

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

DIPLOMSKO DELO

NAPOVED PORABE ELEKTRIČNE ENERGIJE Z NEVRONSKO MREŽO

Ljubljana, julij 2003

TEJA BATAGELJ

IZJAVA

Študentka **Batagelj Teja** izjavljam, da sem avtorica tega diplomskega dela, ki sem ga napisala pod mentorstvom **dr. Jurija Jakliča**, in dovolim objavo diplomskega dela na fakultetnih spletnih straneh.

V Ljubljani, dne _____

Podpis: _____

KAZALO

1. UVOD.....	1
2. SLOVENSKO ELEKTROGOSPODARSTVO.....	2
2.1 Slovenski trg električne energije.....	3
2.1.1 Dnevni trg električne energije.....	4
2.1.2 Napovedovanje povpraševanja električne energije.....	5
3. RUDARJENJE PODATKOV.....	6
3.1 Uporaba rudarjenja podatkov.....	7
3.2 Postopek rudarjenja podatkov.....	9
3.3 Tehnike rudarjenja podatkov.....	10
3.3.1 Klasifikacija.....	10
3.3.2 Statistične metode.....	10
3.3.3 Razvrščanje v skupine.....	10
3.3.4 Asociativna pravila.....	11
3.3.5 Odločitvena drevesa.....	11
3.3.6 Nevronske mreže.....	12
3.3.7 Genetski algoritmi.....	13
4. NEVRONSKE MREŽE.....	13
4.1 Biološke nevrnske mreže.....	13
4.2 Matematični model nevrona.....	14
4.3 Umetna nevrnska mreža.....	15
4.3.1 Vhodi mreže.....	16
4.3.2 Izhodi mreže.....	16
4.3.3 Uteži.....	16
4.3.4 Skrite plasti.....	16
4.3.5 Aktivacijska funkcija.....	16
4.3.6 Učenje.....	18
4.4 Razvoj nevrnske mreže.....	19

4.5 Vrste nevronske mreže.....	19
4.5.1 Preprosta nevronska mreža.....	20
4.5.2 Preprosti linearni perceptron.....	20
4.5.3 Preprosti nelinearni perceptron.....	21
4.5.4 Preprosti perceptron s skrito plastjo.....	21
4.5.5 Večplastni perceptron.....	22
4.5.6 Radialno zasnovane mreže.....	23
4.5.7 Samo-organizirajoče se mreže.....	23
4.5.8 Povratne mreže.....	24
4.6 Prednosti in slabosti nevronske mreže.....	25
4.7 Uporaba nevronske mreže v ekonomiji.....	25
5. NAPOVED PORABE ELEKTRIČNE ENERGIJE Z NEVRONSKO MREŽO.....	27
5.1 Opredelitev problema.....	27
5.2 Vzorčenje.....	28
5.3 Raziskovanje podatkov.....	29
5.3.1 Porazdelitev porabe od drugih spremenljivk.....	30
5.4 Upravljanje s podatki.....	34
5.5 Modeliranje in ocenjevanje rezultatov.....	36
5.5.1 Izbor spremenljivk za učno, testno in validacijsko množico.....	36
5.5.2 Zasnova nevronske mreže.....	37
5.5.3 Končni rezultati napovedovanja.....	40
6. SKLEP.....	43
7. LITERATURA.....	45
8. VIRI.....	46

1. UVOD

Trgi in druga ekonomska področja so postala bolj kompleksna in s tem tudi parametri, s katerimi želimo rešiti določen ekonomski problem. Pri tem mislim tiste ekonomske pojave, ki jih podjetja napovedujejo in od katerih je tudi odvisen njihov poslovni uspeh.

Z nadgradnjo linearnih modelov, ki niso zadostovali za napovedovanje pojavov, ki temeljijo na nelinearnih predpostavkah, lahko danes iščemo vzorce in relacije med podatki teh pojavov. Z rudarjenjem podatkov lahko najdemo vzorce v veliki količini zbranih podatkov.

Osnovni cilj diplomskega dela je izdelava modela nevronske mreže za napovedovanje porabe električne energije v razmerah, s kakršnimi se srečujejo slovenska distribucijska podjetja. Nevronska mreža je ena od tehnik rudarjenja podatkov.

Slovenska distribucijska podjetja morajo zaradi sistema trgovanja z električno energijo napovedovati porabo električne energije en dan vnaprej. Pri tem se srečujejo s podatki, ki jih zbirajo več let, in ob tem spremljajo dejavnike, ki vplivajo na porabo električne energije. Podjetja imajo zaposlenih nekaj ljudi, ki se ukvarjajo s spremljanjem gibanja porabe električne energije in ki kupujejo ter prodajajo električno energijo. Njihove napovedi morajo biti čim bolj natančne, saj je podjetje pri napačni oceni kupljene energije s strani odjemalcev prisiljeno elektriko prodati po nižji ceni, kot jo plačajo na borzi. Zato je cilj distribucijskega podjetja zmanjšati razliko med napovedano porabo električne energije ter kasneje dejansko prodano količino električne energije.

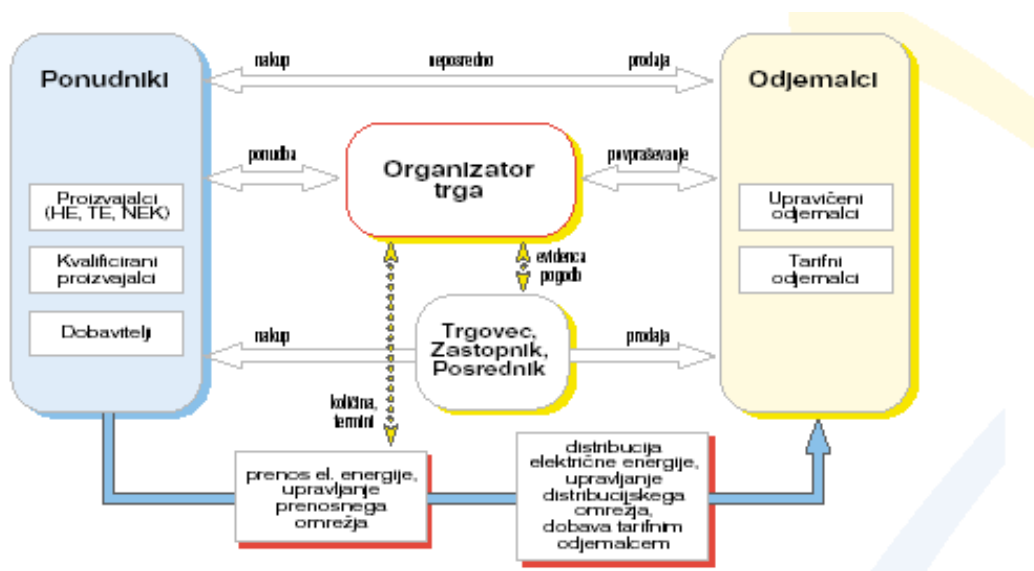
Za rešitev omenjenega problema bom najprej predstavila slovensko elektrogospodarstvo ter delitev na proizvodna, prenosna in distribucijska podjetja in opisala trg električne energije, kjer se srečujeta ponudba in povpraševanje. Zanimalo me bo povpraševanje distribucijskega podjetja po električni energiji na borzi, ki je odvisno od predvidenega povpraševanja njegovih odjemalcev po električni energiji. Zato bom razložila sistem kupovanja energije in od česa je odvisno ter zakaj podjetje sploh napoveduje povpraševanje po električni energiji. V drugem poglavju bom opisala rudarjenje podatkov in njegov izvor. Kako danes v ekonomiji uporabljamo rudarjenje podatkov in kdaj je ta postopek sploh smiseln za neko podjetje, bo naslednja točka poglavja o rudarjenju podatkov. Rudarjenje podatkov zajema več tehnik, zato bo sledila kratka predstavitev vsake od njih ob konkretnem primeru. V tretjem poglavju pa bom napisala teorijo o nevronskih mrežah, ki sem jo izbrala za tehniko, s katero bom zgradila model za napovedovanje porabe električne energije. Teorija bo zajemala osnovne pojme, ki jih srečamo v povezavi z nevronskimi mrežami, predstavitev osnovnih arhitektur, delitev mrež, postopek izgradnje nevronske mreže ter področja uporabe v ekonomiji. Na koncu pa bom predstavila njihove dobre in slabe strani. Postopek gradnje modela bom opisala v četrtem poglavju, in sicer pripravo podatkov, izbiro arhitekture nevronske mreže ter nastavitve parametrov. Izbrala bom najboljši model po kriteriju, ki je primerljiv s kriteriji, ki jih uporabljajo ostala slovenska podjetja. Ugotovitve, do katerih bom prišla ob gradnji modela, bom strnila v sklepu.

2. SLOVENSKO ELEKTROGOSPODARSTVO

Elektrogospodarstvo sodi med javne storitvene panoge, kamor uvrščamo tudi naftno gospodarstvo, telekomunikacije, vodno gospodarstvo, železnice, komunalne storitve. Izraz »javni« ni pogojen z lastninsko strukturo podjetij, temveč s tem, da so ta podjetja ključnega pomena za delovanje večine sektorjev v slovenskem gospodarstvu ter za večino gospodinjstev. Podjetja v tej panogi dobavljajo električno energijo vsem gospodarskim subjektom in tudi manjšim uporabnikom, zato neposredno vplivajo na različna področja življenja (Hrovatin, 1994, str. 434). Zato bo država kljub vsem spremembam, ki se dogajajo na trgu električne energije, tudi v prihodnje morala vsaj deloma nadzirati delovanje tega trga.

Proces deregulacije in liberalizacije, katerega pomembni mejniki so bili na področju elektroenergetike doseženi v letu 2001, pomeni zgodovinsko spremembo na energetskega področju v Sloveniji. Energetski zakon, ki je bil sprejet septembra 1999, uvaja energetski trg z namenom ureditve energetskega sektorja na sodoben način in z upoštevanjem novih razvojnih smeri v energetiki. Energetski zakon je obenem pomemben korak pri usklajevanju slovenske zakonodaje z zakonodajo Evropske skupnosti na področju energetike. Omogoča konkurenčnost na trgu z energijo, obenem pa zahteva izvajanje učinkovitega nadzora nad preskrbo z energijo (Agencija za energijo RS, 2002, str. 5).

Slika 1: Shema trga z električno energijo v Sloveniji



Vir: Agencija za energijo RS, 2002, str. 1.

Slika 1 prikazuje shemo trga električne energije v Sloveniji. Med odjemalci in ponudniki je Organizator trga. Preko njega distribucijska podjetja dobavljajo električno energijo tarifnim in upravičnim odjemalcem in na njem se dnevno določa cena električne energije.

Slovenski proizvajalci električne energije

Slovenski proizvajalci so se združili v Holding slovenskih elektrarn, kamor sodijo Soške elektrarne, Termoelektrarna Šoštanj, Termoelektrarna Brestanica, Premogovnik Velenje, Savske elektrarne. Namen združitve petih podjetij za proizvodnjo električne energije in premogovnika je bil predvsem enoten nastop na trgu pri prodaji električne energije in izboljšanje konkurenčnosti. Ostali večji proizvajalci pa so še Nuklearna elektrarna Krško, Termoelektrarna Trbovlje ter Termoelektrarna-toplarna Ljubljana, kot lahko vidimo tudi na sliki 2 (Agencija za energijo RS, 2002, str. 14).

