav.** Remiantis išsamiąja CHAID analize sukurtas sprendimų medis

Toliau kredito unijos dalijamos pirmame ir antrame mazge. Pirmame mazge kredito unijos dalijamos pagal kintamąjį (Pajinio kapitalo augimas). Jei pajinis kapitalas mažėjo 8,5 procento arba daugiau, kredito unijos buvo

klasifikuojamos kaip didesnės rizikos, jei mažėjo iki 8,5 procento arba didėjo iki 3,2 procento, jos buvo priskiriamos vidutinės rizikos grupei, o jei didėjo daugiau nei 3,2 procento, buvo traktuojamos kaip mažiausios rizikos. Pajinio kapitalo augimas rodo, kad nauji ar esami nariai papildo kredito unijos kapitalą, vadinasi, jie pasitiki kredito unija ir naudojami jos paslaugomis. Nepakankamas pajinio kapitalo didėjimas ar net jo mažėjimas rodo, kad dėl tam tikrų priežasčių nepakankamai sparčiai didėja kredito unijos naujų narių skaičius ar suteikiamų paskolų kiekis. Taip pat gali būti susiduriama net su narių ar paskolų portfelio mažėjimu. Toks pat finansinis rodiklis buvo ir CART sprendimų medyje.

Antrame mazge kredito unijos reitinguojamos pagal kintamąjį (Grynasis pelnas / Pajinis kapitalas). Jei šis kintamasis mažesnis arba lygus  $-5,6$  procento, kredito unijos traktuojamos kaip rizikingesnės. Lygiai toks pat dalijimas buvo atliktas remiantis CHAID analize gautame sprendimų medyje.

Pirmame mazge prie mažiausiai rizikingų priskirtos kredito unijos toliau dalijamos šeštame mazge. Šiame mazge kredito unijos dalijamos pagal kintamąjį (Likvidžių ir finansinių investicijų pajamos / Vidutinės likvidžios ir finansinės investicijos). Jei santykis yra didesnis nei 1,5 procento, kredito unijos priskiriamos mažesnės rizikos grupei, priešingu atveju – vidutinės rizikos grupei. Šis rodiklis parodo, kaip pelningai kredito unijos geba išnaudoti likvidžias ir finansines investicijas. Jei jos geba gauti didesnes pajamas iš šių investicijų, vadinasi, jos efektyviau panaudoja turimas lėšas. Todėl tokias kredito unijas galima traktuoti kaip mažiau rizikingas. Kita vertus, gaunamos didesnės pajamos rodo ir didesnę prisiimamą riziką.

Antrame mazge prie mažiau rizikingų priskirtos kredito unijos toliau klasifikuojamos ketvirtame mazge. Šiame mazge atliekamas labai įdomus padalijimas pagal kintamąjį (Turto augimas). Šioje vietoje didesnės rizikos kredito unijomis laikomos tos, kurių turto augimas per metus buvo tarp 3,8 ir 24,4 procento. Jei turto augimas buvo mažesnis arba didesnis, kredito unijos priskiriamos prie mažiau rizikingų. Mažesnis turto augimas rodo, kad kredito unija dirba stabiliai ir nesusiduria su naujais iššūkiais, kylančiais smarkiai didėjant turtui. Tačiau sunku paaiškinti, kodėl turėjusios didesnę turto augimą kredito unijos yra priskiriamos rizikingesnei grupei. Detaliau panagrinėjus šias situacijas paaiškėjo, kad absoliučia reikšme toks augimas buvo gana nedidelis, todėl ir nesukėlė papildomų sunkumų kredito unijoms.

