

TARTU ÜLIKOOL
Majandusteaduskond
Ettevõtetmajanduse instituut

Allar Karu

TEHISLIKE NÄRVIVÕRKUDE RAKENDAMINE AKTSIA HINNA LIIKUMISE PROGNOOSIMISEL

Magistritöö sotsiaalteaduse magistri kraadi taotlemiseks majandusteaduses

Juhendaja: doktorant Allan Teder

Tartu 2012

Soovitan suunata kaitsmisele
(juhendaja allkiri)

Kaitsmisele lubatud “ “.....2012. a.

.....õppetooli juhataja
(õppetooli juhataja nimi ja allkiri)

Olen koostanud töö iseseisvalt. Kõik töö koostamisel kasutatud teiste autorite tööd, põhimõttelised seisukohad, kirjandusallikatest ja mujalt pärinevad andmed on viidatud.

SISUKORD

Sissejuhatus	4
1. Aktsiaturgude filosoofia ja liikumiste kaardistamine	7
1.1. Aktsiaturgude käitumine	7
1.2. Turu dünaamikat jälgivad majandusnäitajad	12
1.3. Närvivõrgu meetodika rakendamine aktsia hinna prognoosi määramisel	21
2. Närvivõrkude rakendamine ettevõtte aktsia hinna liikumise prognoosimisel	30
2.1. Treenitava närvivõrgu sisendid ja väljundid	30
2.2. Parima närvivõrgu leidmine	36
2.3. Parima treenitud närvivõrgu tulemused	47
Kokkuvõte	53
Viidatud allikad	55
Summary	60

SISSEJUHATUS

Investeeringimaailmas on inimestele alati huvi pakkunud majandusprotsesside prognoosimine ning võimalike protsesside kulg. Teades tuleviku liikumisi turul on võimalik langetada ennetavaid otsuseid toimuva hakkavate liikumiste suhtes. Välja on töötatud mitmeid erinevaid matemaatilisi ning ökonomeetrisi mudeleid, millede abil püütakse ennustada nii turgude kui erinevate varaklasside väärtuste liikumisi. Matemaatilistel ning ökonomeetrisel mudelitel on aga omadus, et nad on oma olemuselt staatilised ning selle tõttu nad ei pruugi teatud aja hetkel enam efektiivselt töötada. Viimasel paaril aastakümnel on aga oluliselt arenenud tehislise närvivõrkude meetoodika ning rakendusvõimalused, millest tulenevalt tasuks kaaluda nende kasutamist väärtipaberituru instrumentide hinnaliikumiste prognoosimisel. Siinjuures omavad närvivõrgud prognoosimise seisukohast mitmeid eeliseid, mis staatilistele mudelitele omased ei ole.

Töös käsitletakse erinevaid teooriad, mis mõjutavad aktsia hinna väärtust, et leida koostatavasse närvivõrgu mudelisse muutujaid, mis võiksid olla eelduseks eduka mudeli toimimisele. Samuti esitatakse teoreetiline tagapõhi eduka närvivõrgu prognoosimudeli koostamiseks. Kombineerides omavahel ettevõtte aktsia hinda mõjutavad tegurid ning probleemiks sobiva närvivõrgu arhitektuuri püütakse jõuda lahenduseni, mis aitaks investoritel langetada kauplemisotsuseid vaadeldava ettevõtte aktsia suhtes. Eduka mudeli loomise puhul võib meetoodikat kasutada ka muude sarnaste probleemide lahendamiseks.

Käesoleva magistritöö eesmärk on koostada tehniliku närvivõrgu metoodikat kasutades matemaatiline mudel, mis on võimeline hindama aktsia hinna liikumist lähitulevikus.

Probleemile lahenduse leidmiseks on järgnevad uurimisülesanded:

- Leida aktsia hinda mõjutavad tegurid,
- selgitada närvivõrgu tööpõhimõtted,
- leida andmetele tuginedes parim teoreetiliselt sobiv närvivõrk.

Töö teoreetilises osas tutvustatakse problemaatikat, mis kaasneb aktsiaturgudega ning seal tegutsevate osapooltega. Siinjuures selgitatakse, miks närvivõrk võiks olla hea lahendus tulevaste liikumiste prognoosimisel, võttes siinjuures teadmiseks väärtpaberiturgudele omaseid iseloomujooni. Samuti leitakse muutujad, mis aktsia hinda võiksid mõjutada ning tuuakse need töös välja. Närvivõrkude puhul tuuakse välja, millises osas on nad varem kasutatust leidnud aegridade prognoosimisel, milledeks on näiteks Kulkarn'i (1996) uurimused S&P 500 indeksi põhjal ning Soman'i (2008), kes uuris närvivõrgu rakendamist valdavalt valuutakursside liikumise prognoosimisel. Siinjuures jõudsid mõlemad autorid positiivsete tulemusteni. Varasemad tööd on küll üldjuhul keskendunud pigem makromajandust väljendavate näitajate ennustamisele, kuid siinjuures ei ole alust arvata, miks metoodika ei peaks toimida ettevõtte tasandil. Antud töö sisuks on leida kinnitus väitele, et närvivõrgu metoodikat rakendades, on võimalik prognoosida ettevõtte aktsia hinna liikumist.

Töö esimese peatüki alapunktis seletatakse erinevaid analüüsi metoodikaid, mille alusel turu või väärtpaberite väärtust hinnata ning selgitatakse turu hinnaliikumiste tausta. Järgnevas kahes alapunktis selgitatakse milliste näitajate alusel võiks turu tulevast liikumist prognoosida ning millised näitajad kajastavad adekvaatselt käsitletava probleemi taustal ettevõtte aktsia väärtuse muutumist. Lisaks sellele esitakse teoreetiline käsitus mudeli koostamiseks ning põhjendus mudeli baasarhitektuuri valikul.

Töö lõpetatakse empiirilise osaga, milles esitatakse metoodika, mille alusel kohandati andmed tööks närvivõrkudega. Andmed analüüsiks saadi avalikke informatsiooniallikaid kasutades ning on kõigile ligipääsetavad. Närvivõrgu prognoosimudelisse kaasati lõplikult järgnevad näitajad: Ostujuhtide indeks, kuine USA kogu jaemüük, tarbijate kindlusindeks, töötushüvitiste taotluste arv, aktsiaturu

hinnaindeks, aktsiaturu kauplemisskäive, aktsiaturu volatiilsusindeks, lahustatud kasum aktsia kohta, võlasuhe koguvaradesse, käive aktsia kohta, stohhastiline ostsillaator, suhtelise tugevuse indeks aktsia kauplemisskäive perioodil ning aktsia sulgemishind perioodil. Eduka närvivõrgu mudeli otsingutel kasutati kahte erinevat väljundmuutujat: signaalmuutujat, mis pidi prognoosima kauplemissignaali ning hinnamuutujat, mis väljendas aktsia sulgemishinda järgneval perioodil. Esmalt testiti milline lähenemine väljundmuutuja rakendamisel on tulemuslikum. Parima lahenduse otsingutel treeniti mitmeid erinevaid närvivõrke. Treeningprotsessist ülevaate andmiseks tuuakse välja erinevad katsed ning esitakse nende tulemused. Lõppfaasis presenteeritakse parima leitud arhitektuuriga närvivõrk ning käsitletakse antud närvivõrgu rakendusvõimalusi. Samuti antakse soovitusel edaspidiseks uurimustööks.

1. AKTSIATURGUDE FILOSOOFIA JA LIIKUMISTE KAARDISTAMINE

1.1. Aktsiaturgude käitumine

Turumajanduses kannavad aktsiaturud endal kolme peamist funktsiooni: nad on allikateks ettevõtete finantsinvesteeringutele, annavad ettevõtte juhtidele signaale investeerimisotsuste kohta ning on ka abivahendiks korporatiivrahanduses (Samuel 1996: 1). Kui ettevõtetele on aktsiaturud peamiselt investeeringute finantseerimisallikaks, siis investoritele on aktsiaturud pigem investeerimisvõimaluseks. Läbi aktsiaturgude on investoritel võimalus raha väärpaberitesse paigutada vara kasvatamise eesmärgil. Antud töös käsitletaksegi aktsiaturgu pigem kui investeerimisvõimaluste vahendajat investorile. Turul kaupleb erinevaid investoreid, kõigepealt tasuks kindlasti ära mainida individuaalsed jaeinvestorid. Põhiliselt kujundavad turgu aga suured institutsionaalsed investorid, kelledeks on näiteks: investeerimisfondid, pangad, kindlustuskompaniid ja riskimaandusfondid.

Aktsiaturul kauplevate investorite majanduslikud arvamused ettevõtte suhtes erinevad. Need väljavaadete erinevused avalduvad aga läbi avalikul börsil kaubeldavate tehingute, mis nad antud ettevõtte aktsiaga sooritavad. Sellised tehingud kogutulemina annavad turule konsensusliku arvamuse aktsia hinnale. Omakorda määratletakse nii ettevõtte aktsia hind. Selline aktsiaturg on alates 1960-ndatest teinud läbi olulisi muutusi, avaldades peamiselt järgnevas kolmes vormis: aktsiaturu institutionaliseerimine on viinud aktsiaturu eemaldumiseni väikeinvestoritelt institutsionaalsetele investoritele, muutused valitsuse regulatsioonides aktsiaturu suhtes ning ka innovatsioon, suuresti tänu arvutitööstuse kiirele arengule. (Fabozzi, Modiglian 1991: 225) Arvutitööstuse kiire areng on andnud võimaluse elektrooniliseks kauplemiseks, mis võimaldab ostu- ja müügiotsuseid langetada algoritmide poolt. Algoritmilise kauplemise võtsid esmaselt omaks just suured institutsionaalsed investorid, mis seejärel on leidnud järjest suuremat

kasutajaskonda. (Kim 2007:2) Selle tulemusel on oluliselt vähenenud ka tehingukulud tänu kasvanud volatiilsusele ja pakutava kapitalimahu kasvule, kuna arvutiseeritud kauplemine teeb investorite eest palju tööd ära (Jain 2005 :2982).

Aeg-ajalt tekib investoritel raha, mida nad siis aktsiaturgudele edasi investeerivad. Üheks investeerimise võimaluseks on paigutada raha aktsiaturgudel kaubeldavatesse aktsiatesse. Igal ajahetkel mõjutavad aktsiate hindu aga mitmed erinevad tegurid: makrouudised, mikrokeskkonna tegurid, poliitilised sündmused, kuulujutud jne. (Dalton 1993: 190).

Investorite, kes raha aktsiatesse paigutavad, meeleolu ja emotsioonid on olnud teemaks finantskirjanduses aastaid. Arutelu, meeleolu ja emotsioonide mõju ning nende tähtsuse üle jätkub siiani. Ühteviisi võib investorite investeerimistunnetust tõlgendada kui uskumust tulevastes rahavoogudesse või siis diskontomääradesse, mis ei toetu valdavatele fundamentaalnäitajatele. (Bennet *et al.* 2011: 107)

Kui investorid tegelevad oma raha paigutamise võimaluste otsimisega, siis analüütikud tegelevad investeerimisvõimaluste analüüsimisega. Analüüsi teostatakse põhiliselt kahe erineva meetodika alusel. Üheks analüüsimeetodiks on võimalus kasutada fundamentaalanalüüsi. **Fundamentaalanalüüsi** puhul analüüsitakse aktsiat emiteerinud ettevõtet, tööstusharu, kauplemisturgu ning ka suhtelisi majandusolusid. Sellise analüüsi põhimõtteks on välja selgitada, mis on aktsia tegelik väärtus. Sisuliselt otsitakse, millist aktsiat osta või müüa toetudes majandusele ja selle põhimõtetele. (Alexander, Sharpe 1989: 274-275)

Põhimõttelises vastuolus fundamentaalanalüüsiga on **tehniline analüüs**. Kuigi tehnilise analüüsi teostajate eesmärk on samuti ennustada aktsia hinna liikumisi, kõrvaldavad nad siinjuures tõenäosuse, et täpsed ennustused on võimalik teha analüüsides fundamentaalnäitajaid. Nemad see-eest vaatlevad detailselt hinnaliikumisi, oletus selle taga on, et kõik hinda mõjutavad tegurid peegelduvad juba aktsia hinna muutuses. Aktsia hinna jälgimiseks kasutatakse tehnilise analüüsi puhul erinevaid jooniseid, graafikuid ning indikaatoreid. Otsuseid langetatakse erinevate mustrite alusel, mis koostatud graafikutel ilmnevad. Põhiliselt keskendutakse asjaoludele millal müüa ja

millal osta. Kui on tuvastatud muster püütakse ennustada suund, kuhu aktsia või siis ka kogu turu hind liigub. (Dalton 1993: 187-190)

Niisiis on teada, et turul tehtavad investeerimisotsused langetatakse oma olemuselt kahe erineva meetodi alusel. Kuigi otsuseid langetatakse valdavalt kahe erineva informatsiooni alusel sooritatakse tehinguid samal turul. Siinjuures tuleb tähele panna, et õiglase hinna väljakujunemisel tehakse turule mitmeid eeldusi. Peamine sellest on efektiivse turu hüpotees, mis tähendab seda, et iga informatsioon, mis võiks mõjutada aktsia hinna väärtust on juba peegeldunud selle aktsia hinnas. Siinjuures tehakse lihtsustusi, et näiteks täielikult efektiivsel turul saavutatakse tasakaal arvestades samu tuleviku tootlusi oodates iga investori poolt ning eeldatakse ka „ausat mängu“ (Fama 1969: 413-414). Seega peaks täielikult efektiivsel turul aktsia hind võrduma tema tegeliku väärtusega, kus investeerimisväärtus on väärtpaberi diskonteeritud väärtus, mis põhineb väärtpaberi tulevastel rahavoogudel, mis omakorda on hinnatud teadlike ja pädevate analüütikute poolt. (Palan 2007: 2) Tuleb tähele panna, et aktsiaturud on efektiivsed vaid siis kui kõik osapooled vaatlevad seda ühte moodi. Juba 1980-ndal aastal vaidlesid Grossmann ja Stiglitz (1980: 404), et aktsiaturud ei saa olla täielikult efektiivsed. Turul valitseb palju müra ning kõik osapooled ei oma ühesugust informatsiooni.

Vaatamata turuosaliste informatsiooni teadlikkusele peab toimival turul olema ka eeldus, et seal osaleb piisav arv osapooli nii ostjate ja kui pakkujate poolel. Majanduses kasutatakse „perfektse turu“ mõistet. Perfektse turu puhul on tegemist olukorraga, kus nii ostjate kui pakkujate arv on piisavalt suur ja iga turuosaline on sealjuures piisavalt väike, et ei suuda individuaalselt mõjutada aktsia hinda. Kokkuvõttes on kõik müüjad ja ostjad hinnavõtjad ning turu hind kujundatakse vastavalt nõudluse ja pakkumise tasakaalule. (Fabozzi, Modigliani: 1991, 226) Lisaks sellele puuduvad perfektsel turul mitmed kitsendused, mis finantsturgudel avalduvad näiteks järgnevalt (*Ibid* 1991, 226):

- komisjonitasud maaklerite poolt,
- ostu- ja müügihindade vahed,
- tehingutasud,
- maksud ja ülekandetasud,
- kulud informatsiooni hankimiseks,

- piirangud tehingu mahtudele,
- piirangud tehingutele regulaatorite poolt.

Sellest nimekirjast võib samuti järeldada, et täielikult efektiivset ja perfektset turgu ei ole võimalik saavutada, kuna paratamatult kogu informatsioon ei jõua kõikidele turuosalistele võrdselt, mida näitasid juba Grossman ja Stiglitz (1980: 404). Samuti ei ole kõik turuosalistes võrdsete iseloomuomadustega ja alati ratsionaalset mõtlevad, mis ei lase turul ka nõrgalt efektiivselt käituda. Just irratsionaalsed otsused ja nende alusel käituvad investorid ei lase turgudel ka nõrgalt efektiivselt käituda (Slezak 2003: 547).

Kuigi järjest enam kauplemist tehakse automatiseeritud süsteemide poolt, siis neid süsteeme programmeerivad samuti inimesed. Sellest tulenevalt tuleb aktsiate hinna kujunemisel arvestada ka psühholoogilist mõju. Siinjuures tuleb tähele panna, et psühholoogiline mõju ettevõtte väärtusele avaldub just läbi tema avalikult kaubeldava aktsia hinna, kuna fundamentaalnäitajad kirjeldavad matemaatiliselt ettevõtte sisemist väärtust. Varasemalt sai mainitud, et algoritmide alusel kauplemine on oluliselt suurendanud turgude likviidsust, kasvatanud kauplemismahte ja vähendanud tehingukuluseid (Jain 2005: 2982). Ka Henderstott *et al.* (2011: 30-31) märgivad, et automatiseeritud kauplemine on toonud endaga kaasa likviidsuse kasvu ja kulude vähendamise, kuid siinjuures on oht, et algoritmid kipuvad ekstreemsetes olukordades üle reageerima. Siit võib näha ka algoritmidesse peidetud psühholoogilise mõju olemasolu.