Slika 2: Podjetja za proizvodnjo električne energije



Vir: Agencija za energijo RS, 2002, str. 14.

Prenos električne energije

Za zagotavljanje maksimalnega obsega prenosa električne energije v Sloveniji skrbi podjetje ELES. ELES združuje v enoten sistem pet distribucijskih podjetij: Elektro Celje, Elektro Gorenjska, Elektro Ljubljana, Elektro Maribor, Elektro Primorska (Agencija za energijo RS, 2002, str. 9).

Distribucija električne energije

Osnovna dejavnost distribucijskih podjetij je distribucija, nakup in prodaja električne energije. V Sloveniji so podjetja razdeljena po teritorialnem načelu. Vsako distribucijsko podjetje je razdeljeno na več podregij.

2.1 SLOVENSKI TRG ELEKTRIČNE ENERGIJE

V oktobru leta 1999 je začel veljati energetska zakon. To je bil prvi pomembni korak na poti k liberalizaciji energetskega tržišča v Sloveniji. Zakon ureja delovanje energetskega sektorja z vnašanjem tržnih mehanizmov v elektroenergetska podjetja, ki so zaradi vezanosti na omrežje naravni monopoli. Energetska zakon zagotavlja pogoje za varno in zanesljivo oskrbo z energijo

po tržnih načelih. Ustanovitev Organizatorja trga z električno energijo je ena izmed obveznosti, ki jo prinaša energetski zakon, in hkrati tudi eden temeljnih pogojev za odprtje trga z električno energijo. Organizirani trg električne energije je osrednje mesto, kjer se na organiziran način srečujeta ponudba in povpraševanje po električni energiji (Borzen, 2003). Člani organiziranega trga z električno energijo posredujejo ponudbe za prodajo in za nakup preko trgovalno informacijskega sistema organizatorja trga – TISOT (Pravila za delovanje električne energije, 1999). TISOT je računalniško podprt informacijski sistem, ki omogoča vnos, spreminjanje in odstranitev ponudb, sklenitev poslov, pregledovanje ponudb in sklenjenih poslov, izmenjavo informacij ter pregled informacij o trgovanju (Pravila za delovanje električne energije, 1999).

Organizator trga v Sloveniji je Borzen d.o.o., ki mora podobno kot vsak drug organiziran trg ustrezati osnovnim načelom borznega trgovanja (Borzen, 2003). To so:

- načelo transparentnosti (pregledno, jasno in javno poslovanje za vse udeležence; javna objava tržnih gibanj),
- načelo likvidnosti (ublažitev nenavadnih sprememb obsega ponudbe in povpraševanje brez pretiranih nihanj cen oziroma nihče od udeležencev trga ne sme imeti prevelikega vpliva na oblikovanje cene na trgu),
- načelo varnosti (Energetski zakon, Pravila za delovanje trga električne energije, finančne garancije članov),
- načelo poštenosti (nediskriminatornost organiziranega trga je zakonsko določena) ter
- načelo učinkovitosti (prilagodljiv trgovalno informacijski sistem).

2.1.1 Dnevni trg električne energije

Dnevni trg je trg, kjer se soočita ponudba in povpraševanje električne energije za obdobje naslednjega delovnega dne oziroma za obdobje do vključno prvega naslednjega delovnega dne. Trgovanje s standardiziranimi produkti trgovanja na dnevnem trgu električne energije poteka na ločenih tržnih srečanjih, ki se medsebojno ločijo tudi po načinu trgovanja.

Posli na dnevnem trgu so nakup in prodaja električne energije v obliki standardiziranih produktov trgovanja. Trgovanje poteka vsak delovni dan. Ob nedelovnih dneh (sobota in nedelja), državnih praznikih, drugih dela prostih dnevih in v primeru posebnih okoliščin se na borzi ne trguje (Pravila za trgovanje trga električne energije, 1999). Na organiziranem trgu poteka trgovanje med 8:00 in 10:30 uro. Organiziran trg je za upravljanje s ponodbami odprt (vnos, spremembe ali odstranitev) vsak trgovalni dan še v fazi pred-trgovanja. Faza pred-trgovanja traja od 6:00 do 8:00 ure za produkte pasovne, trapezne in nočne energije ter od 6:00 do 10:00 ure za produkte urne energije (Pravila za delovanje trga električne energije, 1999).

Na dnevnem trgu električne energije se trguje z naslednjimi fizičnimi produkti (Borzen, 2003):

- pasovna energija (električna energija v bloku ur od 00:00 do 24:00),
- trapezna energija (električna energija v bloku ur od 06:00 do 22:00, trapezna energija ni predmet trgovanja za nedelovne dni, državne praznike in druge dela proste dneve),
- nočna energija (električna energija v bloku ur od 00:00 do 06:00 in od 22:00 do 00:00) ter
- urna energija (trguje se s 24 urami enega dneva).

Avkcije so tržna srečanja, kjer se trguje s produkti urne energije. Za vsako uro naslednjega dne poteka ločena avkcija. Vse avkcije potekajo istočasno. Posamezna avkcija se deli na fazo izklica, fazo izračuna marginalne cene ter fazo, v kateri se ponudi morebitne presežke količine, ki nastanejo zaradi neizenačene količine v točki marginalne cene. Avkcije za vse ure naslednjega dne se pričnejo ob 10:00 uri in trajajo do 10:30 ure. Faza izklica traja od 10:00 do 10:14 in dodatno za naključni čas v roku trajanja največ ene minute. Ob 10:15 uri se prične izračun marginalne cene. Po izračunu marginalne cene pa se prične faza, v kateri je možen nakup morebitnega presežka količine po marginalni ceni. Ta zadnja faza traja do prodaje celotne količine, vendar ne dlje kot do 10:30 ure. Upravljanje s ponudbami je možno še v fazi pred-trgovanja, ki traja od 6:00 do 10:00 ure, ter v času trajanja faze izklica (Pravila za delovanje trga električne energije, 1999).

Izravnalni trg

ELES je edino elektroenergetsko prenosno podjetje v državi. Deluje kot sistemski operater na izravnalnem trgu. Za distribucijska podjetja to pomeni, da lahko vsako uro ELES-u prodajo odvečno električno energijo oziroma ELES proda distribucijskemu podjetju dodatno električno energijo, če jo podjetje kupi premalo, vendar pa to uslugo zaračunava. Po tako imenovani ceni plus (C+) lahko podjetje kupi dodatno elektriko, po ceni minus (C-) pa jo ELES od njega odkupi. Ceni se določita dnevno, glede na gibanje cen električne energije na dnevnem trgu, nekje na sredini med C+ in C- pa je cena električne energije, ki se oblikuje na borzi. Podjetje plača za vsako napačno ocenjeno MWh približno polovico cene, ki jo za eno MWh plača na borzi (Elektro Slovenija, 2003).

2.1.2 Napovedovanje povpraševanja električne energije

Za distribucijsko podjetje je torej ključnega pomena, da se odloči kupiti toliko električne energije, kolikor jo bo v določenih urah tudi prodalo. Zato podjetja napovedujejo porabo oziroma povpraševanje po električni energiji na podlagi izkušenj iz preteklosti. Na samo povpraševanje vpliva več dejavnikov. Najvplivnejši so vreme, vidljivost, veter, letni čas, tip dneva, delovni čas v podjetjih in popularne radijsko-televizijske oddaje. Vreme pomeni temperaturo zraka, ki je povezana z uporabo bodisi grelnih ali hladilnih naprav, kot so klimatske naprave. V vetrovnem vremenu stavbe in ljudje hitreje izgubljajo temperaturo, tip dneva pa pove, ali gre za delovni dan, vikend ali praznik. Na povpraševanje vpliva tudi cena

električne energije, ki pa je odvisna od ponudnika in raste s količino trgovane elektrike in z napovedjo mraza. Njeno nihanje je tem večje, kolikor večji je delež termne proizvodnje elektrike, in tem manjše, kolikor večji je delež hidro proizvodnje, saj je hidro proizvodnja veliko bolj fleksibilna. Način napovedovanja je odvisen od daljnosežnosti simulacije. Za kratkoročno napoved porabe električne energije se navadno uporabljajo (Golob et al., 2001, str. 279):

- regresije,
- tehnike časovnih vrst ali
- nevronske mreže.

Za dolgoročno napoved porabe pa ponavadi izberemo neko tipsko leto, katerega urno postavko popravimo skladno s predvidenimi indeksi rasti porabe električne energije v obravnavanem obdobju. Dolgoročno napovedovanje pomeni od enega tedna pa do več let vnaprej (Golob et al., 2001, str. 280).

Distribucijska podjetja običajno delajo precej razsežne analize podatkov o kupcih, jih segmentirajo po njihovih skupnih značilnostih, geografskih področjih, podatke filtrirajo glede na ure, ločijo modele za vikend in delovne dni, upoštevajo več vremenskih napovedi.

Distribucijska podjetja za mero natančnosti napovedovanja modelov za ugotavljanje porabe električne energije uporabljajo MAPE (Mean Average Percentage Error), ki pomeni aritmetično sredino povprečne napake strukturnega odstotka. Podjetja si jo razlagajo kot absolutno vrednost relativne napake dejanske porabe in napovedane vrednosti porabe električne energije. MAPE se po državah razlikuje zaradi različnih načinov kupovanja električne energije in zaradi različnega deleža vlaganj v razvoj modelov za napovedovanje. V slovenskem distribucijskem podjetju znaša MAPE od 2 do 3%, v Veliki Britaniji 5,8% (Ernst, 2002).

3. RUDARJENJE PODATKOV

Predstavila bom tehnike, s katerimi podjetja oblikujejo modele za napovedovanje povpraševanja po elektriki in ki jih najdemo pod skupnim pojmom rudarjenje podatkov.

»Rudarjenje podatkov je avtomatsko in polavtomatsko raziskovanje in analiziranje velikih količin podatkov z namenom odkriti vzorce in pravila med njimi.« (Berry et al., 2000, str. 7).

Rudarjenje podatkov je v nekem smislu razširitev statističnih metod z umetno inteligenco in strojnim učenjem (Godnov, 2002, str. 26).

Statistika je postavila temelje tehnologijam, na katerih temelji rudarjenje. Statistične metode so verjetno najstarejše metode, saj so matematične osnove in izpeljave statističnih metod definirali še pred uporabo elektronskih računalnikov (Kononenko, 1997, str. 24).

Umetna inteligenca se ukvarja z razvojem sistemov, ki se obnašajo inteligentno in so sposobni reševati relativno težke probleme. Pogosto te metode temeljijo na oponašanju človekovega načina reševanja problemov. V umetni inteligenci imajo algoritmi učenja vse pomembnejšo vlogo, saj se sistemi učijo in izpopolnjujejo v računalniškem zaznavanju, razumevanju naravnega jezika, avtomatskem sklepanju in dokazovanju izrekov, hevrističnem reševanju problemov (Kononenko, str. 195-197).

Osnovni namen strojnega učenja pa je avtomatsko generiranje baz znanja za ekspertne sisteme. Ti so sposobni pomagati strokovnjakom pri njihovem delu, v izjemnih primerih lahko strokovnjake tudi nadomestijo. Njihova pomanjkljivost je, da so manj prilagodljivi kot ljudje, ki svoje znanje dinamično spreminjajo in izpopolnjujejo. Zaradi tega je razvoj metod strojnega učenja tako pomemben. Z algoritmi je potrebno današnje računalnike narediti manj toge in bolj prilagodljive novim situacijam in problemom. To pomeni, da tudi algoritmi sami ne bodo več statični, temveč se bodo dinamično spreminjali z učenjem. Dolgoročni cilj strojnega učenja je ustvariti umetni sistem, ki bi z učenjem dosegel ali celo presegel človekovo inteligenco (Kononenko, 1997, str. 17).