**4 lentelė.** Kredito unijų klasifikavimo, naudojant išsamiosios CHAID analizės metu gautą sprendimų medį, rezultatai, procentais

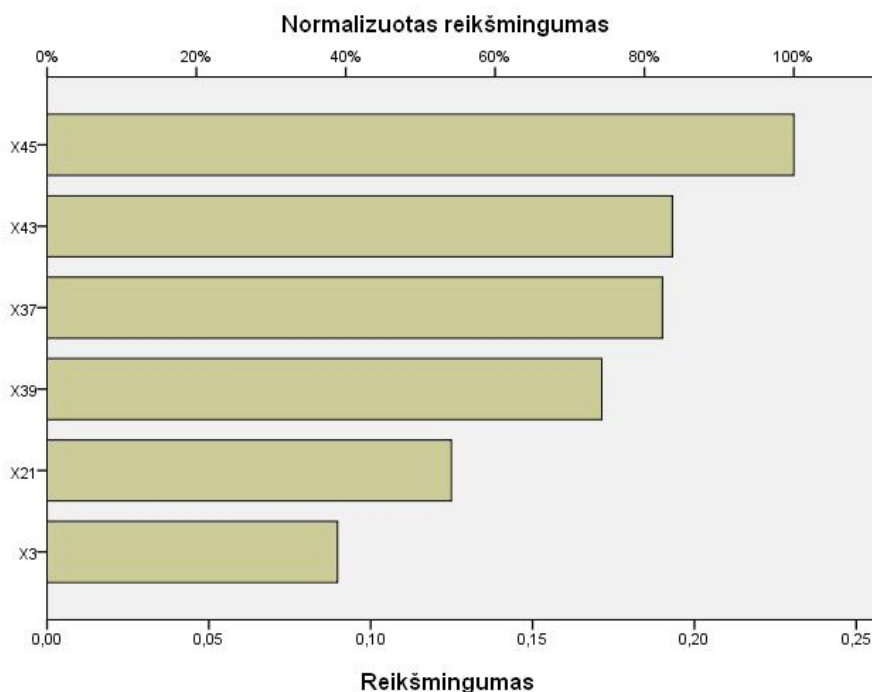
Stebiniai		Prognozės			
		Mažesnė rizika	Vidutinė rizika	Didesnė rizika	Tikslumas
Mokymo duomenys	Mažesnės rizikos	10	3	2	66,7
	Vidutinės rizikos	0	22	3	88,0
	Didesnės rizikos	0	0	21	100,0
	Iš viso	16,4	41,0	42,6	86,9
Testavimo duomenys	Mažesnės rizikos	6	11	1	33,3
	Vidutinės rizikos	6	14	5	56,0
	Didesnės rizikos	1	3	14	77,8
	Iš viso	21,3	45,9	32,8	55,7

Pateikti 4 lentelėje klasifikavimo rezultatai gauti atlikus išsamią CHAID analizę (4 pav.). Remiantis mokymo duomenimis pasiekti geri rezultatai – teisingai suklasifikuota 86,9 procento stebinių ir net 100 procentų tikslumu suklasifikuota tikslinė, didesnės rizikos kredito unijų, grupė. Pagal testavimo duomenis teisingai klasifikuota tik 55,7 procento stebinių, bet teisingai identifikuota 77,8 procento tikslinės grupės kredito unijų.

Norint patikrinti, ar sprendimų medžiai yra vienas iš geriausių būdų sprendžiant kredito unijų klasifikavimo uždavinį, gauti rezultatai buvo patikrinti ir kitais metodais. Geri prognozavimo rezultatai buvo pasiekti naudojant dirbtinius neuroninius tinklus.

Dirbtiniams neuroniniams tinklams dispersinės analizės būdu buvo atrinkti tokie kintamieji: (Specialiųjų atidėjinių pokytis per metus / Vidutinis paskolų portfelis), (Paskolų vertės sumažėjimas / Vidutinis paskolų portfelis), (Kitos veiklos pajamos / Vidutinis turtas), (Grynasis pelnas / Vidutinis turtas), (Rezervinio kapitalo augimas), (Kapitalas / Turtas), (Pajamos / Kapitalas), (Išlaidos / Pajamos), (Grynasis pelnas / Pajinis kapitalas).