Uurimused investorite ootustest ja tunnetest tuginevad „müraga“ kauplejate mudelitel. Black (1986: 538) näitas juba omal ajal, et muutused, mis ei ole põhjendatavad makroökonomiliste muutujate poolt on tingitud ebakindlusest ja diskussioonidest, mis finantsringkondades aset leiavad. Sellist põhjendamatu liikumist nimetatakse müra (noise). Müra uuringutega aktsiaturgude suhtes jõuti järeldusele, et kui mõni kaupleja kaupleb „mürarikka“ signaaliga, mis ei toetu ettevõtte fundamentaalandmetele, siis ettevõtte aktsia turu hind võib erineda tema sisemistest väärtustest. (Bennet *et al.* 2011: 107)

Tänapäeval on siit tulenevalt võetud kasutusse termin *Behavioural finance*, mida võiks eesti keelde tõlkida kui käitumuslikku rahandust. Michael Pompian (2011: 3) on

käitumusliku rahanduse defineerinud järgmiselt: Käitumuslik rahandus püüab aru saada ja selgitada tegelikku investori ja turu käitumist kõrvutades seda investori käitumisteooriatega. Sarnase tõlgenduse pakuvad ka Baker ja Wurgler (2007: 129): Investori tunnetuslikkus on uskumus tulevasesse rahavoogudesse ja investeerimisriskidesse, mis ei ole õigustatud käes olevate faktide poolt. Siinjuures tuleb tähele panna, et varasemad finantsteooriad käsitlevad finantsturgude vaatenurka pigem kuidas nad peaks käituma (Pompian 2011: 3).

Käitumusliku rahanduse raames eeldatakse, et informatsiooni struktuur ja selle turu osaliste karakteristikud süsteemselt mõjutavad indiviidide investeerimisotsuseid kuid ka turu väljundeid. Käitumuslik rahandus keskendub peamiselt sellele, kuidas investorid tõlgendavad ning reageerivad mikro- ja makroudistele langetamaks investeerimisotsuseid. Finantsturgude globaliseerumine on suurendanud jaeinvestorite kogukonda viimastel aastakümnetel pakkudes laialt erinevaid turu- ja investeerimisvõimalusi. Investeerimisvõimaluste mitmekesisus muudab aga nende investeerimisotsuste protsessi keeruliseks. (Bennet *et al* 2011: 108)

Traditsiooniliste turuteooriate kohaselt mitte ainult turud ei käitu korralikult, vaid ka individuaalsed otsustajad ei käitu kooskõlas oodatava kasu teooriaga. Siin tuleb märkida, et investorid näitavad tundlikkust näiteks orientiirpunktides (*reference point*). Kui mingi kindla ostetud aktsia hind peaks langema halbade uudiste tõttu, siis paljud investorid on vastumeelsed seda kahjumiga müüma. Antud juhul on orientiirpunktiks aktsia algne ostuhind. Investoritel on harjumus hoida end kaotustest, kuid mõned investorid ootavad lootuses, et aktsia hind tõuseb algse ostuhinnani, selle asemel, et ratsionaalselt olukorda hinnata. (*Ibid* 2011: 109)

Arvestamaks investorite käitumuslikke harjumusi tuleb aktsia hinna analüüsid arvesse võtta investorite psühholoogilisi aspekte. Tehniline analüüs hindabki, kuidas inimesed on reageerinud üle aja teatud sündmustele, et määrata kuidas nad käituvad tulevikus. Sellised ajaloolised muustrid võivad olla abiks tuvastamaks turu tippe ja madalkohti. Siinjuures on eeldus, et investorid kordavad omi käitumismustreid. Sellest tulenevalt tehniline analüüs aitab ennustada aktsiahindu, see uurib turu käitumist turu signaalidest lähtuvalt. (Siegel *et al* 2000: 7)

Peamiseks sisuliseks erinevuseks fundamentaalse analüüsi ja tehnilise analüüsi vahel ongi, et fundamentaalse analüüsi puhul püütakse leida ettevõtte tegelikku teoreetilist väärtust, kuid tehnilise analüüsi korral analüüsitakse pigem turuosaliste suhtumist ettevõtte aktsia väärtusesse. Nii püütakse tehnilise analüüsi puhul ennustada lühiajalisi hinnaliikumisi ning sellest tulenevalt saadakse signaale pigem millal osta. Tehnilisi analüüsiga otsitaksegi eelkõige vastust sellele, millal osta ja millal müüa. (Alexander, Sharpe 1989: 274-275)

Fundamentaalanalüüs vastab üldjoontes küsimustele, kui palju on vaadeldav ettevõtte väärt, aga ei aita siinjuures selgitada, kuidas turg sellesse suhtub. Seega on otstarbekas analüüsida turuosaliste suhtumist, enne kui hakata otsuseid tegema, et mis hinnaga osta. Sellest tulenevalt tuleks fundamentaalanalüüsi lisada ka sisendeid tehnilisest analüüsist. Situatsioonis, kui on saadud hinnang ettevõtte väärtusele läbi fundamentaalnäitajate, tasub leida kinnitust otsusele läbi tehnilise analüüsi näitajate. (Schwager 1995: 228)

Pikaajaliselt peaks aktsiaturg jälgima oma sisemist (tegelikku/õiglast) väärtust, kuid lühiajaliselt võib tegelik turuhind oluliselt erineda oma sisemisest väärtusest – eriti just äärmuslike turu olukordade puhul. Äärmuslikud turu olukorrad – nagu buumid ja krahhid – on iseloomustatavad ebaratsionaalselt käituvate turuosaliste poolt, kes ei hinda aktsia väärtust peamiselt tema fundamentaalsete näitajate järgi. Hindamisotsused langetatakse siis pigem irratsionaalsetel motivatsioonidel, mida ei saa põhjendada fundamentaalse analüüsi abil. (Schlichting 2008: 62)

Koostades hindamismudeli, mis võimaldab arvesse võtta nii aktsia fundamentaalseid kui ka tehnilisi aspekte, on teoreetiliselt võimalik leida aktsia õiglane väärtus igal suvalisel hetkel.

1.2. Turu dünaamikat jälgivad majandusnäitajad

Teada on, et nii erinevad makromajanduslikud faktorid ning nendest tulenevad mikromajanduslikud tegurid mõjutavad ettevõtte teoreetilist väärtust. Antud alapunktis tuuaksegi välja erinevad mikro- ja makromajandusnäitajad, mis ettevõtte väärtust mõjutavad ning mida võiks aktsia õiglase hinna leidmisel arvesse võtta. Samuti käsitletakse siin ka võimalusi kuidas mõõta käitumusliku rahanduse aspekti aktsiate

hinda mõjutava tegurina. Mõõtmaks erinevaid tegureid ettevõtte aktsia hindu määravate teguritena, esitakse aktsia hindu liikumist prognoosida aitavad muutujad. Muutujad on esitatud tabelis 1.

Tabel 1. Aktsia hindu liikumise prognoosimist kirjeldavad muutujad.

Makromajandusnäitajad	Aktsiaturu näitajad	Juhtimis-tegevuse suhtarvud	Likviidsus-suhtarvud	Kapitali-satsiooni suhtarvud	Tulemus-likkuse suhtarvud	Tehnilise analüüsi muutujad
Majanduskasvu näitajad: SKP kasv, tarbijate kindlusindeks, investeringute maht jne.	Aktsiaturu käive	Dividend aktsia kohta	Võlasuhe koguvardest	Võlasuhe omakapitali	Investeeringu tootlus (ROI)	Toetus- ja vastupanutasemed
Tööturu näitajad: tööpuuduse osakaal, töötushüvitiste arv jne.	Aktsiaindek-siite liikumine	Lahustatud kasum aktsia kohta (EPS diluted)	Võlasuhe käibevaradesse	Võlasuhe koguvardesse	Varade tootlus (ROA)	Trend
Tööstusharu efektiivsuse näitajad: jaemüügi muutus, varude seis jne.	Turu volatiilsus	Raamatu-pidamislik väärtus aktsia kohta		Pikaajaline kapitali-satsioon	Omakapitali tootlus (ROE)	Momendi hindamine
	Turu hinnastatus	P/E suhtarv			Puhaskasumi marginaal	Liikumiskanalist väljamurdmine
		P/B suhtarv			Käive aktsia kohta	

Allikas: Autori koostatud.

Lõplik valim koostatakse põhimõttel, et muutujad kannaksid endas võimalikult täpset informatsiooni ning ei oleks teiste valimisse langevate muutujate poolt kirjeldatavad. Antud töös jaotatakse aktsia hindu mõjutavad tegurid liikudes makromajandusest ja ettevõtet mõjutavast väliskeskkonnast lõplike hindu parameetrite juurde. Jaotades välja käidud põhimõtte alusel näitajaid ning need omakorda alagruppide lõikes lahti kirjutades saame järgnevalt lõpliku välja käidud andmete struktuuri.

- Makromajandusnäitajad:
 - Ostujuhtide indeks (*Purchasing Managers Index*),
 - Kuine USA kogu jaemüük,
 - Tarbijate kindlusindeks,
 - Töötushüvitiste taotluste arv.
- Aktsiaturu näitajad:
 - Turu hinnaindeks,
 - Turu käive,
 - Turu volatiilsusindeks.
- Juhtimistegevust väljendav suhtarv:
 - Lahustatud kasum aktsia kohta.
- Kapitalstruktuuri suhtarv:
 - Võlasuhe koguvaradesse.
- Tulemuslikkuse suhtarv:
 - Käive aktsia kohta (*Revenue per share*).
- Tehnilise analüüsi muutujad:
 - Stohhastiline ostsillaator,
 - Suhtelise tugevuse indeks,
 - Aktsia kauplemismaht perioodil,
 - Aktsia sulgemishind perioodil.

Järgnevalt käsitletakse lähemalt aktsia hindasid mõjutavaid tegureid. Siinjuures seletatakse, millist informatsiooni muutujad endas kannavad ning mil viisil nad võiksid aktsia väärtust mõjutada. Näitajad on esitatud vastavuses eelnevale loetelule.

Makromajandusnäitajad

Aktsiaturgude tootlused on, nii lühi- kui pikaajaliselt, väga tugevalt mõjutatud majandustingimustest ning majanduse kasvu- või kahanemisfaasist, raha ja eelarvepoliitikast. Need faktorid suudavad tõsiselt mõjutada üksikute ettevõtete tulemuslikkust ning kasumlikkust. Näiteks, kui majandus kasvab, siis enamus ettevõtteid saavad sellest kasu. Samas, kui majandus on kahanemas, siis enamus ettevõtteid, eriti tsüklilised ettevõtted, näevad oma kasumeid oluliselt vähenemas. See

omakorda mõjub nende aktsia hinnale negatiivselt. (Khan 2002: 156) Esmapilgul võetaksegi vaatluse alla makromajandust käsitlevad komponendid.

McMillan (2010: 14) tõestab oma uurimuses, et aktsiaturu fundamentaalidel on oluline jõukusefekt SKP suhtes, mis on ka üheks võtmeteguriks määramaks aktsia hinda kaubeldaval turul. Siinjuures on see ka kooskõlas asjaoluga, et kindlustunne ja loomalikud vaistud (*animal spirits* – Keynes) mängivad olulist rolli investori ja tarbija käitumises. Näiteks kui saabuvald positiivsed uudised majandusest, siis võivad aktsiahinnad olla kõrgemad, kui seda toetavad fundamentaalnäitajad. (*Ibid.* 2010: 14) Soros (2003: 62) väidab oma refleksiivsuse teoorias, et kõrgemad aktsiahinnad toetavad omakorda majanduskasvu, kuna ettevõtted julgevad teha rohkem investeringuid ning tarbijate kindlus tuleviku suhtes on kõrgem. Sellest tulenevalt kaastakse koostatavasse mudelisse majanduse arengut hindav komponent, mis käesolevas töös väljendub ostujuhtide indeksi näol (*Purchasing Managers Index*). Antud indeksit avaldatakse iga kuu esimesel tööpäeval eelneva kuu andmetele tuginedes. Kuna näitajat avaldatakse igas kuus, on mudelisse lisanduv informatsioon oma iseloomult kiire ning täpne. Indeks koosneb viiest alaindeksist, millest 25% moodustab hetkeline tootmistase, 30% uute tellimuste osakaal klientidelt, 15% pakkujate tarnete kiirus, 10% ladude täituvus ning 20% tööhõive osakaal. Antud indeksit avaldab Institute of Supply Management (2012). Lisamaks mudelisse turu toimimist kirjeldavat informatsiooni, võetakse vaatluse alla ka muutuja, mis kirjeldab kuist USA kogu jaemüüki. Vastavat statistikat avaldab United States Census Bureau (2012) ning informatsioon on kättesaadav kaks kuud varasemate tulemuste kohta.

Lemmon ja Portniaguina (2006: 1526-1527) toovad oma läbiviidud empiirilises uurimuses välja, et tarbijate kindlustunne (*consumer confidence*) omab endas olulist ennustamisvõimalust aktsiahindade tootluses ja ka makroökonomilises tegevuses. Siinjuures tuleb tähele panna, et mida suuremat osalust ettevõtte aktsiaportfelligist hoidsid jaeinvestorid, seda suuremat osakaalu tarbijate kindlustunne aktsia hinna kujunemisel määras. Huvitava asjaoluna tuleb märkida ka, et tarbijate enesekindlus on hakanud suuremat rolli investorite käitumises määrama just viimastel aastakümnetel. Sellest tulenevalt lisatakse koostatavasse valimisse tarbijate kindlustunnet kirjeldav näitaja ehk tarbijate kindlusindeks (*Consumer Confidence Index*). Konkreetset indeksit avaldatakse

iga kuu kohta jooksva kuu keskel ning avaldajaks on The Conference Board (2012). Ajaloolised andmed indeksi kohta on kättesaadavad University of Wisconsin (2012) kodulehelt. Indeksit arvutatakse igakuiselt põhinedes 5 000 majapidamise arvamustele. Indeksist 40% moodustavad hinnangud hetkelisele olukorrale ning 60% moodustavad majapidamiste hinnangulised väljavaated tuleviku suhtes. Indeksi baasväärtuseks (100) on aasta 1985.

Hindamaks tulevases mudelis paremini makroökonomilist olukorda võetakse vaatluse alla ka töötuse määr. Angeloni *et al.* (2003: 1296) märgivad, et igasugused šokid makromajanduses mõjutavad tarbimist ja pakkumist, millele omakorda järgnevad kohandumised tööturul. Eelpool sai juba mainitud, et makromajandus mõjutab paratamatult ka mikromajandust ning ka sinna hulka kuuluvaid ettevõtteid. Samas näitavad ka Naes *et al.* (2010, 31), et on olemas seos aktsiaturul toimuvaga ja töötuse määra vahel. Sellest tulenevalt lisatakse mudelisse tööturgu kirjeldava muutujana nädalased töötushüvitiste taotluste arv. Näitajat avaldab United States Department of Labor (2012) iga nädala neljapäeval.

Aktsiaturu näitajad

Üheks aktsia hinda mõjutavaks teguriks võib võtta perioodi kauplemissahu, ehk -käibe (*trading volume*). Kauplemissahu ning üldisemalt ka likviidsust saab vaadelda kui investori tunnetuslikku näitajat. (Baker, Wurgler 2006: 137) Siinjuures on teised leidnud (Gul, Javed 2009: 18), et on võimalik välja tuua tugevaid seoseid kauplemissahude ja väärtpaberi hindade seose puhul. Seda nii agregeeritud turu hinna ja turu kauplemissahu, agregeeritud turu kauplemissahuna ja üksiku ettevõtte väärtpaberi hinna vahel, kui ka ettevõtte aktsia kauplemissahu ja ettevõtte kauplemissahuna vahel. Siinjuures on täheldatav kooskõla, et suurem kauplemissahut mõjub üldjuhtudel suurendavalt kaubeldavatele hindadele. Samas on ka see seos mõlemapidi. Sellest tulenevalt lisatakse mudelisse nii kaubeldava turu hinnaindeks, kauplemissahue, volatiilsusindeks (*VIX*) ning ka rakendatava aktsia kauplemissahut.

Juhtimistegevust väljendav suhtarv

Nagu eelnevas alapunktis mainitud, teostatakse aktsia hindade määramiseks ka fundamentaalanalüüsi. Järgnevalt käsitletakse fundamentaalnäitajaid ettevõtte tasandilt, täpsemalt vaadeldakse, kuidas erinevad fundamentaalide põhjal arvutatavad suhtarvud on seoses ettevõtte väärtusega ning sealt tulenevalt ka aktsia hinnaga.