3.1 UPORABA RUDARJENJA PODATKOV

Rudarjenje podatkov se uporablja na različnih področjih tako v ekonomiji kot drugih panogah. Njegovo uporabo upravičijo velike dimenzije podatkov in njihova kompleksnost.

Za rudarjenje podatkov morajo biti izpolnjeni določeni pogoji (Edelstein, 2002, str. 2):

- Zbrani podatki. Podatke morajo podjetja zbirati in jih shranjevati v podatkovnih skladiščih;
- Povezava podatkov in orodij za rudarjenje. Podatke, ki so shranjeni v primerni obliki, povežemo z izbranim orodjem za rudarjenje po podatkih;
- Strokovna usposobljenost in izkušnje. Oseba, ki se ukvarja z rudarjenjem podatkov, mora imeti ustrezno strokovno izobrazbo, poznati mora statistiko, saj je potrebno dobljene rezultate pravilno interpretirati.

Ko so pogoji izpolnjeni, lahko podjetje uporablja rudarjenje podatkov za znižanje stroškov in za povečanje svoje učinkovitosti.

Pristop, ki se v poslovanju zadnje čase zelo pogosto uporablja, se imenuje ravnanje odnosov s strankami – CRM (Customer Relationship Management), in zahteva razumevanje, kdo so stranke, kaj imajo rade, česa ne marajo. CRM v praksi pomeni uporabo vseh informacij o strankah za bolj učinkovito poslovanje z njimi na vseh nivojih sodelovanja s strankami. Te nivoje lahko opredelimo kot življenjski cikel stranke, ki se začne s pridobivanjem strank, nadaljuje s povečevanjem vrednosti strank in nato sledi zadrževanje oziroma ohranjanje dobrih strank. Rudarjenje podatkov v integraciji s CRM-jem lahko poveča donosnost poslovanja v vseh treh stopnjah življenjskega cikla (Berry et al., 2000, str. 14).

Z rudarjenjem lahko zmanjšamo stroške trženja z zmanjšanjem stroškov klicanja ali pošiljanja materiala ljudem, ki ne bodo odgovorili na ponudbo, ali pa z izsledki rudarjenja naslovimo naše aktivnosti na prave ljudi in s tem pravilno izberemo ciljno skupino naše promocijske akcije.

Z rudarjenjem podatkov lahko dodeljujemo objekte v razrede, kar se najbolje vidi na primeru bank, ki se morajo odločiti, komu dati posojilo. Stranka je s svojimi atributi razvrščena v razred 0 ali 1. Razred 0 pomeni, da posojila ne bo dobila, razred 1 pomeni odobreno posojilo (Berry et al., 2000, str. 9).

Prav tako si lahko z rezultati, dobljenimi z iskanjem povezav med atributi, veliki nakupovalni centri lahko pomagajo pri urejanju polic, tako da postavijo skupaj stvari, ki so običajno kupljene skupaj. Z orodji lahko določimo, katere stvari gredo skupaj v nakupovalni voziček in kakšna je verjetnost, da stranka, ki kupi mleto meso, kupi tudi ajvar.

S segmentacijo strank oziroma poslovnih partnerjev lahko ugotovimo, katere stranke prinašajo podjetju zaslužek. Običajno pridemo do splošne ugotovitve, da od 10 do 20 odstotkov strank prinaša podjetju od 40 do 80 odstotkov zaslužka (Bigus, 1996, str. 131). Segmentacija strank je dobra osnova za nadaljnjo uporabo rudarjenja podatkov. Na osnovi ugotovljenih značilnosti segmentov strank izberemo segmente, ki so si podobni. To omogoča iskanje produktov oziroma storitev, ki bi bili zanimivi za posamezne segmente. Taki analizi sledijo akcije oglaševanja, ki so namenjene ozkemu segmentu kupcev. Dobro poznavanje obnašanja kupcev zagotavlja visoko donosnost oglaševalskih akcij.

Napovedovanje gibanja pojavov na podlagi podatkov iz preteklosti nam pomaga prilagoditi naše povpraševanje oziroma ponudbo in se na ta način pravilno odločati. Primer napovedovanja je napovedovanje vrednosti delnice, kjer se ob upoštevanju dejavnikov, ki jih orodja za rudarjenje podatkov ne morejo predvideti, odločimo za nakup ali prodajo delnice.

Vse opisano so primeri podatkovnega rudarjenja, bodisi neposrednega ali posrednega. Pri prvem ponavadi iščemo neko napovedovano spremenljivko, pri drugem pa je namen rudarjenja najti povezave med vsemi spremenljivkami. Posredno rudarjenje je pristop od spodaj navzgor, medtem ko je neposredno rudarjenje pristop od zgoraj navzdol. Rudarjenje podatkov običajno združuje oba pristopa (Berry et al., 2000, str. 40-43).

Rudarjenje podatkov je uporabno, kjer najdemo velike količine podatkov in kjer obstaja možnost učenja. V poslovnem svetu je dokaj natančna definicija, kaj je vredno učenja. Za posel je nekaj vredno učenja takrat, ko je rezultat vreden več, kot stanejo aktivnosti, s katerimi smo prišli do njega.

Znanje je običajno merjeno na dva načina: lahko poveča dobiček z nižanjem stroškov ali pa poveča dobiček z večanjem prihodka. Obstaja tudi tretja pot, to je povečanje vrednosti delnic na podlagi objavljenih prihodnjih povečanih prihodkov.

3.2 POSTOPEK RUDARJENJA PODATKOV

Rudarjenje podatkov v grobem razdelimo na definiranje problema, analizo podatkov, uporabo rezultatov in merjenje uspešnosti sprememb (Pogačnik, 2001, str. 28).

Glede na problem izberemo metodologijo podatkovnega rudarjenja in pri tem upoštevamo razpoložljivost podatkov. Analiza poslovnega problema mora čim bolj popolno opisati vse procese in dejavnike, ki vplivajo na zastavljeni problem.

Podatki so ključni pri podatkovnem rudarjenju. Odvisno od problema je, kako veliko podatkov potrebujemo. Podatke zberemo, jih pripravimo za izdelavo modela, pripravimo postopke za preslikavo novih podatkov v obliko, ki jo zahteva model. Podatke nato opišemo. Odločiti se moramo, kako velik vzorec bomo vzeli. Najbolje, da rešimo isti problem enkrat z manjšim vzorcem podatkov in drugič z vsemi podatki, ki so na voljo. Če se rezultata ne razlikujeta preveč, smo uporabili dovolj veliko količino podatkov v vzorcu. Podatke moramo nato urediti, kar pomeni, da odstranimo odvečne zapise in odstranimo nepravilne podatke, ki nastanejo pri zbiranju ali vnosu podatkov. Podatke se zatem preoblikuje v obliko, v kateri jih bomo uporabljali v algoritmičnih rudarjenja po podatkih. Sodobna orodja za podatkovno rudarjenje vključujejo možnost avtomatskega normaliziranja podatkov, sicer pa normalizacijo izvedemo ročno. Včasih je potrebno vrednosti atributov pretvoriti, in sicer numerične v nenumerične in obratno. Odločimo se tudi, katere podatke bomo izbrali za naš model. Včasih je smiselno uporabiti kar vse podatke, da ne zapravljamo časa z izborom, po drugi strani pa obdelovanje vseh podatkov pomeni večje obremenitve za pomnilnik in to se prav tako izraža v izgubi časa.

Sledi izbor modela za rudarjenje po podatkih in algoritma učenja. Izbira učne metode pri gradnji modela za pomoč pri določanju je v veliki meri odvisna od zastavljenega problema. Pri nekaterih problemih je zelo pomembna razumljivost sprejete odločitve, ki jo dobimo s pomočjo modela za pomoč pri odločanju. V takih primerih zgradimo model v obliki odločitvenega drevesa, ki zelo transparentno prikazuje, zakaj se je v določenem primeru model odločil, kot se je. Podatke, pripravljene za obdelavo, razdelimo na tri dele. Prvi del so podatki, s katerimi se algoritem uči. Drugi del podatkov je namenjen testiranju modela, tretji del pa so podatki, s katerimi se oceni izbran algoritem. Rezultat faze učenja je algoritem z izbranimi parametri, ki omogoča dober končni rezultat.

Rezultate, ki nam jih prinese model, uporabimo v praksi, nato pa uporabo podatkovnega rudarjenja še ocenimo. To zahteva nekoliko daljše časovno obdobje. V primeru pozitivne ocene sprememb poslovanja ugotovitve razširimo in dokončno vključimo rudarjenje podatkov v poslovanje organizacije, sicer pa pregledamo vse korake v rudarjenju po podatkih in jih izboljšamo (Pogačnik, 2001, str. 28-57).

3.3 TEHNIKE RUDARJENJA PODATKOV

Najpogostejše tehnike rudarjenja podatkov so (Bauer, 2002, str. 7):

- klasifikacija,
- statistične metode,
- metoda najbližjega soseda,
- nevronske mreže,
- asociacijska/povezovalna pravila,
- genetski algoritmi ter
- odločitvena drevesa.

V nadaljevanju bom na kratko predstavila vsako od tehnik.

3.3.1 Klasifikacija

Klasifikacija je proces iskanja modelov, ki omogočajo razlikovanje razredov podatkov, s pomočjo katerih bi lahko predvidevali obnašanje nepoznanih razredov objektov. To pomeni, da model učimo na testnih podatkih in jih kasneje uporabimo za napovedovanje na realnih podatkih. Pred izvedbo klasifikacije pa je treba izbrati tiste attribute, ki vplivajo na povezave in vzorce med podatki (Breiman, 1984, str. 37).

3.3.2 Statistične metode


Za statistične metode je značilno, da za analizo podatkov uporabimo osnovne statistike, kot sta srednja vrednost, standardni odklon. Rezultate teh statističnih metod predstavimo s pomočjo grafov. Najbolj pogosto uporabljena statistična metoda so časovne vrste.

3.3.3 Razvrščanje v skupine

Pri tej tehniki gre za razvrstitev enot v skupine, tako da je znotraj skupin dosežena kar največja homogenost (podatki si morajo biti po določeni lastnosti zelo podobni) in so hkrati skupine med sabo čim bolj heterogene (čim bolj narazen). Določimo število skupin (K) in metriko (kako merimo razdaljo med enotami). Odločanje poteka na enak način kot pri podobnih primerih v preteklosti.

Tehnika najbližjega soseda je precej enostavna, kljub temu da je primerna tudi zelo velike modele. Tehnika je zelo podobna tehniki razvrščanja podatkov v skupine. Slika 3 prikazuje metodo k - najbližjih sosedov. Pri klasifikaciji primera X poiščemo k -najbližjih sosedov. Pri tem je potrebno definirati k in mero razdalje med primeri.

Slika 3: Metoda k-najbližjih sosedov



Vir: Bauer, 2002, str. 9.