Kuriant dirbtinį neuroninį tinklą buvo naudojami tokie nustatymai: vienas paslėptas neuronų sluoksnis su penkiais neuronais ir hiperbolinė tangento aktyvacijos funkcija, išvesties sluoksnyje buvo naudojama minkštojo maksimumo (angl. *softmax*) aktyvacijos funkcija, kuri puikiai tinka sprendžiant klasifikacijos uždavinius. Mokymas buvo atliekamas naudojant greičiausio nusileidimo minimizacijos algoritmą.



5 pav. Dirbtinio neuroninio tinklo įvesties duomenų reikšmingumas

Dirbtinio neuroninio tinklo kūrimo metu buvo pašalinti finansiniai rodikliai, kurie nėra labai reikšmingi klasifikuojant, todėl galutinius įvesties duomenis galima matyti išdėstytus pagal reikšmingumą (5 pav.). Finansiniai rodikliai: (Grynasis pelnas / Pajinis kapitalas), (Kapitalas / Turtas) ir (Pajamos / Kapitalas) jau buvo naudojami sukurtuose sprendimų medžiuose. Čia naujai atsirado rodikliai: (Išlaidos / Pajamos), (Kitos veiklos pajamos / Vidutinis turtas) ir (Paskolų vertės sumažėjimas / Vidutinis paskolų portfelis).

Norint nustatyti kiekvieno iš įvesties duomenų įtaką klasifikavimo rezultatui, daryta prielaida, kad visi kintamieji išlieka tokie patys, kinta tik vienas nagrinėjamas kintamasis.

Didėjant kintamajam (Grynasis pelnas / Pajinis kapitalas) didėja tikimybė, kad kredito unija bus priskirta mažesnės rizikos grupei. Tai toks pats kintamasis, kuris buvo naudojamas ir sprendimų medžiuose. Ryšys išliko toks pat – mažiau pelno uždribančios arba patiriančios daugiau nuostolių kredito unijos yra laikomos rizikingesnėmis.

Didėjant kintamajam (Kapitalas / Turtas) mažėja tikimybė, kad kredito unija bus priskirta mažesnės rizikos grupei. Tai toks pats kintamasis, kuris buvo naudojamas ir sprendimų medžiuose. Ryšys išliko toks pat – esant tokiam pat turtui didesnę kapitalą turinčios kredito unijos laikomos rizikingesnėmis.

Didėjant kintamajam (Pajamos / Kapitalas) didėja tikimybė priklausyti didesnės rizikos grupei. Tai toks pats kintamasis, kuris buvo naudojamas ir sprendimų medžiuose. Išlikęs ryšys toks pat – esant tam pačiam kapitalui didesnes pajamas gaunančios kredito unijos yra laikomos rizikingesnėmis.

Didėjant kintamajam (Išlaidos / Pajamos) mažėja tikimybė, kad kredito unija bus priskirta mažesnės rizikos grupei. Šį rodiklį galima vertinti pelningumo požiūriu: kuo didesnės pajamos ir mažesnės išlaidos, tuo didesnis kredito unijos pelningumas. Kaip matyti iš ankstesnių modelių kredito unijų rizikingumui nustatyti, nemažą įtaką turi ir pelningumas. Kita vertus, didesnis skirtumas tarp išlaidų ir pajamų gali reikšti ir didesnės rizikos prisiėmimą, stengiantis padidinti pajamas. Taigi į šį rodiklį žiūrima kaip į efektyvumo matą ir stengiamasi įvertinti pelningumo požiūriu.

Didėjant kintamajam (Kitos veiklos pajamos / Vidutinis turtas) didėja tikimybė, kad kredito unija bus priskirta didesnės rizikos grupei. Kredito unijos veiklos kryptis yra aiški, tad jei papildomai gaunama pajamų iš kitos veiklos, vadinasi, kredito unija verčiasi kažkokia papildoma veikla, kuri nėra jai pagrindinė. Reikia manyti, kad tokia veikla didina kredito unijos rizikingumą, nes tai neatitinka jos kompetencijos.