Bradshaw (2004: 47) väidab oma uurimuse põhjal, et jääktulupõhised väärtushinnangud on positiivselt seotud tulevaste lisatuludega, mis on ka kooskõlas eelnevate uuringutega. Sellest aspektist lähtuvalt lisatakse mudelisse jääktulupõhine suhtarv. Selleks suhtarvudeks on „Lahustatud tulu aktsia kohta“ (EPS diluted – *diluted earnings per share*).

Lahustatud tulu aktsia kohta arvutatakse järgnevalt:

$$(1) \quad EPS \text{ diluted} = \frac{\text{Ärikasum} - \text{eelisaktsia dividendid}}{\text{Lihtaktsiate arv} + \text{konverteeritavate väärtpaberite arv}}$$

Kapitalistruktuuri suhtarv

Kapitalistruktuuri suhtarvudega on võimalik määratleda ettevõtte suhteid omakapitali ja võõrkapitali vahel, samuti kasutatakse ka neid näitajaid võrdluses muude ettevõtetega. Siinjuures määratleb see ka kaudselt, kas ettevõtte on jätkusuutlik ja maksevõimeline. Jätkusuutlikkus ja maksevõimelisus on üks võtmetegureid, mis selgitab ettevõtte võimet genereerida rahavoogu. (Bragg 2002: 103) Kapitali struktuuri määramiseks kasutatakse järgnevat suhtarvu:

Võlasuhe koguvaradesse (*Debts to assets*):

$$(2) \quad \text{Võlasuhe koguvaradesse} = \frac{\text{Kohustused}}{\text{Varad}}$$

Tulemuslikkuse suhtarv

Aasta jooksul ettevõtte genereerib tulusid ja kannab kulusid. Tekkepõhise arvestuse järgi on tulude ja kulude vahe rahavoog, mida ettevõtte toodab. Ettevõtte poolt toodetav raha kas investeeritakse edasi, või siis jaotatakse ettevõtte aktsionäride vahel dividendidena laiali. Kummalgi juhul pole investorile sisulist vahet kas raha jaotatakse investoritele

laiali dividende makstes või selle ettevõttesse edasi investeerides, eeldades siin, et investeringud kasvavad ettevõtte väärtust. Sellisel juhul avaldub investori tulu aktsiaosade väärtuse kasvus. (Alexander, Sharpe 1989: 336-337) Samas näitavad ettevõtte tulemuslikkuse näitajad tema üldist raha genereerimise võimet, mis siis läbi dividendide maksmise või aktsia väärtuse kasvu investorini jõuavad. Mida suurem on aga investorini jõudev rahavoog, seda kõrgemalt hindab investor aktsiat. Campbell *et al.* (2005: 31) näitasid oma avaldatud artiklis, et aktsia hind on sõltuvuses ettevõtte tulususest. Siinjuures, mida noorem ja ettearvamatum on ettevõtte, seda enam tulemuslikkuse suhtarvud aktsia hinda mõjutavad. Samuti märgivad nad, et kasvu- ja väärtusaktiade hinnale on üleüldiselt oluline mõju ettevõtte fundamentaalnäitajatel. Järgnevalt vaadeldakse mudelisse rakendatavat tulemuslikkuse suhtarvu.

Käive aktsia kohta (*Revenue per share*):

$$(3) \quad \text{Käive aktsia kohta} = \frac{\text{Aasta kumulatiivne käive}}{\text{Käigus olevate lihtaktiade arv}}$$

Tehnilise analüüsi muutujad

Varasemalt sai mainitud, et oma olemuselt fundamentaalne ja tehniline analüüs erinevad. Kuigi fundamentaalnäitajate põhjal on võimalik ette ennustada tulevase oodatust suuremaid tootlusi (Abarbanelli, Bushee 1998: 43), siis turu trendi löömise kohapealt võib see osutada mitte väga edukaks tegevuseks. Paljud investorid kipuvad jälgima avalikult esitletavaid ettevõtete finantsaruandeid ning sellest tulenevalt kipub turg käituma sama moodi (Fabozzi, Modigliani 1992: 252). Seetõttu on kasulik loodavasse mudelisse lisada mõni tehnilise analüüsi parameeter, mis aitaks ostu/müügi hetke paremini ajastada. Aktsia hinna ostumomendi tabamiseks lülitatakse mudelisse kaks tehnilise analüüsi muutujat.

Esimese tehnilise analüüsi indikaatorina lisatakse mudelisse stohhastilise ostsillaatori muutuja, mis arvutatakse järgnevalt:

$$(4) \quad \%K = 100 * \left(\frac{CP-LP}{HP-LP} \right) , \text{ kus:}$$

- %K – on kiire stohhastiku väärtus vahemikus 0%-st kuni 100%-ni,
- CP – Aktsia viimane sulgemishind,
- LP – Aktsia madalaim hind viimase 14 perioodi jooksul,
- HP – Aktsia kõrgeim hind viimase 14 perioodi jooksul.

Kui näitaja %K liigub allapoole 20% on see signaal sellest, et aktsia hind on allamüüdnud ning kui näitaja liigub ülevalpool 80% on see märk sellest, et aktsia on üleostetud. Loodavas mudelis peaks näitaja aitama ennustada, kas aktsia hind on liiga kõrge hetkel ostmiseks või mitte. (Siegel *et al.* 2000: 266-267)

Teise tehnilise analüüsi indikaatorina lisatakse mudelisse RSI (suhteline tugevuse indikaator - *Relative Strength Index*) indikaator. RSI oma olemuselt mõõdab aktsia ajaloolist suhtelist tugevust tuginedes tema sulgemishindadele eelneval kauplemisperioodil. (*Ibid.* 2000: 234-242) RSI omab sarnaselt stohhastilisele ostsillaatorile väärtusi 0-st 100-ni. Antud näitaja puhul on ekstreemseteks väärtusteks piirid 30 ja 70, RSI väärtust alla 30-ne peetakse aktsia hinda alamüüduks ning väärtust üle 70-ne puhul üleostetuks.

RSI arvutatakse järgnevalt:

$$(5) \quad RSI = 100 - 100/(1 - RS) , \text{ kus:}$$

$$(6) \quad RS = \frac{14 \text{ päeva keskmine kõrgem sulgemishind}}{14 \text{ päeva keskmine madalm sulgemishind}}$$

Lisades andmebaasi tehnilise analüüsi indikaatorid, mis aitavad mudelil hinnata aktsia hinnapõhiselt, tema suhtelist kallidust on võimalik arvesse võtta turul valitsevat meeolelu. Tehnilise analüüsi parameetrid kannavad, nagu eelnevalt mainitud, endas ka käitumusliku rahanduse poolt ning sellest tulenevalt aitab määratleda, millistes olukordades turu osalised kauplevad ebaratsionaalselt.

Lisaks arvatavatele tehnilise analüüsi näitajatele lisatakse andmebaasi veel vaadeldava aktsia käive ning sulgemishind perioodi lõpus. Varasemalt sai juba antud alapunktis käsitletud, et kauplemismaht ning sulgemishinnad väljendavad endas tehnilise analüüsi olemust ning selle kaudu kannavad endas informatsiooni investorite käitumise kohta. Olles koostanud sobiva andmebaasi töötlemiseks, tuleb hakata nende põhjal ehitama hindamismudelit.

Veel *ca* 15 aastat tagasi võeti tõdemusena, et aktsia hindade liikumine on ülekaalukalt stohhastiline oma olemuselt, kui mitte just päris juhuslik ekslemine. Väide näis vankumatu mitte ainult empiirilisel pinnal, kuid seda toetasid ka teoreetilised toed – nimelt oli see kooskõlas ka efektiivsete turgude paradigmaga. Siinjuures näis võimatu, et kasvu mustreid on võimalik seletada mingi determineeritud protsessi abil. Arvestades, et suurem osa turu kõikumisi põhjustavad juhuslikud uudistevood. (Abhyankar *et al.* 1997: 1)

Viimase paarikümne aasta jooksul on toimunud aga rida arenguid, mis on juhtinud arusaamadele, et aktsiate hinnaliikumiste ennustamine ei ole niivõrd võimatu. Esialgselt jõuti järeldusele, kasutades harilikke ökonomeetrilisi meetodeid, et aktsiahindades leidub olulisi kõrvalekaldeid efektiivsetest olekutest. Teisena jõudsid statistikud, ökonomeetrikud ja füüsikud arenduses testideni, mis võimaldasid täheldada aktsia hindades nii lineaarseid kui ka mitte lineaarseid mustreid. Kolmandaks on viimastel aastakümnetel jõutud mittelineaarsete matemaatika süsteemidega nii kaugele, et suudetakse omistada teatud tüüpi deterministlikku käiku finantsandmetes. Siinjuures on saanud selgeks, et mitmed väikese mõõtmelised deterministlikud mittelineaarsed süsteemid on võimelised genereerima väljundit, mis on üldjuhtudel mitte eristatav valgest müra. (Abhyankar *et al.* 1997: 1)

Rakendades tehniliku närvivõrgu meetodikat on teoreetiliselt võimalik hinnata protsesside kulgu, mille abil finantsandmetel tuginevaid finantsridu prognoosida. Järgnevas alapunktis esitakse tehniliku närvivõrgu põhimõtted ning arhitektuurne ülesehitus töös käsitletavast problemaatikast lähtuvalt. Vastavaid põhimõtteid ning olemasolevaid andmeid kasutades on teoreetiliselt võimalik jõuda süsteemini, mis on võimeline neid protsesse hindama.

1.3. Närvivõrgu metoodika rakendamine aktsia hinna prognoosi määramisel

Närvivõrgud on reaalse maailma statistilised mudelid, mis ehitatakse üles parameetrite häälestamise abil. Need parameetrid, tuntud kui kaalud (*weights*), kirjeldavad mudelit, mis moodustub sisendite (*inputs*) ja väljundite (*outputs*) vaheliste seoste kaardistamise teel. Parameetrite häälestamine õigetele väärtustele – treenimine (*training*) – viiakse läbi sooritades mudelis katseid erinevate sisendite ja väljundite paaride vaheliste kaalude kohandamise teel. Kaale kohandatakse, et vähendada viga mudeli poolt ennustatava väärtuse ja tegeliku väärtuse vahel. Hetkel, mil kaalud on määratletud, on mudel võimeline tootma väärtusi väljunditele, millele sisenditel puudusid vastavad väljundi väärtused. Siinjuures ei viita mudel enam algselt tema treenimisel osalenud andmetele kui ta on juba treenitud, selle tõttu on see mudel funktsiooniline kokkuvõtte treeningandmetest. (Swingler 2001: 3)

Närvivõrkude arvutustehnikal on mõned olulised erinevused programmeeritud käitumise suhtes ning on teada, et näiteks algoritm-kauplemine tugineb programmeeritud käitumisel. Järgnevas tabelis 2 ongi ära toodud programmeeritud arvutustehnika olulisemad erinevused närvivõrkude arvutustehnikate suhtes.

Tabel 2. Närvivõrkude arvutustehnika erinevused programmeeritud käitumisest.

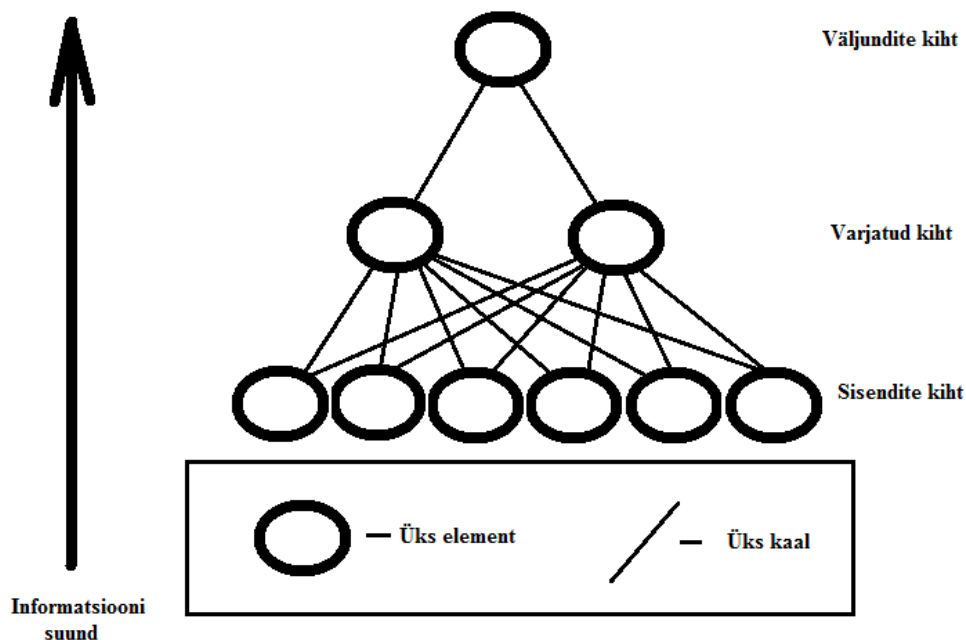
Programmeeritud lähenemine	Närvivõrkudel arvutades lähenemine
<ul style="list-style-type: none">• Järgib endasse kirjutatud reegleid• Lahendus on formuleeritud• Ei suuda üldistada• Ei ole veatolerantne	<ul style="list-style-type: none">• Õpib andmetelt• Reeglid ei ole nähtavad• Võimaldab üldistada• Saab hakkama müraga

Allikas: (Applying Neural Networks 2001: 9).

Andmetelt õppimise näol peetakse närvivõrkude puhul silmas asjaolu, et tegemist on paindlikku süsteemiga, mis salvestab endasse vajalikud parameetrid õigete väljundite genereerimiseks. Vastav informatsioon salvestatakse süsteemi, temast läbi voolavate

andmete abil. Sellisel puhul on õige arhitektuuriga ehitatud süsteem võimeline õppima ning muutuma teda puudutava keskkonnaga koos. Kui programmeeritud käitumise puhul kirjutakse sisse kindlad reeglid, millede järgi süsteemid langetavad otsuseid, siis närvivõrkude puhul genereeritakse need reeglid võrkude poolt ise. Närvivõrgu looja pigem seab valmis süsteemi arhitektuuri, mille alusel reegleid genereeritakse. Üldistamise võime all peetakse silmas asjaolu, et närvivõrgud on võimelised õppima (toimima) ka olukorras, kus andmed sisaldavad müra ning siinjuures tulevad toime ka lünklike andmetega.

Antud töös käsitletakse närvivõrkude süsteemina enim levinumat ja vast kõige universaalsemat närvivõrkude tüüpi, milleks on mitmekihiline pertseptron võrk, ehk MLP (*Multi Layer Perceptron*). MLP tüüpi võrk on vaid üks näide närvivõrkude tüübist, kuid see on kõige populaarsem ning paljud kontseptsioonid, mis rakenduvad MLP tüüpi võrgule töötavad sama hästi ka teiste võrkude peal. Joonisel 1 on toodud MLP tüüpi võrgu toimimisskeem. (Swingler 2001: 10)



Joonis 1. MLP närvivõrgu baasstruktuur koos ühe kihi varjatud elementidega (Swingler 2001: 11).

Joonisel 1 kujutatud igasse elementi tuleb teda aktiveeriv informatsioon temale eelnevast elemendist, mis on võimendatud kaaluga, mida mööda informatsioon liikus. Kui sisendandmed mitmetest elementidest liiguvad igasse järgnevasse kihti, tuleb informatsiooni tulemusvektorid summeerida enne kui kogu info järgnevasse elementi edasi kantakse. Antud funktsioon peab mahutama kogutud informatsiooni nõutavasse vahemikku. (Swingler 2001: 10)

Järgnevalt tuuakse välja närvivõrgus rakendatavad valemite põhikujud ning sümbolite märgistused. Järgnevas nimekirjas ongi seletatud sümbolite tähendused (Swingler 2001: 19):

- Ainsale elemendile viidatakse läbi indekseid i ja j , mis on seotud nimekirjas järgnevate sümbolitega. Siinjuures võib element j olla igas kihis närvivõrgus, kuid kui nii i -d ja j -i on kasutatud, siis element j on alati lähemal väljundile kui element i .
- Väärtused n ja m tähistavad elementide arvu kihis.
- Sümbol w_{ji} tähistab kaalu elemendilt i elemendile j järgmises kihis. Kaalu muutust, mis teostatakse tähistatakse sümboliga Δw_{ji} .
- Sümbol o_j tähistab väljundit elemendilt j .
- Sümbol v_j tähistab sisendit elemendile j .
- Sümbol d_j tähistab soovitud väljundit elemendilt j .
- Sümbol e_j tähistab vea tuletist elemendil j .
- Sümbol $f(\cdot)$ on närvivõrgu aktiveerimisfunktsioon ja $f'(\cdot)$ on tuletis närvivõrgu aktiveerimisfunktsioonist.
- Sümbol η on õppimisparameeter.
- Sümbol α on momendi parameeter.