3.3.4 Asociativna pravila

Že iz majhne podatkovne baze lahko izdelamo veliko asociacijskih pravil. Zaradi tega se omejimo le na tiste, ki so »bolj zanimivi« od drugih. To pa pomeni, da morajo asociacijska pravila veljati za večje število primerkov (v skrajnem primeru veljajo le za en primerek). Pokritje je število primerkov, za katere asociacijsko pravilo velja – včasih imenujemo pokritje tudi podpora. Natančnost je delež vseh primerkov, za katere pravilo napove pravilen rezultat, enak številu vseh primerkov, za katere pravilo velja. Zaradi velikega prostora, ki ga je potrebno preiskati za izdelavo asociacijskih pravil, morajo biti algoritmi dobro načrtovani. Velikokrat so ti algoritmi izdelani z mislijo na določen problem in tako niso dobri tudi pri drugih podobnih problemih. Tipičen problem asociacijskih pravil je že omenjeni problem nakupovalne košarice (Bauer, 2002, str. 10, Pivk, 2001, str. 6).

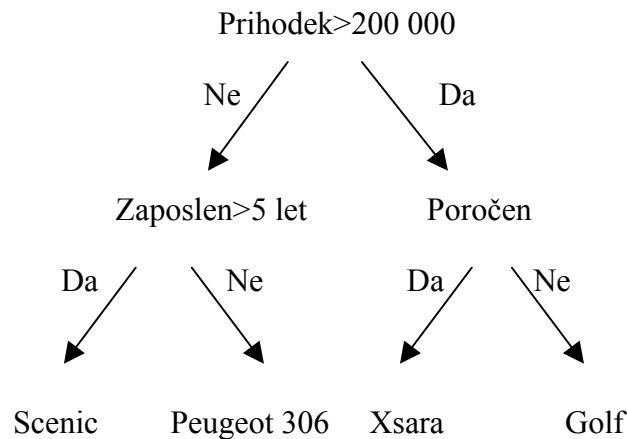
3.3.5 Odločitvena drevesa

Odločitvena drevesa so še posebno uporabna tehnika. Klasificirajo na podlagi zaporedja preprostih in lahko razumljivih testov, semantika pa je intuitivno razumljiva ekspertom s področja klasifikacije.

Odločitvena drevesa so preprosto orodje za predstavitev znanja in klasificirajo primerke v končno število razredov. Vozlišča so označena z imeni atributov, povezave pa z možnimi vrednostmi tega atributa. Listi drevesa so označeni s končnim razredom (Kononenko, 1997, str. 147). Posamezni primerki se klasificira tako, da se v vsakem vozlišču preverjajo vrednosti njegovih atributov in se izbere povezava, ki ji vrednosti ustrezajo. Odločitvena drevesa se uporabljajo za odkrivanje pravil in odvisnosti v podatkih. Proces sistematično razmejuje in razdvaja informacije, ki se nahajajo v podatkih. Algoritmi, ki se uporabljajo za razdvajanje podatkov, stremijo k maksimalni segregaciji zapisov – cilj je najti spremenljivko (atribut), ki najbolje razdeli podatke. Teoretično lahko za segregacijsko spremenljivko izberemo katerikoli atribut, vendar je smiselno izbrati tistega, ki »dobro« razmejuje. Razmejitev podatkov se ponovi na naslednjem nivoju, kjer se izbere druga spremenljivka. Ta »deli in vladaj« pristop h gradnji odločitvenih dreves se imenuje tudi od zgoraj navzdol indukcija odločitvenih dreves. Drevesa

lahko gradimo s pomočjo atributnega učenja ali pa z različnimi algoritmi. Drevo zgradimo na podlagi učne množice, njegovo kakovost pa preverimo s testnimi primeri. Končni cilj gradnje dreves je pridobitev nekaj pravil (Bauer, 2002, str. 11). Slika 4 je primer drevesa odločanja, kjer glede na prihodek stranke podjetje lahko določi, kateri avto bo stranka ob določenih atributih kupila.

Slika 4: Drevo odločanja




Vir: Oblikovala sama.

3.3.6 Nevronske mreže

Nevronske mreže so tehnika za modeliranje obsežnih in zapletenih problemov, za katere imamo na voljo ogromne baze podatkov. Tehnika izvira s področja umetne inteligence, kajti izvira iz časov, ko so jo začeli razvijati znanstveniki z namenom razviti strojno opremo, ki bo sposobna mišljenja (Berson et al., 1999, str. 145). Nevronska mreža lahko poišče skrite relacije, vzorce in trende med podatki, ki bi jih ljudje lahko spregledali. Z odkrivanjem informacij ustvari novo znanje ter zaznava nepravilnosti in izjemnosti, ki izhajajo iz velike količine podatkov. Klasificira, organizira in povzema podatke ter dela napovedi (Bregar, 2001a, str. 12). Njihova največja pomanjkljivost je nezmožnost obrazložitve sprejete odločitve (Bregar, 2001b, str. 211).

Slika 5: Primer enosmerne trinojske nevrnske mreže



Vir: Bregar, 2001a, str. 4.

Slika 5 prikazuje nevronska mrežo s tremi nivoji, od katerih je prvi vhodni, zadnji je izhodni, vmes pa je skriti sloj, ki omogoča nelinearno povezanost med nevroni.

3.3.7 Genetski algoritmi

Genetski algoritmi so sredstvo za reševanje problemov, ki so iskalne ali optimizacijske narave. Delujejo na principu preživetja uspešnejšega. Dobre rešitve združimo v upanju, da bo potomec predstavljal boljšo rešitev.

Ko prvič izvedemo genetski algoritem, se ustvari začetna populacija rešitev. Le-te se po navadi izberejo naključno in večina osebkov v prvotni populaciji verjetno ne bo predstavljala dobrih rešitev. Nekatere bodo celo nasprotje pričakovanega. Izračun uspešnosti osebkov v populaciji se nanaša na preizkušanje rešitev glede na to, kako uspešno in v kakšni meri rešijo dani problem. Na ta način lahko določimo, katera rešitev je boljša od druge. Osebki, ki uspešneje ali vsaj delno rešijo problem, dobijo višjo vrednost uspešnosti od tistih, ki problem rešijo slabše ali pa ga ne morejo rešiti. Izračun uspešnosti se opravi glede na funkcijo uspešnosti. V fazi selekcije iz trenutne populacije izberemo podmnožico osebkov. Glede na oceno uspešnosti bomo kasneje iz te podmnožice izbrali pare osebkov – staršev, ki jih bomo uporabili za razmnoževanje. V fazi razmnoževanja se po nekem postopku združita izbrana starša, iz katerih dobimo dve novi rešitvi (dva potomca). Cilj je, da nam razmnoževanje da vsaj enega potomca, ki je, glede na funkcijo uspešnosti, boljši od obeh staršev. Novi rešitvi v populaciji zamenjata dva osebka z najmanjšo oceno uspešnosti ali pa zamenjata kar starša. Tako velikost populacije ostaja nespremenjena. Mutacija spremeni posamezne gene v potomcih. Koliko otrok bo mutiralo, če sploh bo kateri mutiral, se določi naključno. Tudi geni mutacije se praviloma izberejo naključno. Postopek se ponavlja tako dolgo, dokler ne najdemo najboljše rešitve. Vedno pa ni nujno tako. Genetski algoritem lahko tudi prenehamo izvajati po določenem številu korakov, čez določen čas, ko potomci niso več uspešnejši od staršev. V mnogih primerih bo genetski algoritem našel zelo dobro rešitev, vendar ne tudi najboljšo. Če genetski algoritem izvajamo zelo dolgo, postanejo vsi kromosomi v populaciji enaki. Ta pojav lahko delno odpravimo z mutacijo ali z večjo populacijo, popolnoma pa ga ne moremo odpraviti (Taranenko, 2001, str. 9).

4. NEVRONSKE MREŽE

4.1 BIOLOŠKE NEVRONSKE MREŽE

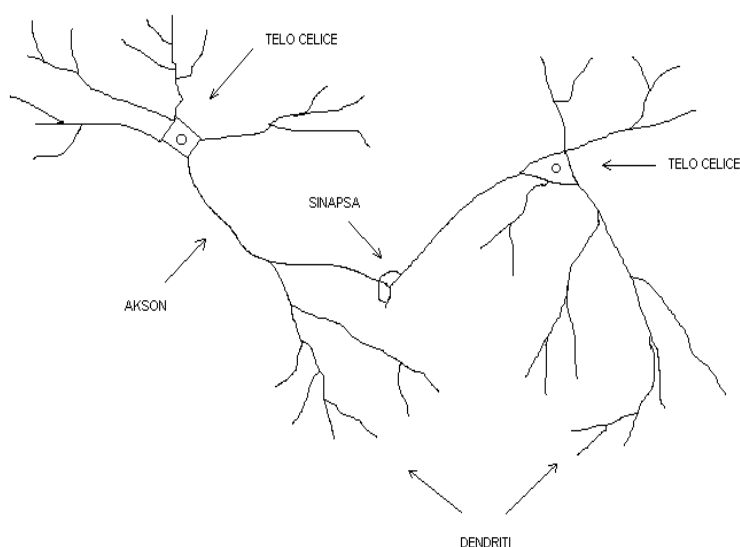
Nevronske mreže so ime dobile po nevronih, ki so možganske celice. Le-te so organizirane v skupine – mreže, od katerih vsaka vsebuje nekaj tisoč celic. Pomembna lastnost takšnih nevronskih mrež je njihova zmožnost učenja in ohranjanja informacij. Vsak nevron vsebuje jedro, dendrite in akson. Dendriti delujejo kot vhodi v celico, akson pa pošilja signale iz nje. Med celicami se nahajajo sinapse, ki imajo vlogo povezovalca med aksoni in dendriti, poleg tega pa lahko določajo moč signala med izhodom in vhomom v naslednjo celico. Nevronske mreže spominjajo na možgane vsaj z dveh pogledov: znanje pridobivajo s procesom učenja, za shranjevanje znanja pa se uporabljajo med-nevronske povezave oz. sinaptične uteži. Nevronska

mrežo lahko naučimo, da opravlja določeno funkcijo s spreminjanjem vrednosti povezav oz. uteži med elementi (Jamšek, 2000, str. 5).

Biološki nevron sestavljajo trije deli (Dobnikar, 1990, str. 4):

- telo celice,
- dendriti (sprejemniki) ter
- akson (glavna prenosna pot).

Slika 6: Model zgradbe biološkega nevrna in prikaz povezav med njimi




Vir: Dobnikar, 1990, str. 5.

Na sliki 6 vidimo zgradbo biološkega nevrna, kjer dendriti sprejemajo signale od drugih celic na stičnih mestih – sinapsah. Od tu potujejo signali do celičnega telesa, kjer se povprečijo z ostalimi podobnimi signali. Če je povprečje dovolj veliko, se celica aktivira. To pomeni, da generira impulz in ga usmeri vzdolž aksona ter dalje preko sinaptičnih povezav do novih celic (Kumer, 1999, str. 37).

4.2 MATEMATIČNI MODEL NEVRONA

Model predstavlja poseben element, katerega vhodi so uteženi, izhod pa se ravna po produktu vrednosti vhodnih spremenljivk z ustreznimi utežmi, glede na neko posebno vrednost. To posebno vrednost imenujemo prag, saj izhod zavzame eno od obeh možnih vrednosti, odvisno od tega, ali je produkt vrednosti vhodnih spremenljivk nad ali pod pragom.

Slika 7: Zgradba umetnega nevrona



Vir: Dobnikar, 1990, str. 10.