Didėjant kintamajam (Paskolų vertės sumažėjimas / Vidutinis paskolų portfelis) didėja tikimybė priklausyti mažesnei rizikos grupei. Toks ryšys atrodo keistai, nes paskolų portfelio mažėjimas reiškia, kad jame atsirado blogų paskolų, kurios gali būti negrąžintos. Todėl didėjant šiam santykiui kredito unijos rizikingumas turėtų didėti. Tačiau gali būti ir kitaip. Pirmiausia šio rodiklio reikšmingumas pats mažiausias. Be to, gali būti, kad kredito unijos vengia daryti atidėjinius blogoms paskoloms, taip norėdamos nusišvęsti blogas paskolas ir pagerinti veiklos rezultatus, todėl atidėjinių formavimas yra sveikintinas dalykas ir parodo realią kredito unijos situaciją.

**5 lentelė.** Kredito unijų klasifikavimo, naudojant dirbtinį neuroninį tinklą, rezultatai, procentais

Stebiniai		Prognozė			
		Mažesnė rizika	Vidutinė rizika	Didesnė rizika	Tikslumas
Mokymo duomenys	Mažesnės rizikos	11	4	0	73,3
	Vidutinės rizikos	5	17	3	68,0
	Didesnės rizikos	4	3	14	66,7
	Iš viso	32,8	39,3	27,9	68,9
Testavimo duomenys	Mažesnės rizikos	12	6	0	66,7
	Vidutinės rizikos	12	9	4	36,0
	Didesnės rizikos	2	1	15	83,3
	Iš viso	42,6	26,2	31,1	59,0

5 lentelėje pateikiami klasifikavimo rezultatai, gauti naudojant trumpai aprašytą dirbtinį neuroninį tinklą. Remiantis mokymo duomenimis teisingai suklasifikuota 68,9 procento stebinių ir 66,7 procento tikslumu suklasifikuota tikslinė, didesnės rizikos kredito unijų, grupė. Pagal testavimo duomenis teisingai suklasifikuota 59 procentai visų stebinių ir teisingai identifikuota net 83,3 procento tikslinės grupės kredito unijų. Kitaip nei sprendimo medžių atvejais, kai remiantis mokymo duomenimis buvo pasiekiami kur kas geresni rezultatai nei remiantis testavimo duomenimis, naudojant dirbtinį neuroninį tinklą buvo pasiekti labai panašūs rezultatai.

Remiantis atliktu tyrimu galima pažymėti, kad skirtingais metodais kurtuose modeliuose atsižvelgiama į tuos pačius finansinius rodiklius: (Grynasis pelnas / Pajinis kapitalas), (Kapitalas / Turtas), (Pajamos / Kapitalas). Jie ir daro didžiausią įtaką nustatant kredito unijos rizikingumą. Aišku, kiekviename modelyje naudojami ir papildomi finansiniai rodikliai, bet jie nėra tokie reikšmingi. Atlikus tyrimą galima apibendrinti, kad rizikingiausios kredito unijos gauna daugiau nei 75 procentus pajamų, palyginti su kapitalu, ir patiria daugiau nei 5 procentus nuostolio, palyginti su pajiniu kapitalu, o mažiausią riziką turinčios kredito unijos gauna mažiau nei 75 procentus pajamų, palyginti su kapitalu, ir jų kapitalo ir turto santykis yra mažesnis nei 13 procentų. Taigi vertinant kredito unijų rizikingumą labiausiai reikia atsižvelgti į grynąjį pelną (nuostolį) ir kapitalą. Taip pat galima padaryti išvadą, kad skirtingų finansinių rodiklių sistema ir į tyrimą įtraukti duomenys, apimantys ilgesnį laiko tarpą, neturėjo didelės įtakos nei pasirenkant reikšmingiausius finansinius rodiklius, nei lyginant klasifikavimo metodus.