Järgnevalt on lahti seletatud närvivõrkudes toimivad põhivalemid.

Aktiveerimisfunktsioonid

Aktiveerimisfunktsiooni üldine kuju summeerib iga eelneva väljundi tulemi altpoolt elemendilt ning seejärel kaalub seda kaaluga, mis on seotud talle määratud elemendiga:

$$(7) \quad o = f\left(\sum_{i=1}^m w_{ji}o_j\right)$$

Lihtne väljundi veamäär

Lihtsaim ja harilikum veamäär on vahe elemendi o_j väljundi ja samale elemendile soovitud väärtuse d_j vahel. Vea tuletis väljundina arvutatakse järgnevalt:

$$(8) \quad e_i = f'(o_i)(d_i - o_i)$$

Siin tuleb tähele panna, et viga on siinkohal väljendatud tuletisena aktiveerimisfunktsioonist.

Vigade tagasipaljundamine varjatud kihtidesse

Viga igas elemendis varjatud kihis i leitakse kui summa vigade tuletistest, e_j (kõrgema rea elemendi vea tuletisest) elementidel kõrgemas reas j ja kaalude tugevustest, mis neid seovad:

$$(9) \quad e_j = f'(o_i)\left(\sum_{j=1}^n e_j w_{ji}\right)$$

Uus viga on kirjeldatav aktiveerimisfunktsiooni tuletisena.

Kaalude parandamine

Kaalude muutus elemendilt i elemendile j leitakse kui õppimismäära tulem, mis on vea tuletis elemendile j ja väljund elemendilt i :

$$(10) \quad \Delta w_{ji} = \eta e_j o_i$$

Kirjeldatud närvivõrkude põhivalemid loovad süsteemi, mille alusel närvivõrkude mehhanism töötab. (Swingler 2001: 19-20) Turu analüüsi seisukohast on närvivõrgud

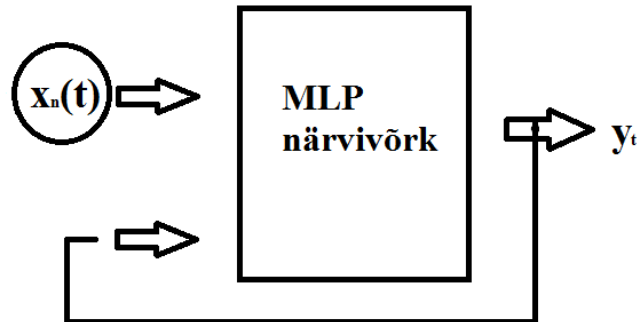
mudelid, mis suudavad arvutada elastsuseid muutujate vahel, suutes leida mustreid ka mitte lineaarsete andmete hulgast. Siinjuures saab närvivõrke kasutada ka andmete analüüsil ja just nende tähtsuse leidmisel. Närvivõrgud võimaldavad hinnata, milline informatsioon on oluline väljundi leidmiseks ning milline mitte. (*Ibid.* 2001: 221-223) Valdav osa närvivõrkudel üles ehitatud mudeleid on siinjuures andnud kinnitust, et antud meetodikal on võimalik hinnata turu liikumist. Närvivõrkude tähtsust nähakse just valdkondades, mida varasemad mudelid ei suutnud piisavalt tõlgendada. (Swingler 2001: 234-235)

Siinjuures on Kulkarni (1996: 17) jõudnud närvivõrku S&P 500 indeksil testides tulemuseni, et antud meetodika võib olla aktsiaturu ennustamisel väga efektiivne. Kulkarni kasutas siinjuures samuti MLP tüüpi võrku. Olulise aspektina tuleb välja tuua siinjuures, et antud juhul suutis närvivõrk ennustada ka ekstreemseid situatsioone. Antud uurimus viidi läbi nädalapõhjalistel andmetel. Kajitani *et al.* (2005: 115) näitasid, et aegridade puhul suudavad MLP tüüpi võrgud (võrgud, kus info liikumine on ühesuunaline) lüüa ka seni välja töötatud väga põhjalikke ökonomeetrilisi mudeleid. Nende praktiline töö oli küll Kanada ilveste põhjal, millede populatsioon on väga kõikuv ning seetõttu statistikutele parajaks väljakutseks. Siinjuures näitasid Chan *et al.* (2000: 5), et on võimalik modelleerida aktsia hinna tulevast väärtust kasutades tema ajaloolist informatsiooni.

Närvivõrke on oma arhitektuurilt erinevaid, kuid mitmed autorid (Menezes, Barreto 2008; Soman 2008) kasutavad finantsandmete puhul NARX (*Nonlinear Autoregressive Network with Exogenous Inputs*) närvivõrgu struktuuri ning on täheldatud, et NARX tüüpi võrgud suudavad aegridu prognoosida teistest aegridade võrgutüüpidest paremini (Menezes, Barreto 2008: 3352-3343; Jiang, Song 2011: 1428). Siinjuures suudab NARX tüüpi närvivõrk edastada ka mitmeid varasemalt välja töötatud ökonomeetrilisi ja muid statistilisi matemaatilisi mudeleid (Soman 2008: 77, Pape *et al.* 2007: 516). Oma positiivsete tulemuste puhul aegridade modelleerimisel varasemates uurimustes valitaksegi antud töös kasutamiseks NARX arhitektuuriga närvivõrk.

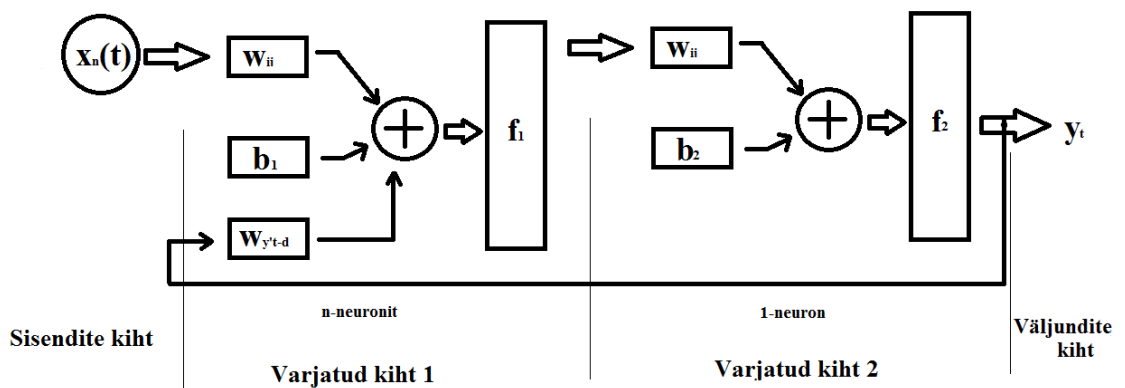
NARX tüüpi närvivõrgud on MLP närvivõrkude edasiarendus, mis on kohandatud aegridade modelleerimiseks. NARX tüüpi närvivõrku on lisatud muutujate viitajad ning

funktsioonid on kohandatud vastavalt. Järgneval joonisel 2 on esitatud NARX närvivõrgu olemus MLP tüüpi närvivõrgu suhtes.



Joonis 2. NARX närvivõrk hariliku MLP tüüpi võrgu suhtes (MathWorks 2012).

Nagu eelnevalt jooniselt võib näha sisaldab NARX närvivõrk endas MLP närvivõrgu olemust, kuid üldpildis ei liigu siiski info võrgus vaid ühes suunas. Antud võrgu puhul saadetakse MLP närvivõrgu poolt eelnevateks perioodideks (sõltuvalt valitud viitaegadest) genereeritud väljundväärtus sisendina uuesti närvivõrku sisse. Täpsemalt nimetatakse antud võrgu struktuuri „NARX paralleelse arhitektuuriga“. Antud protsessi tulemusena kiirendatakse oluliselt võrgu treenimisprotsessi ning vähendatakse võimalikku viga. (MathWorks 2012) Täpsem NARX tüüpi võrgu struktuur on esitatud joonisel 3.



Joonis 3. NARX närvivõrgu baasstruktuur (MathWorks 2012).

Sisendite kihis lisatakse erinevad sisendmuutujad (x -erinevat elementi, n -elementide arv, t -periood). Varjatud kihis 1 on valitud optimaalne neuronite arv. Varjatud kihis 2 on varjatud kihist 1 informatsiooni kokku võttev üks neuron. Informatsiooni läbitöötlemisel väljastatakse see närvivõrgust väljundväärtusena y_t . Teooria närvivõrkude puhul väidab, et on võimalik igat süsteemi ära kirjeldada ühe varjatud kihi abil (Swingler 2001: 61-61), kuid NARX tüüpi närvivõrgul on oma olemuselt tarvilik teist varjatud kihti informatsiooni kokku võtmiseks, siis tema minimaalne varjatud kihtide arv on kaks. Kummagi varjatud kihi neuronid sisaldavad endas aktiveerimisfunktsioone ning sisendit parameeter b näol, mis määrab funktsiooni kallaku. (MathWorks 2012)

Elementide ehk neuronite arvu optimaalseks määraks varjatud kihis pole olemas rusikareeglit, erinevad autorid on küll välja pakkunud võimalikke tulemusvalemiteid, kuid üldjuhul soovitatakse jõuda parima lahenduseni läbi katse-eksituse meetodi (Swingler 2001: 51-51). Siinjuures tuleb tähele panna, et suurem neuronite arv võib viia kiiremini optimaalse lahenduseni, kuid suurem neuronite arv nõuab oluliselt rohkem arvutusvõimsust ja läbi selle aega nõuda. Samuti on närvivõrkude puhul kasutuses mõiste ülepaigutamise (*overfitting*), mille tulemusel võib võrk prognoositavaid väärtusi liiga siluma hakata, mis võib olla liiga paljude neuronite arvu üks tulemusi. Siinjuures on närvivõrkudel nagu ka muudele keerulistele tehisintelligendi- ning arvuti süsteemidele omane mõiste „must kast“ (*black-box*), mille tõttu ei ole alati täpselt teada, millist väljundit süsteemist võib oodata. Nii võib ühes olukorras saavutada näiteks väga efektiivse võrgu väga lühikese ajaga, kuid teises olukorras väga vaevaliselt või siis üldse mitte, siinjuures võttes eeldusteks samad alused (Kajitani *et al* 2005: 115). Hansen ja Nelson (2003: 307) märgivad ka, et antud musta kasti olemus seab antud hetkel piirangud, et luua ühtset toimivat närvivõrgu meetodikat kindlaks määratud protsesside kordamiseks. Sellest tulenevalt tuleb närvivõrke genereerides jõuda parima lahenduseni katse-eksituse meetodil. Üldjuhul kasutatakse 2-10 neuronit.

Närvivõrkude varjatud kihtide neuronites (elementides) asuvad aktiveerimisfunktsioonid, mis eelnevate kihtide neuronitest pärineva informatsiooni kokku summeerivad ning kaaludega läbi korrutavad. Saadakse elemendi o_j väärtus, mis saadetakse läbi

aktiveerimisfunktsiooni. Närvivõrkudes kasutavad aktiveerimisfunktsioonid on järgmised (Swingler 2001: 72-73):

- Lineaarne aktiveerimisfunktsioon:

$$(11) \quad f(o_j) = \gamma o_j,$$

kus γ – osakaal, mis määratletud kallakuna.

- Logistiline aktiveerimisfunktsioon:

$$(12) \quad f(o_j) = \frac{o_j}{1 + e^{-o_j}},$$

- Hüperboolne tangensi (tanh) aktiveerimisfunktsioon:

$$(13) \quad f(o_j) = \tanh(\gamma o_j) \equiv \frac{e^{\gamma o_j} - e^{-\gamma o_j}}{e^{\gamma o_j} + e^{-\gamma o_j}}.$$

Lineaarne ja hüperboolse tangensi aktiveerimisfunktsioonid omavad väärtusi -1-st 1-ni ning logistiline aktiveerimisfunktsioon omab väärtusi 0-st 1-ni. Sellest tulenevalt tuleks ka väljundisignaale omistada väärtused vastavalt kas siis -1-st 1-ni või siis 0-st 1-ni. Hüperboolse tangensi aktiveerimisfunktsioon on a-sümmeetriline ning selle tõttu võib see vajada lühemat treeningaega. (Swingler 2001: 72-73) Funktsioonide iseloomudest võib aga välja lugeda, et antud juhul tuleb tegeleda väljundi skaleerimisega. Tegelikuses on otstarbekas ära skaleerida samasse vahemikku ka sisendmuutujad, kuna vastasel juhul võib närvivõrk omistada teatud muutujatele põhjendamatult kõrgeid või madalaid kaale, ning selle tulemusel väljundit kallutada. (*Ibid.* 2001: 31)

Närvivõrgu treenimisel on otstarbekas alustada alati Levenberg-Marquardt optimeerimisfunktsioonist. Tihti peale on see kiireim ning täpsem viis võrgu treenimiseks, siinjuures sobib see just hästi MLP tüüpi närvivõrkudele. Antud funktsiooni näol on tegemist minimeerimisfunktsiooniga, mis pakub numbrilise lahenduse üle funktsiooni parameetrite ruumi. Tegemist on mittelineaarse funktsiooniga. (MathWorks 2012)

Närvivõrgu toimimist on võimalik hinnata näiteks läbi närvivõrgu poolt genereeritavate väljundite võrdlusega tegelike väljundite väärtustega, aegridade puhul on see näiteks mingi indeksi skaleeritud väärtus perioodidel t . Vea mõõtmiseks, võib kasutada nii lihtsat harilikku viga ($viga_j = väljundi tegelik väärtus_i - võrgu prognoositud väärtus_i$), kui ka näiteks ruutkeskmist viga, lihtsat kaalutud viga ning kaalutud ruutkeskmist viga. (Swingler 2001: 73-74) Ei ole põhjust arvata, et pakutud vea mõõtmisviisidest peaks ühte eelistama teistele. Oluline on, et erinevate närvivõrkude võrdluses võrreldaks neid samade veamääradega parima tulemuse otsimisel.

Lisaks vea määrale on võimalik närvivõrgu headust hinnata tema poolt genereeritud kaalude histogrammi abil. Antud kontrolli on otstarbekas teha pärast parima võrgu analüüsi ning seejärel anda hinnang, kas antud meetodikatest leitud võrk on koostatud siiski probleemiks parima võimaliku meetodika alusel. Alakohandatud kaalud (üldjuhul korralikult treenimata võrgul) koonduvad histogrammil kõik keskvaartuse ümber, ülekohtandatud võrgu puhul jaotuvad nad aga võrdselt laiali. Hea närvivõrk peaks seega omama kaale normaaljaotusega. (*Ibid.* 2001: 69-70)

Närvivõrkude iseloomule ja omadustele tuginedes ning arvestades varasemate uuringute positiivseid näiteid võib arvata, et närvivõrkudel loodud prognoosimismudelit saab edukalt rakendada ka aktsia väärtuse tulevase muutumisel. Kuigi varasemad näited on olnud edukad just laiapõhjalisema turuinformatsiooni hindamisel ei ole alust arvata, et meetodika ei peaks toimima ettevõtetetasandil. Käesoleva töö teises osas püütaksegi rakendada närvivõrkude meetodit ettevõtte aktsia tulevase väärtuse liikumise prognoosimisel.

2. NÄRVIVÕRKUDE RAKENDAMINE ETTEVÕTTE AKTSIA HINNA LIIKUMISE PROGNOOSIMISEL

2.1. Treenitava närvivõrgu sisendid ja väljundid

Järgnevates alapunktides keskendutakse närvivõrkude rakendamisele ettevõtte aktsia väärtuse liikumise prognoosimisel. Siinjuures kasutatakse eelnevates töö osades välja käidud seisukohti ning teooriaid. Valides analüüsiks ettevõtet sai lähtunud põhimõttest, et eelnevalt töös esitatud tegurid tõepoolest võiksid mõjutada antud ettevõtet ja siinjuures küllaltki üheselt. Sellest tulenevalt ei olnud mõistlik analüüsiks valida ettevõtet mille näiteks tulud jaotuvad võrdselt erinevate maailma osade vahel või siis jälle ettevõtet, mis on tugevalt sõltuvuses mingitest kindlatest parameetritest, mis ei ole tugevalt makromajandusega seotud.