Delovanje nevrona s slike 7 podaja izraz:

$$\eta = \sigma(f) = \sigma(\sum \omega_j \cdot \xi_j - P)$$

kjer je:

- ξ_j – primarne spremenljivke oz. vhodi, ki imajo lahko digitalne ali analogne vrednosti ($j = 1 \dots n$),
- $\sigma(f)$ – izhodna funkcija, ki preslika rezultat aktivacije v izhod nevrona. Lahko je deterministična binarna, deterministična zvezna ali stohastična, ki je ponavadi binarna (Kononenko, 1997, str. 207),
- ω – uteži vhodnih spremenljivk ($j = 1 \dots n$),
- η – izhod nevrona, ki je rešitev problema, ter
- P – pragovna vrednost ali prag elementa, ki je posebna vrednost, glede na katero se ravna izhod po zmnožku vhodov z utežmi.

4.3 UMETNA NEVRONSKA MREŽA

Umetna nevronska mreža je množica paralelno povezanih računalniških nevronov, ki istočasno dobijo signal in ga z računskimi operacijami obdelajo. Moč signala, ki pride na naslednji sloj, je odvisna od uteži. Nevronska mreža je sestavljena iz vhodov, izhodov, med njimi pa so skrite plasti, kjer so uteženi nevroni z aktivacijsko funkcijo.

4.3.1 Vhodi mreže

Vsak vhod odgovarja posameznemu atributu. Vrednosti atributov, ki vstopajo v mrežo, so lahko izključno numerične. V primeru drugih podatkovnih tipov, kakršni so besedilo, zvok ali slika, je potrebna predhodna pretvorba – normalizacija (Bregar, 2001a, str. 5).

4.3.2 Izhodi mreže

Izhod nevronske mreže je rešitev problema. Ker je izražen kot število na določenem intervalu, ga je potrebno na splošno pretvoriti v kvalitativno ali razumljivejšo kvantitativno vrednost (na primer 0.1 v »zavrni kredit« in 0,8 v »odobri kredit«). Izhodni nivo mora imeti toliko nevronov, kolikor je možnih odločitev – razredov vhodnih objektov (Bregar, 2001a, str.5).

4.3.3 Uteži

Ključni element umetne nevronske mreže je utež. Pripada povezavi in izraža moč podatka, ki prehaja preko te povezave iz enega na drug nivo. Določa torej relativno pomembnost vhoda glede na ostale vhode v procesirni element. Če je utež pozitivna (vzpodbujajoča), nevron sprejema signal povezanega nevrona iz predhodnega nivoja, če je negativna (zavirajoča), ga zavrača, če je 0, pa pomeni, da ni povezave med nevronoma (Bregar, 2001a, str. 6). Uteži so bistvene zato, ker se nevronska mreža uči skozi postopek njihovega prilagajanja. Postavljanje uteži različnih faktorjev vodi do ustrezne klasifikacije in s tem do sprejemanja odločitev.

4.3.4 Skrite plasti

Umetni nevron obdela vhode in jih posreduje skozi en sam izhod, ki je s sinapsami vezan na druge nevrone. Nastane povezana mrežna struktura, sestavljena iz nivojev ali plasti. En nivo je vedno voden in skrbi za vstopanje informacij v model, en je izhoden in posreduje rezultate delovanja mreže, ostali nivoji pa so skriti. Slednji omogočajo klasifikacijo objektov, ki jih ne moremo opisati z linearnimi enačbami. Zato lahko nevronska mreža z vsaj enim vmesnim nivojem aproksimira katerokoli linearno ali nelinearno matematično funkcijo.

4.3.5 Aktivacijska funkcija

Prvi del operacij, ki se dogajajo v nevronu, predstavlja seštevanje uteženih vhodov, nato pa ta vsota doseže nelinearni filter, ki se imenuje aktivacijska funkcija. Aktivacijska funkcija kombinira vhode v vmesno vrednost, izhodna funkcija pa preslika rezultat aktivacije v izhod nevrona. Aktivacijska funkcija se lahko določi v skritih plasteh ali v izhodni plasti.

Aktivacijske funkcije v skritih plasteh

V vsaki skriti plasti je vhod transformiran z aktivacijsko funkcijo. Običajno se skozi vse skrite plasti uporablja ista aktivacijska funkcija, lahko pa ima celo vsak nevron svojo aktivacijsko funkcijo. Običajno se uporablja aktivacijska funkcija za vključitev nelinearnosti med podatki, s tem da doda določene matematične transformacije. Brez teh transformacij je mreža enostavni perceptron z vhodi in izhodi. V tabeli 1 vidimo aktivacijske funkcije, ki se uporabljajo v


nevronskih mrežah, odvisno od vrednosti vhodne spremenljivke.

Tabela 1: Aktivacijske funkcije, ki se uporabljajo v nevronskih mrežah

Ime funkcije	Dopuste vrednosti izhoda	Funkcija
Identična	Poljubno	X
Linearna	Poljubno	X
EkspONENTna	>0	$\text{Eksp}(X)$
Ulomljena racionalna	>0	$1/X$
Kvadratna	≥ 0	X^2
Logistična	$[0,1]$	$1/(1+\text{eksp}(-X))$
Gaussova	$[0,1]$	$\text{Eksp}(-X^2)$
Sinusna	$[0,1]$	$\text{Sinus}(X)$
Kosinusna	$[0,1]$	$\text{Kosinus}(X)$
Eliotova	$[0,1]$	$X/(1+\text{abs}(X))$
Hiperbolični tangens	$[-1,+1]$	$\text{Tanh}(X) = 1-2/(1+\text{eksp}(2X))$
Arkus tangentna	$[-1,+1]$	$\text{Arctan}(X) (2/\pi)$

Vir: SAS Institute Inc., 1997, str. 52.

Slika 8: Primeri aktivacijskih funkcij



Vir: Matlab, 1997, str. 46, 418.

Na sliki 8 vidimo tri primere aktivacijskih funkcij. Prva od leve proti desni je linearna, druga je sigmoidna in tretja je hiperbolični tangens, kjer so n vhodi, a pa izhodi mreže. Pri prvi vidimo, da je vrednost izhoda neomejena, pri drugi je izhod omejen na vrednosti od 0 do 1 in pri tretji je izhod omejen na vrednosti od -1 do 1.

Aktivacijske funkcije v izhodni plasti

Izhodna aktivacijska funkcija je povezana s funkcijo napake, ki se jo minimizira z učenjem. Linearna funkcija se običajno uporablja za nezvezne spremenljivke, medtem ko se pri spremenljivkah s pozitivno vrednostjo uporablja eksponentna aktivacijska funkcija (SAS Institute Inc., 1997, str. 52).

4.3.6 Učenje

Nevronska mreža potrebuje učne in testne podatke. Učni oz. zgodovinski podatki so tisti, na katerih se uči in na podlagi katerih se razporeja uteži, da se približa čim boljšemu izhodu. Nevronska mreža na osnovi vhodnih podatkov postavi uteži na povezavah, ki se primerjajo s pragom nevrona. Postavitev uteži v naslednjem nivoju je odvisna od odločitve posameznih nevronov v prejšnjem nivoju. Na ta način pride do končne odločitve na izhodu, kjer se dobljeni rezultat primerja s predvidenim iz učnega modela. Če je rešitev znotraj predvidene tolerance, bo mreža shranila razporeditev uteži in pragov kot ustrezno, v nasprotnem primeru pa se bo učenje ponavljalo, dokler ne bo dosežen zeleni rezultat. To pa je lahko tudi več 1000-krat. Problem, ki se pogosto pojavi pri učenju nevronske mreže, je generalizacija, kar pomeni, da si nevrnska mreža zapomni učno množico in ni več sposobna dobro sklepati za vhode, ki jih še ni videla, kar vodi do slabih rezultatov.

Učne algoritme delimo v dve skupini (Bregar, 2001a, str. 6):

- Nadzorovano učenje. Temelji na naboru vhodnih podatkov – učnih primerov, za katere so znani ustrezni izhodi. Glede na razlike med zelenimi in dejanskimi izhodi mreže se izračunajo popravki uteži povezav. Najbolj uveljavljen ter hkrati sorazmerno preprost in dobro razumljen tovrstni algoritem je vzvratno širjenje napake;
- Nenadzorovano učenje. Primerno je izključno za mrežno strukturo s povratnim tokom. Ta se oblikuje samodejno na takšen način, da je vsak procesirni element strateško vezan na različen nabor vhodnih vrednosti. Mreži so posredovani izključno vhodni podatki, znanje o pravilnosti izhodov ni potrebno.

Naj omenim tri tehnike učenja (SAS Institute Inc., 1997, str. 23):

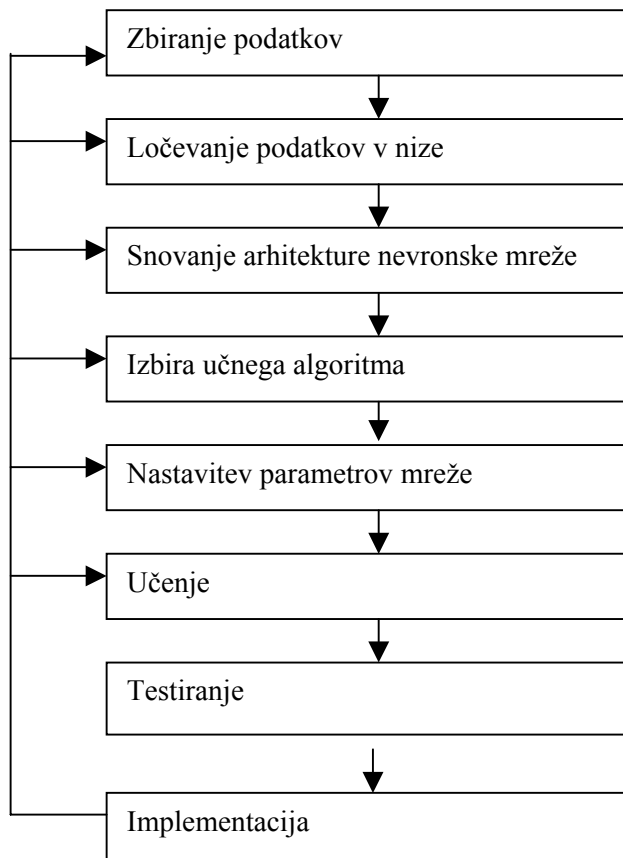
- Levenberg-Marquardt je primerna za učenje mrež z manj kot 100 utežmi;
- Quasi-Newton se uporablja za modele s številom utežmi do 500;
- Conjugiran gradient se priporoča za modeliranje mrež, ki imajo več kot 500 uteži.

Večplastni perceptron običajno uporablja učenje z vzratnim širjenjem napake, ki mrežo uči tako, da približuje napako vrednosti nič, napaka pa je razlika med izhodom in odvisno spremenljivko. Težava, ki se pojavlja pri tej vrsti učenja, je, da pri učenju z veliko podatki mreža potrebuje veliko časa, kajti učenje z vzratnim širjenjem zahteva veliko ponavljanj (SAS Institute Inc., 1997, str. 24).