## 5. Išvados

Tyrimo metu nustatyta, kad vertinant kredito unijos rizikingumą reikšmingiausi yra grynojo pelno ir pajinio kapitalo, kapitalo ir turto, pajamų ir kapitalo, taip pat pajinio kapitalo ir turto, grynojo pelno ir vidutinio turto, paskolų ir kapitalo santykius nusakantys finansiniai rodikliai. Taigi identifikuojant kredito unijos rizikingumą svarbiausi yra turto, kapitalo ir grynojo pelno duomenys. Be to, nustatyta, kad kredito unijos rizikingumą nusako ir už indėlius mokamų palūkanų ir vidutinių rinkos palūkanų santykis.

Sprendimų medžių formavimo metodais (CART, CHAID, išsamioju CHAID) ir dirbtinių neuroninių tinklų metodu klasifikuojant kredito unijas reikšmingiausi tie patys finansiniai rodikliai. Nustatyta, kad rizikingiausios kredito unijos dirba nuostolingai ir patiria daugiau nei 2,5 procento nuostolio nuo turto, o mažiausios rizikos grupei priklausančios kredito unijos dirba pelningai, jų paskolų ir kapitalo santykis mažesnis nei 6,6, o jų pajinis kapitalas – mažesnis nei 9 procentai nuo viso turto.

Tolimesniuose tyrimuose viešai pradėjus skelbti kredito unijų finansines ataskaitas būtų galima įtraukti ir Lietuvos centrinei kredito unijai nepriklausančias kredito unijas. Taip pat būtų galima atlikti tokius pat tyrimus naudojant kitus metodus ir palyginti su šiame straipsnyje gautais rezultatais. Dar vienas iš galimų variantų – patobulinti kredito unijų rizikingumo nustatymo būdus ar naudoti tam tikrus jų derinius.