Antud töös valiti analüüsiks ettevõtte Wal-Mart Stores Inc. Ettevõtte oma põhiolemuselt on säästu jaekaubanduskett, kus müüakse kõiki toidukaupu lisaks üldistele majapidamistarvetele, siinjuures on pakutaval sortimendil väga suur omamärgitoodete (*private label*) osakaal. WalMart asutati 1962. aastal Sam Waltoni poolt esimese poe avamisega Rogersis, Arkansase osariigis, Ameerika Ühendriikides. Kümne aastaga kasvas poodide arv juba 276-ni ning tegutseti 11 osariigis. Täna hetkel on Wal-Mart Ameerika Ühendriikide üks suurimaid jaekaubanduskette, mis olnud noteeritud juba 1972.-st aastast New York'i aktsiaturul. Täna päevaks on kaubandusketil ligi 8 500 poodi 55 erineva nime all. Nädalas teenindatakse keskmiselt rohkem kui 200 miljonit klienti ning ettevõtte palgal on 2,2 miljonit töötajat. 2012. majandusaasta prognoositav käive on ligikaudu 444 miljardit USD-d. (Walmart Corporate 2012)

Kuigi ettevõtte tegutseb 27 riigis saadakse ligi 75% tuludest Ameerika Ühendriikidest. Wal-Mart on hea ettevõtte analüüsiks, kuna sõltub küllaltki tugevalt ühe regiooni makromajandusest (Ameerika Ühendriigid) ning on sellest tulenevalt üldise

majanduspildiga küllaltki tugevalt seotud. Samuti on osutunud Wal-Mart'i aktsia ajalooliselt küllaltki stabiilseks ning pole läbi elanud märkimisväärseid ekstreemsusi.

Andmebaas närvivõrgu treenimiseks koostati avaliku informatsiooni alusel. Valimi kogumahuks võeti ajaliselt 11 aastat alustades 2001-se aasta esimesest nädalast ning lõpetades 2011-nda aasta viimase nädalaga. Andmeridade ajaliseks intervalliks võeti siinjuures üks nädal, millest tulenevalt jäi lõplikusse andmebaasi 538 erineva nädala andmed, kui oli maha arvatud teisendamistest ning arvutustest tekkivad puuduvad väärtused. Siinjuures tuleb märkida, et aktsia ja turu hindu, kauplemismahtu ning ka töötusabirahade taotluste mahtu väljendavad andmed olid kättesaadavad nädalapõhiselt. Samas näiteks makroandmetest olid kogu jaemüügi määr, tarbijate kindlusindeks ja ostujuhtide indeks kättesaadavad vaid kuupõhiselt. Ülejäänud finantsandmed (v. a. tehnilised indikaatorid) olid rakendatavad andmebaasi koguni vaid kvartalipõhiselt, nagu näiteks ettevõtte finantssuhtarvud. Põhiline probleem andmete puhul seisnebki selles, et ettevõtete finantsnäitajaid, nagu ka Wal-Mart'i puhul, esitatakse kord kvartalis, mille tõttu tuleb samu väärtusi ajas edasi pikendada ning vastavad muutujad on teatud perioodi vältel staatilised. Samas ei peatud vajalikuks andmebaaside ridu vähendada ka näiteks kuupõhisteks, sest sellest tulenevalt võib investeerimishorisont kujuneda liiga pikaks. Andmed analüüsiks on saadud Yahoo! Finance'i (S&P 500 2012; Wal-Mart Stores Inc 2012; Volatility S&P 500 2012), University of Wisconsin'i (Consumer Confidence Index 2012), United States Census Bureau (Business and Industry 2012), United States Department of Labor'i (Unemployment Insurance ... 2012), Institute for Supply Management'i (ISM Report On Business 2012) ja Stockpup'i (Corporate fundamental data 2012) interneti lehekülgedelt.

Andmebaasi kuuluvad esimeses töö osas välja käidud muutujad, milledeks on:

- Makromajandusnäitajad:
 - Ostujuhtide indeks (*Purchasing Managers Index*),
 - Kuine USA kogu jaemüük,
 - Tarbijate kindlusindeks,
 - Töötushüvitiste taotluste arv.

- Aktsiaturu näitajad:
 - Turu hinnaindeks,
 - Turu käive,
 - Turu volatiilsusindeks.
- Juhtimistegevust väljendav suhtarv:
 - Lahustatud kasum aktsia kohta.
- Kapitalstruktuuri suhtarv:
 - Võlasuhe koguvaradesse.
- Tulemuslikkuse suhtarv:
 - Käive aktsia kohta (*Revenue per share*).

Kõik eelnevalt väljatoodud muutujad on närvivõrkude mudeli koostamisel sisendmuutujateks (suhtarvud ning kordajad arvutati välja töös esitatud valemite põhjal). Sõltuvalt andmete avaldamise aegadest sisestatakse need mudelisse nii, et arvestatakse nende ajalise avaldamiskalendrist tulenevate nihetega nagu näiteks ostujuhtide indeks on mudelis kuuajalise hilinemisega, kuna näitaja avaldatakse järgneva kuu esimesel tööpäeval. Tarbijate kindlusindeks on mudelis jällegi kahenädalase nihkega kuna näitaja avaldatakse jooksva kuu keskel.

Eelnevas peatükis sai mainitud, et närvivõrkude modelleerimiseks on tarvilik muutujad skaleerida ühele skaalale, kas siis 0-st 1-ni või siis -1-st 1-ni. Järgnevalt esitatakse andmete töötlemiseks kasutatud meetodikaid. Kuna modelleerimiseks sai valitud nii lineaarne kui ka hüperboolse tangensi aktiveerimisfunktsioon, siis tuli kõik andmed skaleerida vahemikku, kus nende miinimum ei oleks väiksem -1-st ning suurem 1-st. Siinjuures tuleb aegridadest eemaldada ka trend. Muutujate aegridade töötlemiseks kasutatakse Microsoft Office Excel 2007 tarkvara. Esmalt tuuakse välja lihtsamalt skaleeritavaid muutujad. Muutujad ning nende skaleerimiseks kasutatavad võtted on kirjeldatud järgnevalt:

- Tarbijate kindlusindeks:

Antud muutuja varieerub väärtuse 100 ümber, sellest tulenevalt kasutati skaleerimiseks lihtsat valemit:

$$(14) \quad \textit{skaleeritud v\aa rtus}_t = \left(\frac{\textit{skaleerimata v\aa rtus}_t}{100} \right) - 1.$$

- T\o otush\uvitiste taotluste arv:

Konkreetse muutuja teisendamiseks kasutati j\aa rgmist v\o tet:

$$(15) \quad \textit{skaleeritud v\aa rtus}_t = \left(\frac{\textit{skaleerimata v\aa rtus}_t}{\textit{perioodi aritmeetiline keskmine v\aa rtus}} \right) - 1.$$

- Ostujuhtide indeks, stohhastiline ostsillaator ja suhtelise tugevuse indeks:

Antud muutujad varieeruvad v\aa rtuse 50 \u00fcmber. Stohhastilise ostsillatori ning suhtelise tugevuse indeksi k\o ikumiste amplituudid v\o ivad k\u00fcll olla laiad, kuid nad ei oma kunagi 0-st v\aa ksemaid ning 100-st suuremaid v\aa rtusi. Sellest tulenevalt kasutati muutujate skaleerimiseks j\aa rgnevat v\o tet:

$$(16) \quad \textit{skaleeritud v\aa rtus}_t = \left(\frac{\textit{skaleerimata v\aa rtus}_t}{50} \right) - 1.$$

J\aa rgnevalt esitatakse S&P 500 turu volatiilsuse, S&P 500 VIX indeksi ning vaadeldava aktsia (antud juhul Wal-Mart) kauplemisk\aa be teisendamine kujule -1-st 1-ni. Teisendamisev\o tted sooritatakse j\aa rgnevas j\aa rjekorras:

1. V\o etakse skaleerimata v\aa rtusest naturaalloogarm:

$$(17) \quad \textit{logaritmitud v\aa rtus}_t = \ln(\textit{skaleerimata v\aa rtus}_t).$$

2. Leitakse logaritmitud v\aa rtuste aritmeetiline keskmine:

$$(18) \quad \textit{logaritmitud v\aa rtuste keskmine} = \left(\frac{\sum_{t=1}^n \textit{logar\aa tmitud v\aa rtus}_t}{n} \right).$$

3. Lahutatakse logaritmitud v\aa rtusest aritmeetiline keskmine:

(19)

$$\textit{leitud v\aa rtus}_t = \textit{logaritmitud v\aa rtus}_t - \textit{logar\aa tmitud v\aa rtuste keskmine}.$$

4. Leitakse 3. punktis leitud väärtuste maksimum ning miinimumi absoluutväärtus. Antud tehete sooritamiseks kasutatakse üle käsitletavate aegridade Microsoft Office Exceli funktsioone „MAX“, „MIN“ ja „ABS“.
5. Jagatakse 3. punktis leitud väärtus kohal t 4. punktis leitud maksimaalse absoluutväärtusega.

(20)

$$\text{skaleeritud väärtus}_t = \frac{\text{leitud väärtus}_t}{\text{MAX}(\text{MAX}(3.\text{punktis leitud väärtused});\text{ABS}(\text{MIN}(3.\text{punktis leitud väärtused}))}$$

Sellisel viisil genereeritud aegread omavad endas võimalikke väärtusi vahemikus -1-st 1-ni ning sobivad modelleerimiseks tehislake närvivõrkudega.

Järgnevad valimis olevad sisendmuutujad sisaldavad endas trendi ning seetõttu tuleb aegridade modelleerimisel ka antud asjaolu arvesse võtta, ehk trend eemaldada. Antud muutujate plokki kuuluvad järgmised näitajad: Kuine USA kogu jaemüük, S&P 500 hinnaindeks, lahustatud kasum aktsia kohta, võlasuhe koguvaradesse, käive aktsia kohta ning vaadeldava aktsia (antud juhul WalMart) sulgemishind perioodil. Viimases plokkis olevate muutujate aegridade teisendus- ja skaleerimisvõtted on toodud oma järjekorras järgnevalt:

1. Leitakse aegrea parima regressioonisirge lõikumispunkt y -teljega. Selleks kasutatakse Microsoft Office Exceli funktsiooni „INTERCEPT“:

$$(21) \text{ lõikepunkt } y - \text{teljega} = \text{INTERCEPT}(\text{perioodi skaleerimata väärtused})$$

2. Leitakse aegrea regressioonisirge kallak perioodis. Kallaku leidmiseks kasutatakse Microsoft Office Exceli funktsiooni „SLOPE“:

$$(22) \text{ regressioonisirge kallak} = \text{SLOPE}(\text{perioodi skaleerimata väärtused}).$$

3. Genereeritakse aegrida, mille esimene liige avaldub y -telje lõikumispunkti ja regressioonisirge kallaku summana. Aegrea ülejäänud liikmed leitakse järgnevalt:

$$(23) \text{ väärtus perioodil}_t = \text{väärtus perioodil}_{t-1} + \text{regressioonisirge kallak} .$$

Antud punktis genereeritud aegrida on oma sisult ka esialgsete andmete trendi väljendavad väärtused.

4. Eemaldatakse aegreast trend. Trendi eemaldamiseks kasutatakse järgmist võtet:

$$(25) \quad \text{väärtus perioodil}_t = \text{esialgne väärtus}_t - 3.\text{punktis leitud väärtus}_t .$$

5. Leitakse 4. punktis leitud väärtuste maksimum ning miinimumi absoluutväärtus. Antud tehete sooritamiseks kasutatakse üle käsitletavate aegridade Microsoft Office Exceli funktsioone „MAX“, „MIN“ ja „ABS“.

6. Jagatakse 3. punktis leitud väärtus kohal t 5. punktis leitud maksimaalse absoluutväärtusega:

(26)

skaleeritud väärtus _{t} =

$$\frac{\text{leitud väärtus}_t}{\text{MAX}(\text{MAX}(3.\text{punktis leitud väärtused});\text{ABS}(\text{MIN}(3.\text{punktis leitud väärtused}))} .$$

Sellisel viisil genereeritud aegread omavad endas võimalikke väärtusi vahemikus -1-st 1-ni ning sobivad modelleerimiseks tehislake närvivõrkudega.

Andmetöötluses viimase parameetrina tuleb modelleerimiseks süsteemile defineerida väljundmuutuja. Võimaliku parima lahenduse otsimiseks genereeritakse oma olemuselt kaks erinevat tüüpi väljundmuutujad: signaalmuutuja ning järgneva perioodi hinda väljendav muutuja. Esimesel puhul genereeriti väljundmuutujaks muutuja, mis kannab endas „Müü“, „Hoiu“ või „Osta“ signaali. Signaalid defineeriti järgnevalt:

- „Müü“ – kui vaadeldavale nädalale järgneb kauplemisspäev, mille lõpus sulgemishind on rohkem langenud kui koguperioodi aktsia hinna standardhälbe piires, siis antakse „Müü“ signaal.
- „Hoiu“ – „Hoiu“ signaal on nädalal, kui järgneval nädalal aktsia sulgemishind jääb aktsia hinna kõikumise koguperioodi standardhälbe piiridesse.
- „Osta“ – „Osta“ signaal on nädalal, kui vaadeldavale nädalale järgneb kauplemisspäev, mille aktsia hind tõuseb rohkem kui koguperioodi aktsia hinna standardhälve.

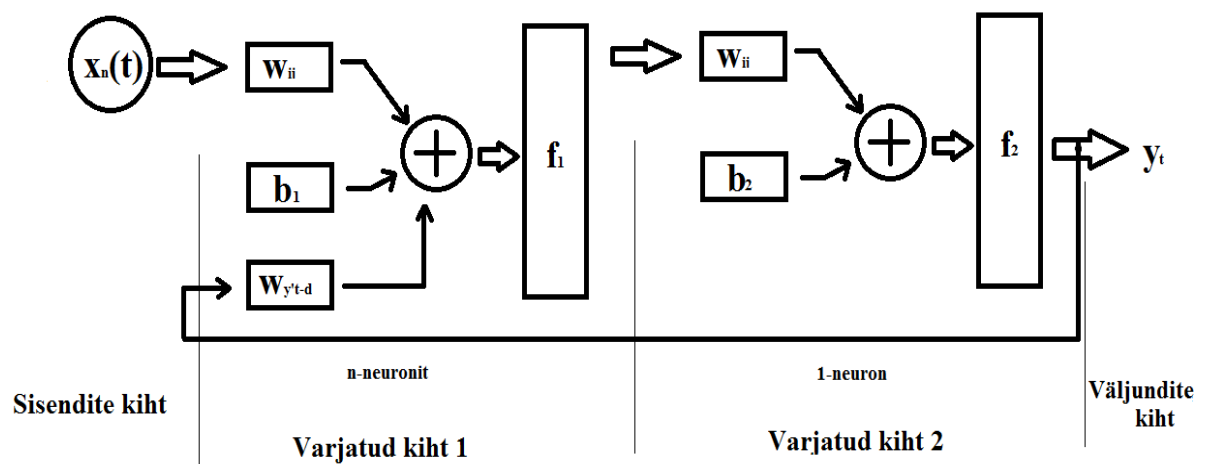
„Müü“, „Hoia“ või „Osta“ signaalidele anti väärtused -1-st 1-ni, ehk siis vastavalt „Müü“ signaalile -1, „Hoia“ signaalile 0 ning „Osta“ signaalile väärtus 1. Andes signaalidele numbrilised väärtused on võimalik närvivõrgul kohandada end vastavalt signaalidele.

Teisel puhul loodi väljundmuutuja, mis kujutab endas perioodile järgneva perioodi aktsia sulgemishinda. Seega antud puhul antakse närvivõrgule ülesanne, mitte ennustada kauplemistehingu signaali perioodil vaid ennustatakse hoopis järgneva perioodi aktsia sulgemishinda. Aegrida genereeriti kui kopeeriti sisendmuutujana leitud aktsia sulgemishinna skaleeritud väärtused ning liigutati seda aegrida ühe perioodi võrra ajas tagasi. Antud võtte küll vähendab valimimahtu ühe ajasammu võrra, kuid oma olemuselt ei oma võrgu treenimisele ja tulemustele olulist rolli, kuna valimisse jääb siiski 537 nädalat.

2.2. Parima närvivõrgu leidmine

Teoreetilises osas sai märgitud, et antud tüüpi probleemi jaoks on otstarbekas kasutada NARX arhitektuuriga närvivõrku. Võrgu treenimiseks ning testimises kasutati MatLab R2011b tarkvara. Selleks, et närvivõrkudega käsitletava tarkvaraga töödelda tuleb andmed esitada programmile sellisel viisil, et tulpades jookseb aeg ning ridades erinevad muutujad. Seetõttu tuli andmed transponeerida vastavale kujule. Kokku loodi kaks andmebaasi modelleerimiseks. Esimesel puhul kasutati andmebaasi 14 valitud sisendmuutujaga 538 nädala lõikes ning väljundmuutujaks määrati kauplemissignaali väljendav muutuja. Teisel puhul oli andmebaasis 14 valitud sisendmuutujat 537 nädala lõikes (valim vähenes perioodi lõpust ühe nädala võrra) ning väljundmuutujaks määrati aegreas perioodile järgneva perioodi (antud juhul nädala) aktsia skaleeritud sulgemishind.