4.4 RAZVOJ NEVRONSKE MREŽE

Razvoj nevronske mreže se začne z zbiranjem podatkov, ki se jih loči v različne nize. Nato je treba izbrati arhitekturo nevronske mreže in učni algoritem. Določijo se še ostali parametri mreže, potem pa se mrežo uči ter testira. Postopek se ponavlja toliko časa, dokler ne da dovolj dobrih rezultatov. Seveda pa je za to potrebno spreminjati bodisi arhitekturo, učni algoritem ali parametre mreže. Ko dobimo zadovoljiv rezultat, sledi korak implementacije. Postopek razvoja nevronske mreže lahko vidimo na sliki 9.

Slika 9: Razvoj nevronske mreže



Vir: Bregar, 2001a, str 8.

4.5 VRSTE NEVRONSKIH MREŽ

Nevronske mreže lahko razvrstimo v skupine po različnih kriterijih. Najpogosteje se ločijo glede na (Kononenko, 1997, str. 198):

- topologijo nevronske mreže,
- namen nevronske mreže,
- pravilo učenja ter


- kombiniranje vhodov nevrona v izhod.

V nadaljevanju bom opisala tiste arhitekture nevronskih mrež, ki se najpogosteje uporabljajo in združujejo zgoraj naštete kriterije.

4.5.1 Preprosta nevronska mreža

Preprosta nevronska mreža ima en sam vhod, en izhod in eno odvisno spremenljivko. Vhod so podatki, ki jih imamo. V statistiki bi vходу rekli neodvisna spremenljivka, izhod pa je informacija, ki jo potrebujemo, oziroma spremenljivka, ki jo napovedujemo. Odvisna spremenljivka je vrednost, kateri naj bi se mreža med učenjem čim bolj približala. Preprosto nevronska mrežo ponazarja slika 10.

Slika 10: Preprosta nevronska mreža



Vir: SAS Enterprise Miner Help, 1999-2001.

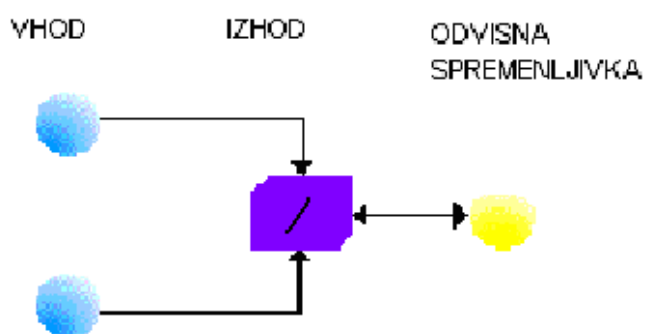
Na sliki ima vsaka od povezav med vhodi in izhodi neko svojo težo. Krog predstavlja neodvisne spremenljivke oziroma vhode, medtem ko kvadrat predstavlja vrednosti, izračunane iz vhodov. Kako je ta vrednost izračunana, je odvisno od aktivacijske funkcije (SAS Institute Inc., 1997, str. 14).

4.5.2 Preprosti linearni perceptron

Najpreprostejši perceptron ima en izhod. V primeru, kot ga vidimo na sliki 11, je perceptron tudi linearen (aktivacijska funkcija je linearna). V statistiki je ekvivalent linearnemu perceptronu linearna regresija.

Na sliki 11 sta dva vhoda povezana v en izhod. Kombinacijska funkcija določa, h katerim vhodom sodi določena aktivacijska funkcija in jih kombinira (SAS Institute Inc., 1997, str. 16).

Slika 11: Preprosti linearni perceptron




Vir: SAS Enterprise Miner Help, 1999-2001.

4.5.3 Preprosti nelinearni perceptron

Preprosti nelinearni perceptron je mreža, ki z nelinearno aktivacijsko funkcijo omogoča nelinearno povezavo med vhodom in izhodom.

Slika 12: Preprosti nelinearni perceptron



Vir: SAS Enterprise Miner Help, 1999-2001.

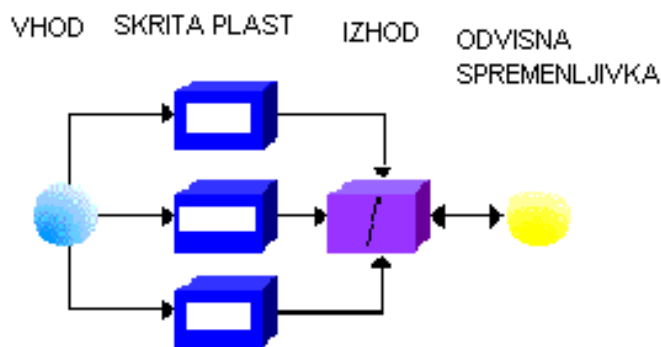
Slika 12 prikazuje preprost nelinearen perceptron z nelinearno aktivacijsko funkcijo, v tem primeru logaritmsko. Statistično je to enako logaritmski regresiji.

4.5.4 Preprosti perceptron s skrito plastjo

Mreži z vhodom in izhodom lahko dodamo skrito plast in tako dobimo sloj z utežmi, kateremu sledi izhodna plast. Nastane preprost perceptron s skrito plastjo.

Slika 13 prikazuje vhod, tri nevrone v skriti plasti v obliki pravokotnika, izhod in odvisno spremenljivko, ki jo prikazuje desni krog. Posebna značilnost nevronske mreže je ta, da vključujejo eno ali več skritih plasti. Te vsebujejo dodatne transformacije, na sliki beli pravokotnik.

Slika 13: Preprosti perceptron z eno skrito plastjo s tremi nevroni



Vir: SAS Enterprise Miner Help, 1999-2001.

4.5.5 Večplastni perceptron

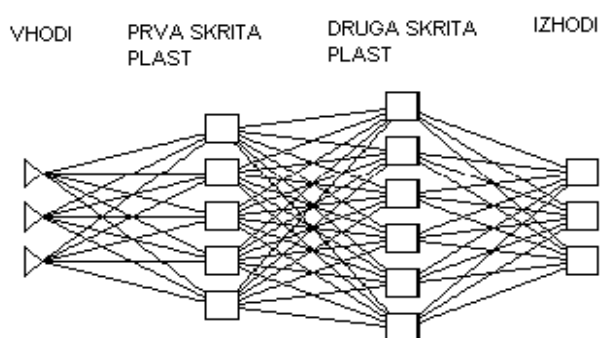
Je ena najbolj priljubljenih oblik nevronske mreže.

Večplastni perceptron ima (SAS Institute Inc., 1997, str. 23):

- poljubno veliko število vhodov,
- vsaj eno skrito plast,
- v vsaki skriti plasti tolikšno število nevronov, kot jih potrebuje,
- lahko različno število nevronov v vsaki skriti plasti,
- uteži med:
 - vhodi in prvo skrito plastjo,
 - med skritimi plastmi ter
- med zadnjo skrito plastjo in izhodom je večplastni perceptron nelinearen, ker skrite plasti uporabljajo nelinearno aktivacijsko funkcijo, najpogosteje hiperbolični tangens.

Večplastni perceptron je primer mreže s širitvijo napake naprej. To pomeni, da je povezava samo v eno smer. Kot lahko vidimo na sliki 14, je vhod povezan s prvo skrito plastjo, vsaka skrita plast pa je povezana z naslednjo. Zadnja skrita plast je povezana z izhodom.

Slika 14: Večplastni perceptron

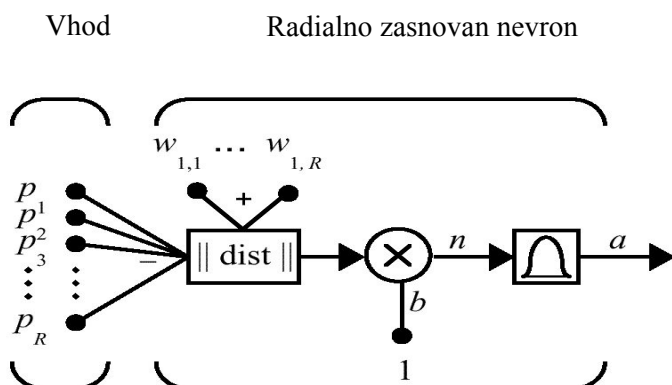


Vir: Neural networks, 2003.

4.5.6 Radialno zasnovane mreže

Radialno zasnovane nevronske mreže so mreže, ki ponavadi zahtevajo več nevronov kot klasični večplastni perceptroni, vendar jih lahko načrtujemo v veliko krajšem času. Najbolje delujejo, ko je na razpolago velika učna množica podatkov. Problem teh mrež je, da zaradi uporabljenih transformacijskih funkcij potrebujejo več nevronov kot ostale mreže v skritih plasteh. Te mreže se uporabljajo za aproksimacijo zveznih funkcij ter za klasifikacijo problemov. Načrtujejo se direktno in niso odvisne od učenja. Mreža je veliko počasnejša od ostalih, ker je računsko zahtevnejša (Jamšek, 2000, str. 8).

Slika 15: Primer enostavne radialno osnovane mreže z enim samim nevromom.



Vir: Matlab, 1997, str. 197.

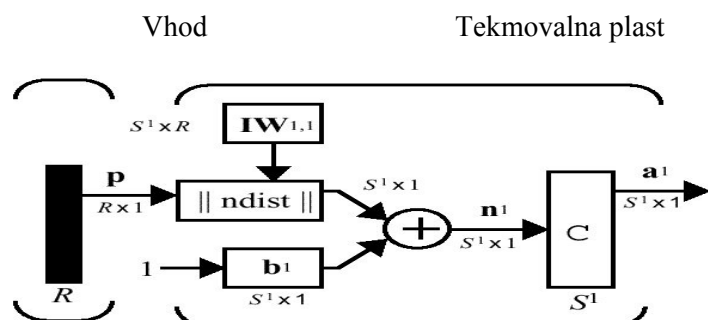
Slika 15 prikazuje radialno zasnovano mrežo, kjer je vhod v nevrom vektor razdalje med vektorjem uteži w in vhodnim vektorjem p , pomnožen z odmikom b . Izhod ponazarja oznaka a .

4.5.7 Samo-organizirajoče se mreže

Samo-organizirajoče se mreže so zagotovo eno najbolj zanimivih področij nevronske mreže. To so mreže, ki so se same sposobne naučiti ugotavljati zakonitosti in korelacije vhodnih signalov.

Primerne so takrat, ko potrebujemo samo-kategorizacijo vhodnih vektorjev. Sposobne so se naučiti tudi topologijo vhodnih vektorjev. Samo-organizirajoče se mreže spoznavajo skupine podobnih vhodnih vektorjev na ta način, da nevroni, ki so si v plasti mreže fizično blizu, odgovorijo na podobne vhodne vektorje. Nevroni tekmovalne plasti so tako porazdeljeni, da spoznajo pogosto predstavljene vhodne vektorje (Jamšek, 2000, str. 8).

Slika 16: Primer samo-organizirajoče se mreže



Vir: Matlab, 1997, str. 217.

Na sliki 16 je vhodni vektor p , matrika vhodnih uteži je IW , na izhodu pa je vektor s S elementi. Elementi so negativne vrednosti razdalj med vhodnim vektorjem in vrstičnim vektorjem matrike IW . Če so vsi odmiki b enaki nič, potem je maksimalna vrednost n enaka nič. Izhod transformacijske funkcije tekmovalne plasti je vrednost 0 za vse nevrone, razen za zmagovalca, kjer je izhod 1. Zmagovalni nevron je tisti, katerega vrednost je najbolj pozitivna in je tako najbližje vhodnemu vektorju.