### Literatūra

1. Aktan S. 2011: *Early Warning System for Bankruptcy: Bankruptcy Prediction*. Disertacija (rankraštis). Prieiga per internetą: <http://digbib.ubka.uni-karlsruhe.de/volltexte/documents/2001113> (žiūrėta 2012 m. lapkričio 5 d.)
2. Altman E. 1968: Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23(4), p. 589–609.
3. Baker A. 2008: Credit Union Regulation and the Financial Services Authority: Less is More, but Better! *International Journal of Law and Management*, 50(6), p. 301–315.
4. Balcaen S., Ooghe H. 2004: Alternative Methodologies in Studies on Business Failure: do they Produce Better Results than the Classical Statistical Methods? *Vlerick Leuven Gent Management School Working Papers Series*, No. 16
5. Biggs D., De Ville B., Suen E. 1991: A Method of Choosing Multi-Way Partitions for Classification and Decision Trees. *Journal of Applied Statistics*, 18(1), p. 49–62.
6. Braspenning P. J., Thuijsman F., Weijters A. J. M. M. 1995: *Artificial Neural Networks: An Introduction to ANN Theory and Practice*. Germany: Springer, p. 293.
7. Breiman L., Friedman J. H., Olshen R., Stone. C. 1984: *Classification and Regression Trees*. London, Chapman and Hall, p. 368.
8. Bishop C. M. 1995: *Neural Networks for Pattern Recognition*, 3rd ed. Oxford: Oxford University Press, p. 504.
9. Garškaitė K. 2008: Įmonių bankroto prognozavimo modelių taikymas. *Verslas: teorija ir praktika*, 9(4), p. 281–294.
10. Grigaravičius S. 2003: *Įmonių nemokumo diagnostika ir jų pertvarkymo sprendimai*. Kaunas: VDU leidykla, 126 p.
11. Karalevičienė J., Bužinskienė R. 2011: Moderniųjų bankroto diagnozavimo modelių taikymas įmonėje. *Vadyba*, 19(2), p. 113–122.
12. Kass G. V. 1980: An Exploratory Technique for Investigating Large Quantities of Categorical Data. *Applied Statistics*, 29(2), p. 119–127.
13. Mackevičius J., Rakštelienė A. 2005: Altman modelių taikymas Lietuvos įmonių bankrotui prognozuoti. *Pinigų studijos*, No. 1, p. 24–42.
14. Mackevičius J., Silvanavičiūtė S. 2006: Įmonių bankroto prognozavimo modelių tinkamumo nustatymas. *Verslas: teorija ir praktika*, 7(4), p. 193–202.
15. Norkevičius G., Kazlauskienė A., Raškiniš G. 2006: Garsų trukmės modeliavimas naudojant klasifikavimo ir regresijos medžius. *Konferencijos „Informacinės technologijos 2006“ pranešimų medžiaga*, p. 82–85.
16. Norkevičius G., Raškiniš G. 2008: Modeling Phone Duration of Lithuanian by Classification and Regression Trees, using Very Large Speech Corpus. *Informatica*, 19(2), p. 271–284.
17. Pham H. 2006: *Springer Handbook of Engineering Statistics*. Springer, p. 1164.
18. Raudys Š. 2008: *Žinių išgavimas iš duomenų*. Klaipėda: Klaipėdos universiteto leidykla, p. 172.
19. Rugenytė D., Menciūnienė V., Dagilienė L. 2010: Bankroto prognozavimo svarba ir metodai. *Verslas: Teorija ir praktika*, 11(2), p. 143–150.
20. Shmueli G., Patel N., Bruce P. 2010: *Data Mining for Business Intelligence: Concepts, Techniques, and Applications in Microsoft Office Excel with XLMiner*. Wiley, p. 428.
21. Timofeev, R. 2004: *Classification and Regression Trees (cart) Theory and Applications*. Master's thesis. Berlin: Humboldt University.
22. Lietuvos centrinė kredito unija. [interaktyvus]. [žiūrėta 2011 05 15]. Prieiga per internetą: <http://www.lku.lt/lt/kredito-unijos-paslaugos.html>.

### APPLICATION OF MULTIDIMENSIONAL ANALYSIS TO THE ACTIVITY OF CREDIT UNIONS

Vytautas Kėdaitis, Evaldas Žilinskas

**Abstract.** The main purpose of this paper is to develop models that would name risky credit unions, in other words, credit unions, which are most likely at risk of bankruptcy.

The work consists of two main parts: the analysis of literature and the research, and its results and conclusions.

When the survey of the literature was carried out, the authors made financial indicator sets which were used for classification of the credit unions into the risk groups. Bankruptcy cases in Lithuania were insufficient so the authors suggested two ways to measure credit unions' riskiness. Based on good classification results of the surveyed researchers the authors have chosen decision trees and artificial neural network methods to solve a classification problem. Decision trees were formed using CART, CHAID and exhaustive CHAID analysis. With these methods applied, some research was carried out using distinct financial indicator sets and different credit union classification in risk groups. The performed research revealed that the most significant financial indicators classifying risky credit unions were net profit and share capital ratio, capital and asset ratio, income and capital ratio, also share capital and asset

ratio, net profit and average asset ratio, loans and capital ratio. The best classification accuracy was achieved by using artificial neural networks. With different classification of credit union riskiness, the most important financial indicator was interest paid on deposits and average market interest rate ratio. The best classification accuracy was achieved by decision tree made by CART analysis.

The authors believe that the results of the study could provide credit union members (or potential members) with useful guidelines regarding credit unions which they should avoid and which not. Moreover, this information could be useful for supervisors.

**Keywords:** credit unions, classification trees, artificial neural networks, riskiness, estimation.