Koostatud NARX närvivõrkude arhitektuur sai loodud varasemalt käsitletud teooria baasil ning katse-eksituse meetodil. Siinjuures tuuakse välja närvivõrgu lähtearhitektuur, mida kasutati esialgse hinnangu saamiseks. Selguse huvides esitatakse veelkord järgmisel leheküljel joonisel 4 kasutatava närvivõrgu baasstruktuur.



Joonis 4. NARX närvivõrgu baasstruktuur (MathWorks 2012).

NARX tüüpi närvivõrgul on võimalik kasutada viitaegu nii sisendmuutujate kui ka närvivõrgu poolt genereeritud väljundmuutujatele. Siin tuleb tähele panna, et väljundmuutuja puhul saab tegemist olla ainult viitaegadega, sest vastasel juhul läheb võrgu treenimisalgoritm tsirkulatsiooni. Võrgu treenimiste puhul ei rakendata sisendmuutujate suhtes viitaegu ning võrgu poolt eelnevaks perioodiks genereeritud väljundmuutujate viitaegade puhul kasutatakse kahte viitaega. Siinjuures võib teha ka eelduse, et eelnevateks perioodideks genereeritud väljundmuutujad sisaldavad endas informatsiooni eelnevate perioodide sisendmuutujate kohta.

Võrgu treenimisfunktsioonina kasutatakse Levenberg-Marquardt'i optimeerimisfunktsiooni, mis on enamikul juhtudel alati rakendatav ning kiireim viis parima võrgu treenimisel. Kaalude kohandamisfunktsioonina kasutatakse *Gradient descent with momentum weight and bias learning function*'t, antud funktsiooni väljundiks on kaalude muutuste või funktsioonide kallakute muutuste maatriks, mis treeningprotsessi käigus uuesti närvivõrku sisestatakse. Treeningprotsessis kasutatakse võrgus endale hinnangu andmiseks vigade ruutude keskväärtust (*mean of squared errors*). Võrgu loomisel kasutatakse kahte varjatud kihti. Esimesse varjatud kihti määratakse võrkude treenimisprotsessi algfaasis nelja neuronit ning NARX närvivõrgu puhul on teises varjatud kihis alati 1 neuron, mis eelnevast varjatud kihist saadava informatsiooni kokku võtab. Treeningprotsessi lähtepunktis rakendatakse aktiveerimisfunktsioonidena mõlemas kihis hüperboolse tangensi (tanh) aktiveerimisfunktsiooni, kuna see on

üldjuhul õpiprotsessina kiirem ning tulemused ei erine märkimisväärsel määral lineaarsest aktiveerimisfunktsioonist. Logistilist aktiveerimisfunktsiooni ei kasutata, kuna andmed varieeruvad vahemikus -1-st 1-ni.

Kõikidele (v.a. üks erand, mida käsitletakse hiljem) närvivõrkudele rakendati järgmised treenimisparameetreid (treenimisprotsess lõppeb, kui üks parameetritest täitub):


- Iteratsioonide arv: 2000,
- Treeningaeg: 600 sekundit,
- Minimaalne ruumivektori kallak: $1e^{-10}$,
- Maksimaalne järjestikku paranemata iteratsioonide arv: 1000.

Erinevate närvivõrkude esmaseks analüüsiks ning võrdluseks kasutatakse närvivõrgu poolt genereeritud väljundväärtuste ning tegelike väärtuste vahet. Antud vahet võib hinnata kui viga, mil määral närvivõrk teatud perioodil t eksib tegeliku väärtuse suhtes. Leitud vigade absoluutväärtuste keskväärtuseid ning vigade standardhälvet võrreldes erinevate närvivõrkude vahel on võimalik anda järeldusi, kui edukalt loodud närvivõrk toimib. Võib eeldada, et mida väiksem on vigade keskväärtus ja vigade standardhälve närvivõrgul, seda edukamalt närvivõrk toimib.

Seadnud paika närvivõrgu treenimise algseaded ning nende võrdlemise põhimõtted on võimalik alustada närvivõrkude treenimiste protsessi. Esmaselt alustati 538 nädala pikkuse valimiga treenimaks närvivõrku, mis suudaks hinnata perioodil kauplemissignaali järgneva perioodi suhtes. Antud eeldustel genereeritud närvivõrgu veaparameetrid on järgnevad:

- Vigade keskväärtus: 0,2831,
- Standardhälve: 0,3939.

Siia juurde tasub vaadata veel järgmisel leheküljel paiknevat genereeritud väljundite vigade histogrammi (joonis 5).



Joonis 5. Kauplemissignaali ennustava närvivõrgu vigade histogramm (autori koostatud).


Joonisel 5 on võimalik näha, et vead ei jaotu just normaaljaotuse järgi nagu seda võiks eeldada hästi toimiva närvivõrgu puhul. Antud juhul on võimalik käesolev vigade jaotus võib olla tingitud ka väljundsignaali karakteristikutest. Teada oli, et antud juhul signaalmuutuja, mida närvivõrgul lasti ennustada, omas kolme erinevat väärtust: -1, 0 ja 1. Sellest tulenevalt tasub leitud veamäärade taustal vaadata ka närvivõrgu poolt genereeritud väljundmuutujaid. Selgus, et genereeritud andmerida omandas mitte täisarvulisi väärtusi -1-st 1-ni ning ei saavutanud kordagi piirväärtusi. Ümardades genereeritud aegrea väärtused esimese täisarvulise väärtuseni, et seeläbi võimalik signaal kätte saada on väljundiks 538-st võimalikust signalist 536 0-id ning ülejäänud kaks väärtusega 1. Tegelikuses oli andmearas 61 „Osta“ (väärtusega 1), 408 „Hoia“ (väärtusega 0) ja 69 „Müü“ (väärtusega -1) signaali. Siinjuures ei tasu vahetada ka aktiveerimisfunktsiooni lineaarsele kujule või leida paremat lahendust erinevate neuronite arvu näol, kuna antud muudatused ei omaks oma sisult piisavalt suurt parendusefekti. Siit võib teha järelduse, et antud meetodika ei sobi väljundsignaali leidmiseks.

Paremate tulemuste otsingul närvivõrgu meetodika rakendamisel liiguti võtte juurde, kus NARX tüüpi närvivõrgul lasti ennustada järgneva perioodi hinda skaleeritud kujul. Antud võtte korral oli valimis 14 erinevat sisendmuutujat 537 erineval järjestikusel perioodil, milledele vastasid järgneva perioodi aktsia sulgemishind. Treeningprotsessi

algseaded olid samad, mis eelneva variandi puhul, ehk kahe varjatud kihiga (esimeses kihis 4 neuronit) närvivõrk. Väljundsignaali tagasisaatmisel kasutatakse kahte viitaega ning rakendatakse hüperboolse tangensi aktiveerimisfunktsioone. Treeningparameetrid on samuti samad, mis eelneva variandi puhul. Saadud närvivõrgu vea karakteristikud on järgnevad:

- Vigade keskvärtus: 0,0860,
- Standardhälve: 0,0740.

Toodud karakteristikutest võib järeldada, et antud närvivõrk toimib oluliselt paremini kui kauplemissignaali ennustav närvivõrk. Siinjuures on teada, et närvivõrk ennustab numbrilisi väärtusi -1-st 1-ni ning tegelikud väärtused omavad samuti väärtusi -1-st 1-ni. Seetõttu võib arvata, et närvivõrgu poolt genereeritud väärtused ei hälbi niivõrd olulisel määral tegelikest väärtustest. Joonisel 6 on kajastatud treenitud närvivõrgu genereeritud väljundmuutujate vigade histogramm.



Joonis 6. Aktsia hinda ennustava nelja neuroniga närvivõrgu vigade histogramm (autori koostatud).

Jooniselt 6 on näha, et treenitud närvivõrgu vead jaotuvad normaaljaotuse järgi, mis tähendab, et närvivõrk eksib võrdses ulatuses mõlemas suunas. Sellest tulenevalt võib eeldada, et treenitud närvivõrk on oma üldpõhimõtelt toimiv.

Parima võrgu otsingul viidi läbi samade treeningandmete rakendamisel järgnevaid treenimisi, kus oli eesmärgiks leida parim neuronite arv varjatud kihis 1. Neuronite arvu kihis varieeriti 2-st 10-ni. Treeningparameetrid jäeti samaks. Samuti viidi iga neuronite arvu puhul läbi kaks erinevat treeningut juhuks, kui teine treenime peaks esimesest oluliselt erineva (närvivõrgud alustavad treeningprotsessi juhuslikust punktist). Tulemused on toodud tabelis 3.

Tabel 3. Erinevate neuronite arvuga närvivõrkude vigade väärtused.

		(vigade keskvärtus; standardhälve)				
Neuronite arv 1. kihis		2	3	4	5	6
Treeningu nr.	1	(0,0970; 0,0864)	(0,0983; 0,0830)	(0,0860; 0,0740)	(0,0995; 0,0814)	(0,1012; 0,0842)
	2	(0,0989; 0,0972)	(0,0993; 0,0879)	(0,0904; 0,0822)	(0,0997; 0,0914)	(0,1034; 0,0953)
Neuronite arv 1. kihis		-	7	8	9	10
Treeningu nr.	1	-	(0,0992; 0,0830)	(0,0938; 0,0766)	(0,0937; 0,0791)	(0,0916; 0,0780)
	2	-	(0,0941; 0,0847)	(0,0998; 0,0846)	(0,0929; 0,0893)	(0,0966; 0,0789)

Allikas: Autori arvutused.


Neuronite arvust 2-10 esimeses varjatud kihis võib järeldada, et antud juhul on parimaks neuronite arvuks esialgselt juhuslikult valitud neuronite arv 4, mille puhul närvivõrk suutis genereerida vähima veaga väljundid (tabelis 3 kajastatud toonitud taustal). Vaatamata leitud lahendustele, tasub uurida kas antud andmete ja probleemi osas süsteem ei nõua hoopis märgatavalt suuremat neuronite arvu. Selleks viidi läbi treeningprotsess, kus esimesse varjatud kihti määrati 50 neuronit. Kasutati samuti hüperboolseid aktiveerimisfunktsioone, kuid olulise arvutusmahu kasvu tõttu suurendati treeningparameetreid. Rakendatud treeningparameetrid on toodud järgnevalt:

- Iteratsioonide arv: 200000,
- Treeningaeg: 7200 sekundit,
- Minimaalne ruumivektori kallak: $1e^{-20}$,
- Maksimaalne järjestikku paranemata iteratsioonide arv: 100000.

Saadud 50 neuroniga närvivõrgu vea karakteristikud on järgnevad:

- Vigade keskvärtus: 0,1237,
- Standardhälve: 0,0977.

Tulemustest saab välja lugeda, et märkimisväärne neuronite arvu suurendamine ei paranda närvivõrgu prognoosivõimet. Siia juurde tasub vaadata ka närvivõrgu poolt genereeritud väljundite vigade histogrammi joonisel 7.



Joonis 7. Aktsia hinda ennustava 50-e neuroniga närvivõrgu vigade histogramm (autori koostatud).

Jooniselt 7 on näha, et tegemist ei ole ka parima normaaljoatusega. Antud juhul on näha, et 50-e neuroniga närvivõrgu vigade jaotus on vasakule poole kaldu, ehk ühes suunas eksimusi tehakse rohkem. Siinjuures on tõenäoliselt tegemist ülekohandamise probleemiga. Saadud tulemuste põhjal võib järeldada, et suure tõenäosusega on antud probleemi lahendamiseks närvivõrk, kus esimeses varjatud kihis on neli neuronit. Siinjuures tasub testida, kas teises varjatud kihis lineaarne aktiveerimisfunktsioon suudab närvivõrku paremini prognoosida panna. Selleks viidi läbi võrgu treenimised esimeses varjatud nelja neuroniga hüperboolse tangens aktiveerimisfunktsiooni ning teises kihis rakendatava lineaarse aktiveerimis-funktsiooniga. Siinjuures tasub märkida, et esimeses varjatud kihis neuronite aktiveerimis-funktsiooni kuju muutmine ei oma


endas arvestatavat efekti, kuna selle mõju on MLP tüüpi närvivõrgu puhul antud võrguarhitektuuris teoreetiliselt märkamatu. Närvivõrgu treeningparameetritena rakendati samasid väärtusi, mis eelnevate 4 neuroniga närvivõrkude puhul. Läbiviidud võrgutreenimiste vigade tulemused on toodud tabelis 4.

Tabel 4. Teises varjatud kihis lineaarse aktiveerimisfunktsiooniga närvivõrgu keskväärtuste ja standardhälvete väärtused.

		(vigade keskväärtus; standardhälve)
Neuronite arv 1. kihis		4
Treeningu nr.	1	(0,0993; 0,0859)
	2	(0,0986; 0,0863)
	3	(0,0974; 0,0882)

Allikas: Autori arvutused.

Siia juurde kuvatakse joonisel 8 parima lineaarse aktiveerimisfunktsiooniga närvivõrgu (toonitud taustal) genereeritud väljundite vigade histogramm.



Joonis 8. Parima lineaarse aktiveerimisfunktsiooniga närvivõrgu vigade histogramm (autori koostatud).

Jooniselt 8 on näha, et antud juhul on vigade jaotus samuti vasakule kaldu sarnaselt 50 neuroniga närvivõrgule. Tabelist 4 kuvatud lineaarse aktiveerimisfunktsiooniga

närvivõrgu keskväärtuste ning standardhälvete väärtuste ja vigade histogrammide võrdluses hüperboolse tangensi aktiveerimisfunktsiooniga närvivõrguga on võimalik teha järeldus, et käsitletavat problemaatikat suudab paremini kirjeldada hüperboolse tangensiga närvivõrk. Järgnevalt treeniti närvivõrke parima lahendi otsimiseks, kus võrgu poolt genereeritavate väljundite ning viitajana sisendina uuesti võrku saadetavate väljundmuutujate viitaegade arvu suurendati. Siinjuures tehakse eeldus, et eelnevate perioodide väljundmuutujad sisaldavad endas informatsiooni eelnevate perioodide sisendmuutujate suhtes, ning seega sisendmuutujatele viitaegu ei lisata (rakendatakse sama perioodi väärtusi). Treenitud varieeritud viitaegade arvuga närvivõrkude lahendid on toodud tabelis 5.

Tabel 5. Erineva väljundmuutuja viitaegadega närvivõrkude võrdlus

		(vigade keskväärtus; standardhälve)
Neuronite arv 1. kihis		4
Viitaegade arv.	1	(0,0956; 0,0795)
	2	(0,0860; 0,0740)
	3	(0,0928; 0,0762)
	4	(0,3198; 0,2114)

Allikas: Autori arvutused.

Tabelist 5 võib näha, et väikseimat eksimust omab antud uuritav närvivõrgu süsteem võrrandisse tagasi saadetavate sisenditena kahe viitajaga genereeritud väljundmuutuja mudeli puhul (toonitud taustal). Veamääradest saab välja lugeda, et oluliselt langeb närvivõrgu prognoosivõime alates neljast viitajast. Ühtlasi selgub, et käsitletava probleemi lahendiks on tõenäoliselt parim närvivõrk, mis sisaldab varjatud kihtides hüperboolse tangensi aktiveerimisfunktsioone, esimeses varjatud kihis nelja neuronit ning võrku tagasi saadetava närvivõrgu poolt genereeritud väljundmuutujate kahte viitaega. Seega probleemi parimaks lahendiks on algselt välja pakutud süsteemikuju. Küll tuli siinjuures testida, kas antud süsteemiga närvivõrk võib omandada parema struktuuri kaalude näol. Kuna närvivõrgu treenimisprotsessi alustatakse alati uuest juhuslikust punktist ning võimalike lahendite hulgast ei ole võib-olla jõutud parima lahendini, siis tasub treenida esialgselt treenitud närvivõrgule samadel alustel uusi

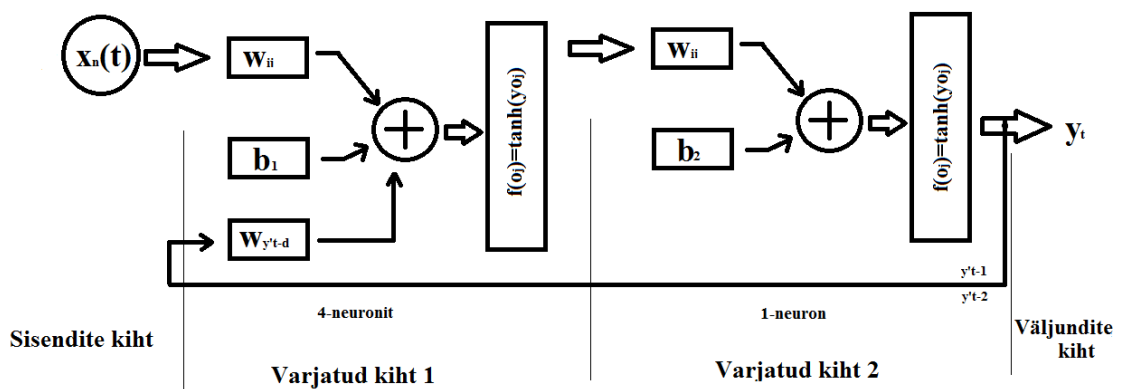
närvivõrke. Kajastatava arhitektuuriga närvivõrgu lahendite vigade karakteristikud on toodud tabelis 6.