4.5.8 Povratne mreže

Povratne mreže se ločijo od večplastnih perceptronov po tem, da vsebujejo vsaj eno povratno povezavo. Povratna povezava lahko izvira iz skrite plasti ali pa izhodne plasti mrež. Prisotnost povratne povezave ima velik vpliv na izboljšanje sposobnosti učenja in delovanja. Najbolj znani sta Elmanova in Hopfieldova povratna nevronska mreža.

Elmanova mreža

Elmanova mreža je dvoplastna nevronska mreža z vzratnim širjenjem napake, z dodatkom povratne povezave iz izhoda skrite plasti nazaj na vhod. Ta povratna povezava omogoča Elmanovi mreži, da se uči, spozna in generira začasne, časovno variabilne vzorce in tudi prostorske vzorce. V skriti plasti oz. povratni plasti vsebuje nevrone s tangento sigmoidno transformacijsko funkcijo, v izhodni plasti pa nevrone z linearno transformacijsko funkcijo. Posebnost te funkcije je, da aproksimira katerokoli funkcijo s poljubno natančnostjo. Elmanove mreže so uporabne na področju procesiranja signalov in napovedovanja, kjer ima čas prevladujočo vlogo (Jamšek, 2000, str. 9).

Hopfieldova mreža

Uporablja se za pomnjenje enega ali več konstantnih želenih izhodov. Izhodi so kot spomin, ki ga mreža priključuje, ko so si vhodi podobni. Vhodi delujejo kot namig na mrežni spomin. Edini pogoj je, da ima v skriti plasti dovolj nevronov. Čim bolj je zapletena funkcija, ki jo želimo aproksimirati, tem več nevronov potrebujemo. Mreža shranjuje določene množice ravnovesnih točk. Povratnost mreže zagotavlja povratna povezava iz izhoda nazaj na vhod, ko je v delovanju. Pričakuje se, da se mreža ustali v eni od ravnovesnih točk. Slabost te mreže je, da ima lahko poleg želenih tudi lažne točke ravnovesja. Hopfieldova mreža uporablja simetrično omejeno linearno transformacijsko funkcijo. Če je vhod manjši od -1, da transformacijska funkcija na izhodu -1, podobno velja, če je vhod večji kot 1. Mrežo lahko preizkusimo z enim ali več vhodnimi vektorji, ki so predstavljeni kot začetni pogoji. Ko so dani začetni pogoji in da mreža izhodi, se le-ta pripelje nazaj na vhod in tako predstavlja vhod za naslednji korak. Vhod se povratno popravlja, dokler izhod ne doseže stabilnosti. Mreže se v praksi ne uporabljajo veliko (Hopfield J.J., 1982, str. 2554-2558).

4.6 PREDNOSTI IN SLABOSTI NEVRONSKIH MREŽ

Nevronske mreže so primerne za reševanje kompleksnih problemov. Čeprav se ponajbolj s številnimi prednostmi, imajo tudi nekaj slabosti.

Njihova dobra stran je, da so sposobne reševati probleme, ki jih ne moremo opisati z analitično funkcijo, hkrati pa z analiziranjem velike količine podatkov poiščejo vzorce, relacije in lastnosti objektov v slabo strukturiranih problemskih situacijah, v katerih pravila niso poznana. Same oblikujejo predstavitev informacij, se prilagajajo zahtevam okolja in z učenjem izboljšujejo delovanje, prav tako same zgradijo model. Lahko aproksimirajo katerokoli nelinearno realno funkcijo z vsaj enim skritim nivojem. Poleg tega pa so strpne do napak, saj lahko obdelujejo nepopolne ali nepravilne podatke, tudi takšne, ki jih še ne poznajo. Nevronska mreža se zelo enostavno prilagodi spreminjajočemu okolju. Je hitra zaradi medsebojno povezanih procesirnih enot, ki delujejo paralelno, tako da obdelava podatkov poteka hitro (Šušteršič, 2002, str. 28, 29).

Njihova največja slabost je nezmožnost obrazložitve sprejete odločitve, saj delujejo kot črna škatla. Zato se na izhode odločitvenih sistemov, katerih modeli so zgrajeni z nevronskimi mrežami, ne smemo zatrdno zanašati, temveč jih upoštevamo zgolj kot nasvete. Imajo dolg čas učenja, ker učni algoritem izvaja veliko ponovitev in nenehno prilagaja uteži. Njihova slabost pa je tudi, da za dobro učenje mreže potrebujemo veliko podatkov tako za učni kot za testni niz (Bregar, 2001a, str. 14).

4.7 UPORABA NEVRONSKIH MREŽ V EKONOMIJI

V ekonomiji se pogosto srečujemo s situacijami, ko imamo veliko podatkov in so odvisnosti med njimi kompleksne in nelinearne. Nevronske mreže ne temeljijo niti na klasičnem programiranju niti na logičnih kriterijih, na katerih temeljijo ekspertni sistemi. V času učenja,

ko nevrnska mreža dela z učnim nizom podatkov, se s spreminjanjem uteži ustvarijo povezave med vhodnimi in izhodnimi vektorji. Obdelujemo lahko obsežne baze podatkov in prav zaradi te lastnosti kot tudi drugih prednosti se nevrnske mreže uporabljajo v ekonomiji. V tabeli 2 so zbrana področja in primeri uporabe nevrnskih mrež v ekonomiji. Največji uporabniki nevrnskih mrež so banke. Za napovedovanje finančne stiske podjetij je zelo znan Altmanov Z model (Altman, 1993. str. 244).

Tabela 2: Primeri uporabe nevrnskih mrež v ekonomiji

Področje	Primer uporabe
Finance	Trgovanje z vrednostnimi papirji Kreditna analiza strank Napovedovanje stečaja Preverjanje podpisov Napovedovanje dobičkonosnosti kreditnih kartic in izbiranje strank Napovedovanje prevzema podjetij Napovedovanje višine menjalniškega tečaja
Organizacija	Razporejanje dela Določanje optimalne poti vozil Napovedovanje zasedenosti letalskih linij
Človeški viri	Določanje potreb po osebju Ujemanje kandidatov z delovnimi mesti
Trženje	Analiza novega proizvoda Klasifikacija navad potrošnikov Napovedovanje prodaje Ciljno trženje Upravljanje s cenami letalskih prevozov

Vir: Miller, 1994, str. 132, Turban et al., 1998, str. 658.

5. NAPOVED PORABE ELEKTRIČNE ENERGIJE Z NEVRONSKO MREŽO

Zgradila sem model nevronske mreže in uporabila podatke za napovedovanje porabe električne energije. Za izdelavo modela sem uporabila orodje Enterprise Miner podjetja SAS Institute. Pristop k rudarjenju podatkov imenujejo v podjetju SEMMA, kar pomeni Sample – vzorčenje, Explore – raziskovanje, Manipulate – upravljanje, Model – modeliranje, Assess – ocenjevanje (Krašovec, 1996, str. 4).

Količina podatkov, ki jo želimo analizirati, je ponavadi velika, zato je smiselno vzeti pravilno vzorčno množico, ki bo pokazala takšne relacije med podatki, trende in vzorce, kot bi jih dobili, če bi vzeli celotno množico podatkov. Poznamo več vrst vzorčenja: od preprostega naključnega vzorčenja pa vse do stratifikacijskega vzorčenja. Pri metodologiji SEMMA razdelimo podatke v tri množice. Učna množica je namenjena za oblikovanje nevronske mreže, testna množica služi za ocenjevanje mreže, validacijska množica pa se uporablja za ocenjevanje in preprečuje generalizacijo. Pri ocenjevanju se mreža obnaša tako, kot da še ni videla podatkov v validacijski množici. Z brskanjem po podatkih in ugotavljanjem njihovih značilnosti in porazdelitev skušamo izbrati najbolj relevantne podatke za naš model. Nekatere je potrebno odstraniti, druge nadomestiti z drugimi vrednostmi. Lahko pa uvedemo nove spremenljivke (SAS, 2003). V fazi modeliranja izberemo model, ki ga uporabljamo, v mojem primeru bodo to nevronske mreže, lahko pa izbiramo med drevesi odločanja, regresijo, v kolikor pa imamo modul za časovne vrste, pa tudi tehnike časovnih vrst. Po izgradnji več modelov se na podlagi kriterija, ki ga izberemo kot ključnega za izbor modela, odločimo za najbolj primeren model.

5.1 OPREDELITEV PROBLEMA

Funkcije distribucijskega podjetja sem opisala v prvem poglavju, prav tako dejavnike, ki vplivajo na porabo električne energije, s katero trguje tovrstno podjetje. Podjetje mora obravnavani pojav čim bolj poznati, da ga bo lahko dobro napovedovalo. Stroški napak pri napovedovanju so visoki, zato morajo podjetja stalno delati na podatkih, ki so jim na voljo in jih zbirajo več let. Podjetje mora rezultate, dobljene z zgrajenim modelom, ovrednotiti in morebitno uporabo modela upravičiti. Distribucijsko podjetje se vsakodnevno srečuje z napovedjo porabe električne energije, katere napake stanejo podjetje od 2 do 3% celotnega nakupa električne energije mesečno, seveda odvisno od točnosti napovedi, zato je cilj podjetja zmanjšanje razlike med napovedano količino elektrike ter dejansko porabo električne energije (Pogovor z odgovornim za napovedovanje porabe električne energije v distribucijskem podjetju, 2003). In to bo tudi moj cilj rudarjenja podatkov – zgraditi nevronske mreže, ki bo napovedovala s čim nižjo vrednostjo MAPE, ki se po Evropi pojavlja kot merilo uspešnosti napovedovanja porabe električne energije (Ernst, 2002). Primerjala bom rezultate z različnimi vrstami nevronske mreže, spreminjala njihove parametre in se na koncu odločila za tisto, ki bo dala najnižjo MAPE. Pri tem ne bom segmentirala trga ali delala filtrov po mesecih, dneh, vrsti vremena, temveč bom upoštevala osnovne podatke, ki jih imam na voljo, in bazo, v kateri imam shranjene podatke. Moja napoved električne energije bo napoved porabe za trinajst ur

naprej, glede na to, da morajo distribucijska podjetja napovedati porabo za naslednji dan 13 ur vnaprej.

5.2 VZORČENJE

Distribucijsko podjetje mi je dalo podatke, ki jih uporablja pri napovedovanju porabe električne energije z nevronske mreže. Z analizo podatkov pa sem se ukvarjala sama. Podatki so ključnega pomena za izgradnjo modelov, saj se modeli na podlagi le-teh učijo in napovedujejo pojave. Zato je pomembno, da izberemo dovolj veliko količino podatkov za spremenljivke, ki vplivajo na napovedovan pojav. Kateri podatki so pomembni za model, vedo najbolje tisti, ki se s konkretnim pojavom ukvarjajo vsakodnevno, za model pa mora obstajati možnost zbiranja podatkov o vseh spremenljivkah, ki vplivajo na odvisno spremenljivko.

Podatke, ki sem jih uporabila pri izdelavi modela, zajemajo obdobje treh let, in sicer za vsako uro posebej. Podatki vključujejo poleg neodvisnih spremenljivk tudi višino porabe električne energije v določeni uri, sumirano po vseh odjemalcih. Po mnenju podjetja je osem spremenljivk, ki vplivajo na porabo električne energije. Spremenljivke so:

- datum,
- leto,
- mesec,
- dan,
- ura,
- temperatura,
- stopnja osvetljenosti ter
- tip dneva.