Tabel 6. Esimeses varjatud kihis 4 neuroniga kahe väljundmuutuja viitajaga närvivõrkude veakarakteristud.

		(vigade keskväärtus; standardhälve)
Neuronite arv 1. kihis		4
Treeningu nr.	1	(0,0860; 0,0740)
	2	(0,0984; 0,0822)
	3	(0,0943; 0,0836)
	4	(0,0946; 0,0800)
	5	(0,0977; 0,0843)

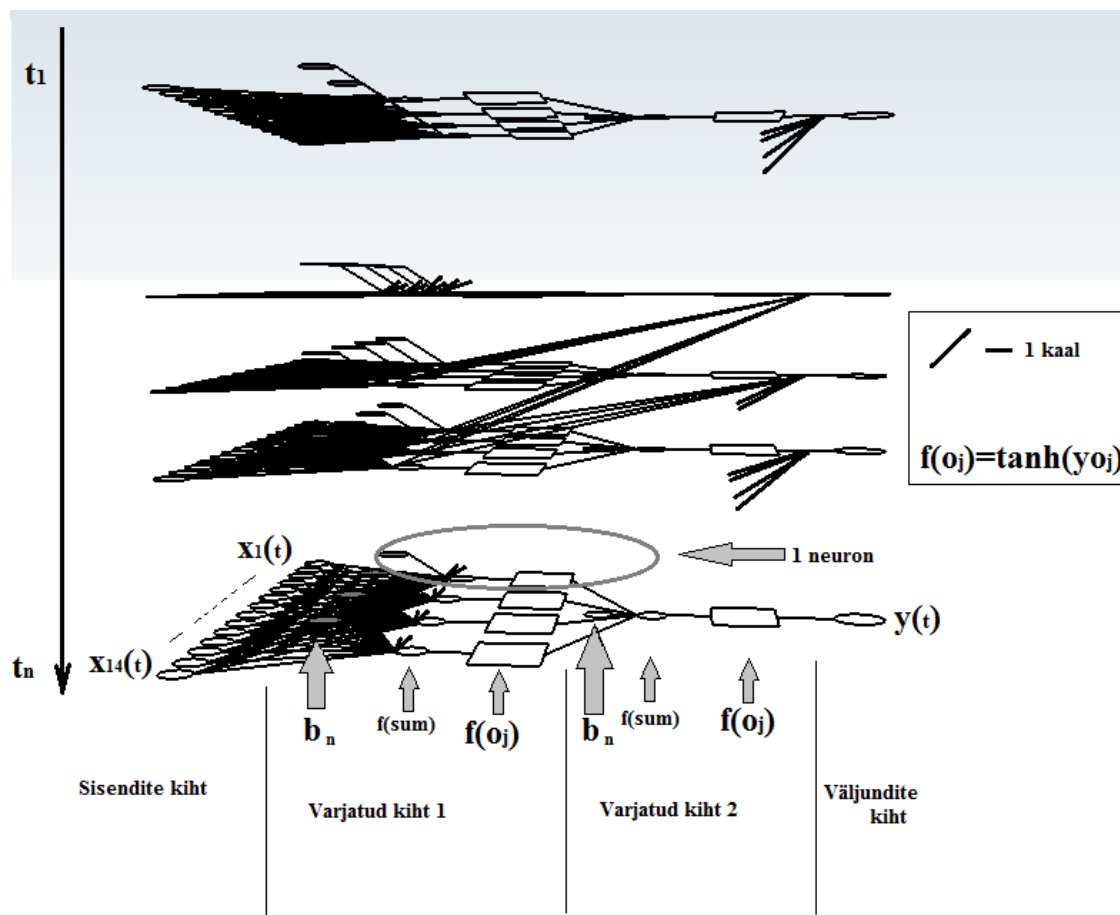
Allikas: Autori arvutused.

Tabelist 6 on välja loetav, et parima närvivõrguni jõuti kohe esimesel katsel (toonitud taustal). Antud töö raames koguni katsel, mil esmakordselt lasti närvivõrgul prognoosida järgneva perioodi aktsia sulgemishinda. Järgneval joonisel 9 on esitatud parima leitud arhitektuuriga närvivõrgu struktuur.



Joonis 9. Parima leitud arhitektuuriga närvivõrk (autori koostatud).

Joonisel 10 esitatakse parima treenitud närvivõrgu arhitektuuriline täpne ülesehitus paremaks mõistmiseks kolmemõõtmelises ruumis. Joonis 10 on koostatud tarkvara Google SchetchUp 8.0 tarkvara kasutades.




Joonis 10. Parima leitud arhitektuuriga närvivõrk kolmemõõtmelises ruumis (autori koostatud).

Jooniselt 10 on näha, kuidas koostatud närvivõrgus funktsioonid ja infoliikumine on omavahel kaalude abil ühendatud erinevate ajaliste dimensioonide vahel. Erinevad närvivõrgu mudelkihid joonisel 10 tähistavad erinevaid ajahetki aegreas. Iga närvivõrgu tase (t_n) mudelis on omavahel ühendatud kahe eelneva taseme väljundsignaali muutujaga, mis sisestatakse konkreetsesse tasemesse sisenditena esimese varjatud kihi nelja neuronisse. Üks esimese varjatud kihi neuron võtab seega endasse informatsiooni 14-st sisendmuutujast, kahe viitajaga võrgu poolt genereeritud väljundmuutujast ning funktsiooni kallaku määravast sisendist b_n (kokku 17 sisendit). Seejärel neuroni summeerib sisenditelt saadud väärtused, mis on juba vastavalt kaalutud, ning sisestab aktiveerimisfunktsiooni, mis genereerib vastava väärtuse. Informatsioon närvivõrgu taseme kihis liigub joonisel vasakult paremale. Esimesest varjatud kihist pärinev informatsioon võetakse kokku teises varjatud kihis ning väljastatakse ühtse

informatsioonina, antud juhul prognoositava hinna skaleeritud väärtusena. Kuna antud närvivõrgu arhitektuur on erinevate närvivõrgu lahendite hulgast parima lahend, siis keskendutakse antud närvivõrgule edaspidi põhjalikumalt. Närvivõrgu poolt prognoositud tulemuste analüüsil ning rakendatavusel peatutakse järgnevas alapunktis.

2.3. Parima treenitud närvivõrgu tulemused


Eelnevas alapunktis sai leitud võimalike närvivõrgu lahendite hulgast parima arhitektuuriga närvivõrk. Käesolevas alapunktis uuritakse, kui häid tulemusi leitud võrgustruktuur suudab genereerida ning kas ja mil viisil on need praktikas rakendatavad. Esialgse ülevaate saamiseks kujutatakse järgmisel leheküljel joonisel 11 võrgu poolt genereeritud väärtusi ning tegelikke väärtusi aegrida käsitleval perioodil. Siinjuures tuleb tähele panna, et tegemist on skaleeritud väärtustega.



Joonis 11. Närvivõrgu poolt genereeritud väärtused võrdluses tegelike skaleeritud väärtustega (autori koostatud).

Kuigi joonisel 11 on tegemist skaleeritud väärtustega, siis võib juba joonise põhjal teha järelduse, et närvivõrk suudab vähemalt valdavas osas aimata aktsia hinna liikumise suunda. Siinjuures võib näha, et närvivõrgu poolt leitud väärtused ei suuda tabada

languste ning tippude maksimumpunkte, selle põhjuseks on närvivõrgu omadus, mille tõttu nad kipuvad andmeid siluma. Täpsemaks analüüsiks viiakse närvivõrgu poolt genereeritud väljundväärtused samasse suurusjärku tegelike aktsia hinna väärtustega. Selleks teostakse vastandsuunaline arvutusprotsess alapunktis 2.1. kajastatud aktsia hinna skaleerimiseks teostatud protsessile. Olles viidud närvivõrgu poolt genereeritud hinnad tegelikkusega võrreldavale kujule saab neid võrrelda tegelike hindadega. Joonisel 12 on kujutatud närvivõrgu poolt genereeritud hinnad võrrelduna tegelike hindadega.




Joonis 12. Närvivõrgu poolt prognoositud hind võrdluses tegeliku hinnaga, USD (autori koostatud).

Kuigi jooniselt 12 on samuti näha, et närvivõrk ei suuda täielikult tabada aktsia hinnaliikumist liigub ta siiski samas suunas tegeliku väärtusega. Järgnevalt on välja toodud närvivõrgu poolt prognoositud väärtuste keskmine viga ning vea standardhälve tegelike hindade suhtes:

- Keskmine viga: 0,96 USD,
- Vea standardhälve: 0,83 USD.

Joonisel 13 on kujutatud tegelike hinnavigade histogramm analüüsivaks tegelike prognoosivigade normaaljaotust.




Joonis 13. Tegelike närvivõrgu prognoosivigade histogramm (autori koostatud).

Jooniselt 13 on näha, et vead jaotuvad normaaljaotuse järgi. Sellest tulenevalt pole põhjust järeldada, et treenitud närvivõrgu tulemused võiksid milleski suunas kallutatud olla. Siiski võib antud veakarakteristikuid vaadeldes väita, et närvivõrgu poolt pakutav informatsioon liiga ebatäpne, et antud informatsiooni alusel investeerimisotsuseid sooritada. Küll võis aga joonistelt 11 ja 12 tähele panna, et loodud närvivõrk on võimeline ära tabama hinnaliikumiste suundi, sellest tulenevalt genereeritakse närvivõrgu poolt prognoositud hindade põhjal signaalid. Signaalid koostatakse samadel alustel nagu alapunktis 2.1., ehk siis: „Müü“, „Hoiu“ ning „Osta“ signaal. Siinkohal:

- „Müü“ – kui vaadeldavale nädalale järgneb kauplemisnädal, mille lõpus sulgemishind on rohkem langenud kui koguperioodi prognoositud aktsia hinna standardhälbe piires, siis antakse „Müü“ signaal.
- „Hoiu“ – „Hoiu“ signaal on nädalal, kui järgneval nädalal prognoositud aktsia sulgemishind jääb prognoositud aktsia hinna kõikumise koguperioodi standardhälbe piiridesse.

- „Osta“ – „Osta“ signaal on nädalal, kui vaadeldavale nädalale järgneb kauplemisnädal, mille prognoositud aktsia hind tõuseb rohkem kui koguperioodi prognoositud aktsia hindade standardhälve.

Vajab märkimist, et närvivõrgu poolt prognoositud aktsiahinna muutuse standardhälve järgneva perioodi suhtes oli 0,02 ning tegeliku aktsiahinna muutuse standardhälve järgneva perioodi suhtes 0,03. Siin tuleb välja närvivõrgu omadus aeGRIDade silumise näol. Eriti kipuvad aeGRIDu siluma ülekohandatud närvivõrgud. Eelnevas alapunktis sai aga leitud, et antud juhul on hetkel kasutatav närvivõrk parim lahendus käsitletavale probleemile. Siinjuures võib vaadelda leitud närvivõrgu kaalude normaaljaotust, mis viitaks närvivõrgu üle- või alakohandatusele. Joonisel 14 on toodud loodud närvivõrgu sisendelementide kaalude histogramm.



Joonis 14. Närvivõrgu sisendelementide kaalude histogramm (autori koostatud).

Histogrammilt on näha, et kaalud ei jaotu küll ideaalselt normaaljaotuse järgi, kuid viitavad sellele. Sellest võib järeldada, et tegemist ei ole antud juhul parima närvivõrgu lahendusega probleemile, kuid tegemist on varasemate testide põhjal siiski parima lahendusega lahenduste hulgast. Võrreldes treenitud võrku Kulkarni (1996) poolt treenitud võrguga, mille eesmärk oli prognoosida S&P 500 indeksi väärtust siis tulemused on siiski küllaltki sarnased. Indeksit prognoosiv võrk pandi ennustama kahel erineval perioodil, millest esimesel puhul oli keskmine protsentuaalne viga 0,95% ning

maksimaalne viga 4,04%. Teisel puhul oli aga võrgu prognoosiviga 4,18% ning maksimaalne viga 13,17%. Käesolevas töös käsitletava aktsia hinda prognoosiva närvivõrgu keskmine ennustusviga (käsitleti ühe järjepideva perioodina) protsentuaalselt oli 1,85% ning maksimaalne viga 10,67%. Tulemused võrdluses Kulkarni testidega ei ole küll halvad, aga ei ole välistatud, et eksisteerib paremaid närvivõrke probleemi lahendamiseks. Joonisel 14 asuv histogramm viitabki sellele, et närvivõrk ei toimi täielikult hästi.

Tulles tagasi signaalväärtuste genereerimise ning võrdlemise juurde võib genereeritud närvivõrgu vastused jagada kolme rühma: õiged signaalid, kerge eksimus ning tugev eksimus. Hinnang „Õige signaal“ anti närvivõrgule, kui ta prognoosis täpselt sama signaali, mida ka tegelikkuses tuli ennustada. Hinnang „Kerge eksimus“ anti närvivõrgu signaalile kui see eksis ühe signaali kalde võrra, ehk siis ta ei prognoosinud „Müü“ signaali asemel „Osta“ signaali või vastupidi. „Tugev viga“ anti hinnanguks signaalile, kui närvivõrk prognoosis „Müü“ signaali asemel „Osta“ signaali või vastupidi. Tabelis 6 on kujutatud närvivõrgu hindade põhjal genereeritud kauplemissignaali väärtused võrrelduna tegelikult nõutavate signaalidega.

Tabel 7. Närvivõrgu prognoositud hindade põhjal genereeritud kauplemissignaali võrdlus tegelikkuses nõutavate signaalidega.

	Osakaal	Arv
Õige signaal	60,63%	325
Kerge eksimus	36,57%	196
Tugev eksimus	2,80%	15

Allikas: Autori koostatud.

Tabelist 7 võib välja lugeda, et närvivõrgu prognoositud hindade põhjal genereeritud kauplemissignaalid suudavad siiski ligi 2/3 kordadest ära tabada õige signaali ning alla 3% genereeritavatest signaalidest on vaid hinnanguga „Tugev eksimus“. Antud tulemuste põhjal võib väita, et genereeritud närvivõrk oma olemuselt on üldjoontes võimeline hindama tulevikus toimuvaid aktsia hinnamuutusi. Käesoleva töö tulemust võib pidada ka varasemalt läbiviidud närvivõrkude poolt prognoositud aegridade võrdluses küllaltki heaks tulemuseks. Üldjärelalusena võib väita, et töös kasutatud töövõtteid järgides on võimalik koostada tehnilikku närvivõrku aktsia hinna liikumise

prognoosimiseks ning antud närvivõrgu väljundit kasutada kui ühte argumenti investeerimisotsuse langetamisel. Küll ei saa antud hetkel aga väita, et investorid võiksid antud närvivõrgu süsteemi abil langetada investeerimisotsuseid vaid sellest süsteemist pärineva informatsiooni alusel.

Antud töös väljatöötatud närvivõrku on võimalik rakendada Wal-Marti aktsia nädalase sulgemishinna liikumise prognoosimisel. Siinjuures tuleb veelkord panna tähele, et vaid antud närvivõrgust pärineva informatsiooni alusel ei ole otstarbekas langetada investeerimisotsuseid. Väljuvat signaali saab kasutada pigem ühe vihjena võimaliku aktsiahinna liikumise kohta. Närvivõrgu rakendamiseks tuleb nädala lõpus sisestada andmebaasi uued jooksvad sisendmuutujad (skaleeritud kujul) ning seeläbi lasta närvivõrgul ennustada prognoositav aktsia väärtus järgmiseks nädalaks. Närvivõrgu poolt genereeritud väärtus tuleb seejärel skaleerida üles genereerimaks selle põhjal soovituslik kauplemissignaali järgmise perioodi suhtes. Otstarbekas on treenida koostatud närvivõrk teatud mõistliku aja tagant uuesti üle (seda võib teha ka iga nädal). Sellisel juhul võib olla kindlam, et närvivõrk arvestab turu osaliste käitumismudelitega, mitte ei käitu vanade standardite järgi.

Parema prognoosivõimega närvivõrkude leidmiseks tuleks antud temaatikaga seonduvat uurimustegevust edaspidi jätkata ning leida võtteid, kuidas närvivõrgu toimimist parandada. Edaspidises uurimistöös tuleks võimalusel leida paremad sisendparameetrid, mis suudaksid närvivõrgu kirjeldamisvõimet tõsta. Siinjuures tuleb otsida ka paremat võrguarhitektuuri ning paremaid võrrandeid närvivõrgu siseehituses antud probleemi suhtes.

KOKKUVÕTE

Käesoleva magistritööga jõuti tulemusele, mille põhjal võib väita, et tehniliku närvivõrgu meetodikat kasutades on võimalik jõuda mudelini, mille alusel saab hinnata aktsia hinna tulevast liikumist. Konkreetse töös käsitletud näite puhul tuleb selleks luua NARX paralleelse arhitektuuriga närvivõrk. Leidnud parima arhitektuurse eeldusega närvivõrgu testiti närvivõrgu tulemuslikkust erinevate närvivõrgu siseste arhitektuursete nüansside täpsustamiseks. Kokku trenniti 32 erinevat närvivõrku parima tulemuse leidmiseks.

Töös seati eesmärgiks hinnata aktsia hinna liikumist kahe erineva põhimõtte alusel, sellest esimese variandi puhul lasti trennitaval närvivõrgul prognoosida kauplemissignaale järgneva perioodi suhtes ning teise variandi puhul hinnata aktsia sulgemishinda järgneval perioodil. Katsete tulemusena selgus, et oluliselt paremini toimib variant, kus närvivõrk hindab aktsia hinda järgneval perioodil.

Viidi läbi mitmeid katseid samadel treeningpõhimõtetel ning leiti, et parima prognoosivõimega närvivõrk käsitletava probleemi ning andmete taustal omab endas kahte varjatud kihti, mille puhul esimeses varjatud kihis on 4 neuronit. Varjatud kihtide neuronite aktiveerimisfunktsioonidena kasutatakse hüperboolse tangensi aktiveerimisfunktsioone ning sisendina kahe viitajaga võrgu poolt genereeritud väljundit. Antud eeldustel koostatud närvivõrk on võimeline prognoosima ettevõtte aktsia liikumist täpsusega 1,85%.

Lasknud hinnata närvivõrgul järgmise perioodi aktsia sulgemishinda tuletati võrgu poolt ennustatud hindade põhjal kauplemissignaalid tehingute sooritamiseks. Genereeritud signaalid jaotusid kolmeks: „Müü“, „Hoia“ ja „Osta“ signaaliks. Antud signaale võrreldi tegelikkuses vaja minevate signaalidega. Võrgu poolt ennustatud hindade põhjal tuletatud signaalid osutusid 60,63%- täielikult täpseks. Kerge viga ennustuses oli,

kui võrk eksis signaali ennustamise suhtes ühe hälbe võrra, ehk ta ei ennustanud vastupidist kauplemissignaali. Antud vigade osakaal koguennustuste suhtes oli 36,57%. Rangelt valed signaalid moodustasid tulemustest vaid 2,8%.

Võib väita, et koostatud närvivõrk on võimeline hindama aktsia hinna tulevast liikumist, kuid antud signaali ei saa võtta ainsa otsustuskriteeriumina edukate investeerimisotsuste langetamiseks. Pigem tuleks antud närvivõrgu põhjal saadavat informatsiooni kasutada sümbioosis teiste informatsiooniallikatega. Parema prognoosivõimega närvivõrgu saavutamiseks tuleks uurimistööd jätkata.

Edaspidises töös tasuks kaaluda teiste sisendmuutujate kasutamist või lisamist, mis võiksid paremini kirjeldada aktsia hinna liikumisi. Siinjuures tuleks jätkata uurimustööd närvivõrgu matemaatilise arhitektuuri loomisel, seda nii üldkuju kui võrgu sisemiste funktsioonide kuju seisukohast lähtuvalt. Potentsiaalsed eeldused parema lahenduseni jõudmisel on olemas.

Antud töös kajastatud meetodikate puhul tõestati ära, et tehnilike närvivõrkude meetodikat on võimalik rakendada ettevõtte aktsia hinna liikumiste prognoosimisel. Närvivõrgu väljundite põhjal genereeritud rangelt valede kauplemissignaali osakaal oli küll vaid 2,8%, kuid ei ole välistatud et eksisteerib veel paremaid lahendusi probleemile. Sellest tulenevalt tuleks uurimistööd antud valdkonnas tulevikus jätkata.

VIIDATUD ALLIKAD

1. **Abarbanell, J. S., Bushee, B. J.** Abnormal Returns to a Fundamental Analysis Strategy. – *The Accounting Review*, Jan. 1998, Vol. 73, No. 1, pp. 19-45.
2. **Abhyankar, A., Copeland, L. S., Wong, W.** Uncovering Nonlinear Structure In Real-Time Stock-Market Indexes: The S&P 500, the DAX, the Nikkei 225, and the FTSE-100. – *Journal of Business & Economic Statistics*, 1997, Vol. 15, No. 1, pp. 1-14.
3. **Alexander, G. J., Sharpe, W. F.** *Fundamentals of Investments*. Englewood Cliffs: Prentice Hall, 1989, 678 p.
4. **Angeloni, I., Kashyap, A. K., Mojon, B., Terlizzese, D.** The Output Composition Puzzle: A Difference in the Monetary Transmission Mechanism in the Euro Area and United States. - Ohio State University Press, *Journal of Money, Credit and Banking*, 2003, Vol. 35, No. 6, Part 2: Recent Developments in Monetary Economics, pp. 1265-1306.
5. **Baker, M., Wurgler, J.** Investor Sentiment in the Stock Market. – American Economic Association, *The Journal of Economic Perspectives*, Spring 2007, Vol. 21, No. 2, pp. 129-151.
6. **Bennet, E., Selvam.,M., Ebenezer, E. E. S.** The Influence of Stock-Specific Factors on Investors' Sentiment. – *World Journal of Social Sciences*, 2011, Vol. 1, No. 4, pp. 107-116.
7. **Black, F.** Noise. – *The Journal of Finance*, Jul. 1986, Vol. 41, No. 3, pp. 529-543.
8. **Bradshaw, M. T.** How Do Analysts Use Their Earnings Forecasts in Generating Stock Recommendations? – *The Accounting Review*, Jan. 2004, Vol. 79, No. 1, pp. 25-50.

9. **Bragg, S. M.** Business Ratios and Formulas. Hoboken: John Wiley & Sons, 2002, 334 p.
10. **Campbell, J. Y., Polk, C., Vuolteenaho, T.** Growth or Glamour? Fundamentals and Systematic Risk in Stock Returns. – Review of Financial Studies, 2010, Vol. 23, No. 1, pp. 305-344.
11. **Chan, M., Wong, C., Lam, C.** Financial Time Series Forecasting by Neural Network Using Conjugate Gradient Learning Algorithm and Multiple Linear Regression Weight Initialization. The Hong Kong Polytechnic University, Department of Computing, 2000, 6 p.
12. **Dalton, J. M.** How the Stock Market Works. New York: New York Institute of Finance, 1993, 325p.
13. **Fabozzi, F. J., Modigliani, F.** Capital Markets: Institutions and Instruments. New Jersey: Massachusetts Institute of Technology, 1992, 726p.
14. **Fama, E. F.** Efficient Capital Markets: A Review of Theory and Empirical Work. – The Journal of Finance, May 1970, Vol. 25, No. 2, pp. 383-417.
15. **Grossmann, S. J., Stiglitz, J. E.** On the Impossibility of Informationally Efficient Markets. – The American Economic Review, Jun. 1980, Vol. 70, No. 3, pp. 393-408.
16. **Gul, F., Javed, T.** Relationship Between Trading Volume And Stock Exchange Performance: A Case From Karachi Stock Exchange. - International Business & Economics Research Journal, August 2009, Vol. 8, No. 8, pp. 13-19.
17. **Hansen, J. V., Nelson, R. D.** Forecasting and Recombining Time-Series Components by Using Neural Networks. – The Journal of the Operational Research Society, 2003, Vol. 54, No. 3, pp. 307-317.
18. **Hendershott, T., Jones, C. M., Menkveld, A. J.** Does Algorithmic Trading Improve Liquidity? – The Journal of Finance, February 2011, Vol. 66, Issue 1, pp. 1-33.
19. Institute for Supply Management.
[<http://www.ism.ws/ISMReport/content.cfm?ItemNumber=10752>] 22.04.2012.
20. **Jain, P. K.** Financial Market Design and the Equity Premium: Electronic versus Floor Trading. – The Journal of Finance, Dec. 2005, Vol. 60, No. 6, pp. 2955-2985.

21. **Jiang, C., Song, F.** Sunspot Forecasting by Using Chaotic Time-series Analysis and NARX Network. – Journal of Computers, 2011, Vol 6, No. 7, pp. 1424-1429.
22. **Kajitani, Y., Hipel, K. W., Mcleod, A. I.** Forecasting Nonlinear Time Series with Feed-Forward Neural Networks: A Case Study of Canadian Lynx Data. – Journal of Forecasting, March 2005, Vol. 24, Issue 2, pp. 105–117.
23. **Khan, A.** 501 Stock Market Tips and Guidelines. Lincoln: Writers Club Press, 2002, 240p.
24. **Kulkarni, A. S.** Application of Neural Networks to Stock Market Prediction. 1996, pp. 1-18.
25. **Lemmon, M., Portniaguina, E.** Consumer Confidence and Asset Prices: Some Empirical Evidence. Oxford University Press, 2006, pp. 1499-1529.
26. MathWorks. [<http://www.mathworks.se/>] 03.05.2012.
27. **McMillan, D. G.** Stock Market Fundamentals and Bubbles: Implications for Prices, GDP and Consumption. University of Stirling and University of Saint Andrews, 2010, pp. 1-33.
28. **Menezes, J. M. P. Jr, Barreto, G. A.** Long-termtimeseriesprediction with the NARX network: An empirical evaluation. – Neurocomputing, October 2008, Vol. 71, Issues 16–18, pp. 3335–3343.
29. **Naes, R., Skjeltop, J. A., Odegaard, B. A.** Stock Market Liquidity and the Business Cycle. Journal of Finance, 2010, pp. 1-82.
30. **Nissim, D., Ziv, R.** Dividend Changes and Future Profitability. – The Journal of Finance, Dec. 2001, Vol. 56, No. 6, pp. 2111-2133.
31. **Palan, S.** The Efficient Market Hypothesis and Its Validity in Today's Markets. Graz: Karl-Franz University, Institute für industrial Economics. 2004, 80p.
32. **Pape, L., Ruessink, B. G., Wiering, M. A., Turner, I. L.** Recurrent neural network modeling of nearshore sandbar behavior. – Neural Networks, May 2007, Vol. 20, Issue 4, pp. 509–518.
33. **Penman, S. H.** The Articulation of Price-Earnings Ratios and Market-to-Book Ratios and the Evaluation of Growth. – Journal of Accounting Research, Autumn 1996, Vol. 34, No. 2, pp. 235-259.

34. **Pompian, M.** Behavioral Finance and Wealth Management: How to Build Optimal Portfolios That Account for Investor Biases, New Jersey: John Wiley & Sons. 2011, 384p.
35. **Samuel, C.** The Stock Market as a Source of Finance: A Comparison of U.S and Indian Firms. – Policy Research Working Paper, 1996, Issue 1592, pp. 1-43.
36. **Schlichting, T.** Fundamental Analysis, Behavioral Finance and Technical Analysis on the Stock Market: Theoretical Concepts and their Practical Synthesis Capabilities. Leverkusen: Fachhochschule für Oekonomie & Management Essen, 2008, 116p.
37. **Schwager, J. D.** Schwager on Futures: Fundamental Analysis. John Wiley & Sons, 1995, 639 p.
38. **Siegel, J. G., Shim, J. K., Qureshi, A. Brauchler, J.** Encyclopedia of Technical Analysis. Chicago: Glenlake Publishing Company, 2000, 356 p.
39. **Slezak, S. L.** On the Impossibility of Weak-Form Efficient Markets. – The Journal of Financial and Quantitative Analysis, Sep. 2003, Vol. 38, No. 3, pp. 523-554.
40. **Sloan, R. G.** Do Stock Prices Fully Reflect Information in Accruals and Cash Flows about Future Earnings? – The Accounting Review, July 1996, Vol. 71, No. 3, pp. 289-315.
41. **Soman, P. C.** An adaptive NARX neural network approach for financial time series prediction. The State University of New Jersey, Electrical and Computer Engineering, 2008, 111 p. (Master of Science)
42. **Soros, G.** The Alchemy of Finance. Wiley, 2003, 391 p.
43. Stockpup. [<http://www.stockpup.com/data/>] 15.03.2012.
44. **Swingler, K.** Applying Neural Networks: A Practical Guide. Bodmin: MPG Books Ltd, 2001, 303 p.
45. The Conference Board.
[<http://www.conferenceboard.org/data/consumerconfidence.cfm>] 14.03.2012.
46. United States Census Bureau.
[[<http://www.census.gov/econ/currentdata/dbsearch?program=MRTS&startYear=1992&endYear=2012&categories=44X72&dataType=SM&geoLevel=US&adjusted=1¬Adjusted=1&errorData=0>] 22.04.2012.

47. United States Department of Labor.
[<http://www.ows.doleta.gov/unemploy/claims.asp>] 22.04.2012.
48. University of Wisconsin. Dairy Marketing and Risk Management Program.
[http://future.aae.wisc.edu/data/monthly_values/by_area/998?tab=sales]
14.03.2012.
49. Walmart Corporate.
[<http://investors.walmartstores.com/phoenix.zhtml?c=112761&p=irol-irhome>]
14.04.2012.
50. Yahoo! Finance. [<http://finance.yahoo.com/>] 13.03.2012.

SUMMARY

APPLYING ARTIFICIAL NEURAL NETWORKS FOR FORECASTING STOCK PRICE MOVEMENTS

Allar Karu

Forecasting processes of economics have been always fascinating subject to the people of investment world. Knowing the movements of these processes in the future it is possible to make foreseeing decisions towards to these movements. Several mathematical and econometrical models have been developed to predict market and different asset movements. These mathematical and econometrical models has one key disadvantage – they are by their characteristics static and by that characteristic there is always a risk that they do not work at some point effectively any more. During past two decades major improvements have been made in modeling artificial neural networks. According to that applying artificial neural networks to the stock price movement predictions should be considered. Hereby artificial neural networks have many advantages over static mathematical models.

Different theories, what influence stock price value, have been discussed in current working paper to find suitable variables for successful artificial neural network model. Also theoretical background is being presented to compose forecasting neural network model. With combining right variables and right neural network architecture the aim is to build neural network model for predicting stock price movements. By baking a successful neural network model there is strong belief that that methodology could be used to evaluate different stock price movements as well.

To full-fill the goal set following research tasks were set:

- Find key variables, what influence stock price movements,
- explain artificial neural network behavior,
- find suitable neural network according to theoretical background,

Working paper's theoretical part covers problematic which is related to the stock markets and its behavior. Hereby are explained why neural network should be good solution for forecasting stock price movements with taking into account characteristics which are related to the financial markets. Also variables are being presented which influence stock's price. Former results and works are being presented with neural networks like as Kulkarn's (1996) research for predicting S&P 500 index with neural network and Soman's (2008) work for predicting mostly currency exchanges. Hereby both authors made a positive result and former practical experiments have been shown that neural networks even could outperform today widely used econometrical models.

Current work's first half stands on explaining the problems with financial markets forecasting and solutions what neural networks could provide. Second half of this working paper describes what methods and practical steps have been used and made to achieve the desired goal. Also different test results are being presented and the best artificial network architecture is presented to deal with current problem.

Results according to this working paper show that it is possible to build neural network which is possible to predict stock price movements in the future. According to the example of current work and NARX parallel neural network should be built. In total of 32 different tests were made to find best inners structure for NARX parallel network and two different principles were set for neural network for forecasting future price movements. At first neural networks goal was set to predict price movement by signal. Second goal was to let network predict stock's future price. Tests showed that the second approach was far more accurate.

The best neural network architecture found for the problem was following: 2 hidden layers with 4 neurons in first hidden layer with tanh activation functions and with two delays from predicted network output. Network created by previous assumptions was available to predict stock price movements. Predicted price by the trained network was quite accurate but not accurate enough to make investment decisions on that. That's why trading signals were created and compared these signals with actual trading signals needed. Comparing these signals with each other results showed that 60.63% of total signals generated were accurate, 36.57% made small error and only 2.8% of total

signals made rough error (there were 3 different signals). Rough errors were defined as error by two steps on the scale of three step signals.

According to these result it is possible to say that built neural network is able to predict stock price movements, but the signal made by constructed network could not be used as an only indicator for making successful stock investments. Preferably signal constructed by the neural network should be used as an indicator of many for future movements in stock price. Research should be made in the future for building network which could predict stock price movements more accurately. Variables which probably indicate stock's price movements better should be considered and work for finding better network architecture should be carried on. All in all it was proved in current working paper that it is possible to predict stock price movements by using artificial neural networks.