Za vzorec sem izbrala 2000 naključno izbranih vrstic izmed 26123 vrsticami.

Vzorec z 2000 vrsticami ponudi orodje samo. Poizkusila sem tudi z večjim vzorcem, primerjala sem rezultat, dobljen s celotno množico podatkov in različnimi velikostmi vzorca, vendar rezultat ni bil bistveno boljši ali slabši. Zato se pustila privzeto velikost vzorca. V nasprotju s teorijo pa pri meni čas učenja ni bil bistveno daljši, ko sem za učenje vzela celotno množico ali pa samo vzorec z 2000 vrsticami. Po občutku sodeč je bilo učenje pri pol urnem učenju mreže morda za nekaj minut daljše pri celotni množici kot pri vzorcu z 2000 vrsticami, pri učenju z algoritmom z vzvratnim širjenjem napake pa je bilo učenje pri celotni množici za kakšno tretjino daljše kot pri učenju mreže z manjšim vzorcem.

5.3 RAZISKOVANJE PODATKOV

Napovedana spremenljivka je poraba električne energije v določeni uri na določen dan v mesecu in letu.

Opis vhodnih spremenljivk

Datum je formata dan: mesec: leto.

Leto: 2000, 2001, 2002.

Mesec: meseci so označeni s številkami od 1 do 12, kakor si sledijo na koledarju.

Dan: Vrednost dneva poteka od 1 do 31, odvisno od števila dni v mesecu.

Ura: Vrednost ure zajema obdobje od 1 do 24, na vsako uro.

Temperatura: merjena v stopinjah Celzija.

Stopnja osvetljenosti.

Poraba elektrike je merjena v MWh.

Tip dneva opisuje tabela 3.

Tabela 3: Oznake za tip dneva

Dan v tednu	Tip dneva
Ponedeljek	2
Torek	3
Sreda	4
Četrtek	5
Petek	6
Sobota	7
Nedelja	1
Praznik	8

Vir: Podatki distribucijskega podjetja, 2003.

V tabeli 4 vidimo nekaj podatkov o spremenljivkah, ki se pojavljajo kot vhodi v mrežo.

Tabela 4: Statistični podatki za nekatere spremenljivke

Spremenljivka	Minimalna vrednost	Maksimalna vrednost	Povprečna vrednost	Standardni odklon
Poraba	115.731	349298.905	227.004	53.295
Temperatura	-13,3	34,5	11,479	8,6952
Osvetljenost	0	961	143,33	233,77

Vir: Zasnovala na podlagi podatkov.

5.3.1 Porazdelitev porabe od drugih spremenljivk


Poglejmo porazdelitev porabe v odvisnosti od spremenljivk, kjer F9 predstavlja porabo električne energije, F2 leta, F3 mesece, F4 dneve, F5 ure, F6 temperaturo, F7 osvetljenost in F8 pomeni tip dneva. S porazdelitvami lahko ugotovimo, kje so posebnosti in kje ni razlik v porabi električne energije. Za tiste segmente, kjer je poraba električne energije približno enaka, bi bilo dobro narediti svoje modele, saj se mreža bolje nauči na podatkih, kjer ni izrazitih nihanj.

Spodnje porazdelitve kažejo povprečja vseh treh let.

Porazdelitev vrednosti porabe po posameznih letih

Na sliki 17 lahko vidimo naraščajoč trend porabe elektrike po letih.

Slika 17: Odvisnost porabe električne energije od let

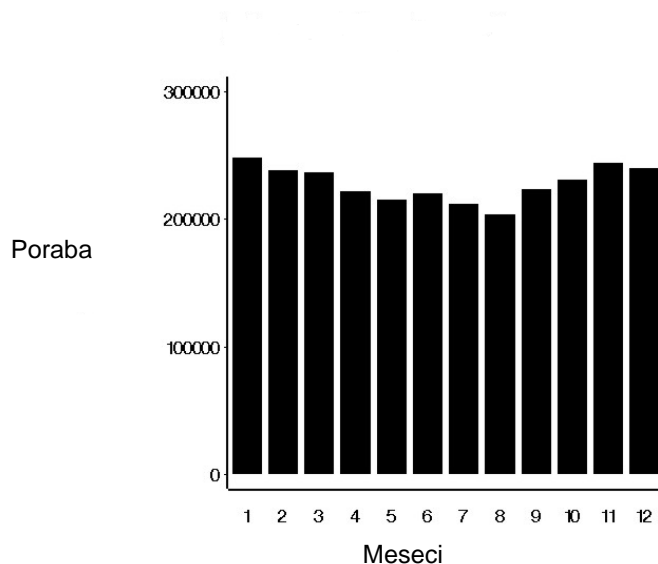


Vir: Zasnovala sama.

Porazdelitev vrednosti porabe po posameznih mesecih

S slike 18 vidimo, da se največ elektrike porabi v zimskih mesecih, zato bi veljalo razviti posebej model za zimske mesece in posebej mesece, ko je poraba manjša. Z učenjem mreže s podatki z manjšimi odkloni bi lahko dobili boljše rezultate (Ernst, 2002).

Slika 18: Porazdelitev vrednosti porabe po posameznih mesecih

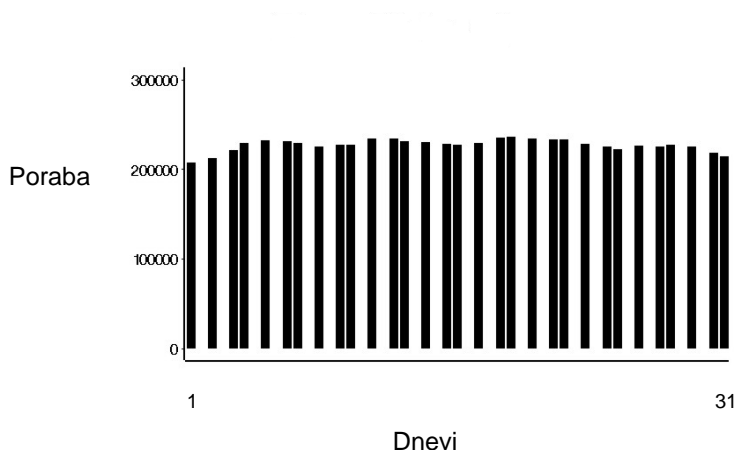


Vir: Zasnovala sama.

Porazdelitev vrednosti porabe po posameznih dnevih

Kot vidimo na sliki 19, na podlagi dneva v mesecu ne moremo sklepati na porabo električne energije.

Slika 19: Porazdelitev vrednosti porabe po posameznih dnevih




Vir: Zasnovala sama.

Porazdelitev porabe po posameznih urah

Poraba elektrike je večja v času delovnih ur, kar je v Sloveniji od sedme ure dalje. V nočnih urah je poraba elektrike najnižja, saj večina podjetij in gospodinjstev ne uporablja elektrike v nočnem času. To nam lepo pokaže slika 20.

Slika 20: Porazdelitev porabe po posameznih urah




Vir: Zasnovala sama.

Porazdelitev porabe v odvisnosti od temperature

Na sliki 21 lahko vidimo, da razen pri zelo nizkih temperaturah ni večjih razlik porabe električne energije. To pomeni, da glede na temperaturo ne moremo sklepati na količino porabljene električne energije.

Slika 21: Porazdelitev porabe v odvisnosti od temperature

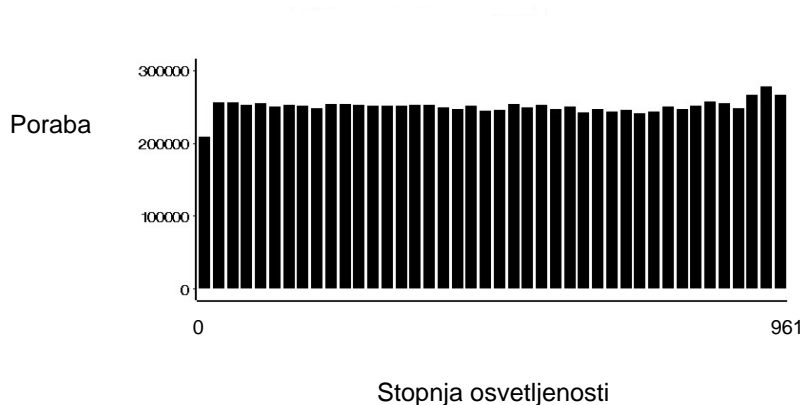


Vir: Zasnovala sama.

Porazdelitev porabe v odvisnosti od osvetlitve

S slike 22 sklepamo, da nam podatek o osvetljenosti ne pove nič novega o porabi elektrike. V večernih urah gospodinjstva prižigajo luči, čez dan uporabljajo elektriko tovarne. Porabo električne energije bi morali gledati ločeno po odjemalcih, da bi ugotovili vpliv osvetljenosti na porabo elektrike.

Slika 22: Porazdelitev porabe v odvisnosti od osvetlitve



bi bilo zanimivo razviti dva modela za napovedovanje porabe elektrike v odvisnosti od tipa dneva. Enega posebej za vikend in praznik, drugega za delovne dni.

5.4 UPRAVLJANJE S PODATKI

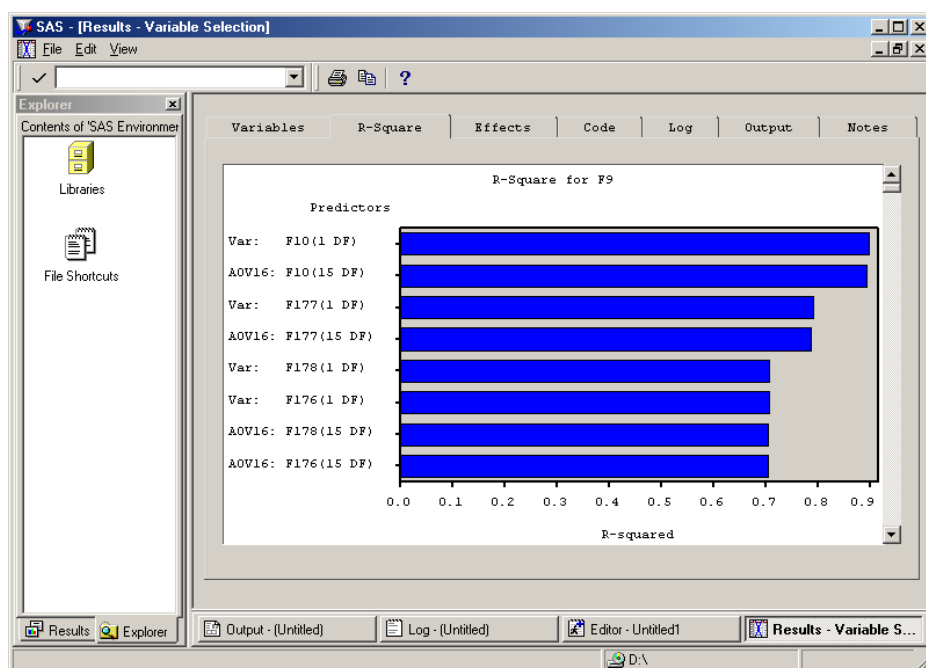
Med podatki ni bilo manjkajočih vrednosti, tako da jih ni bilo treba nadomeščati, sem pa izvedla izbor spremenljivk, ki sem jih želela vključiti v model.

Izbor spremenljivk

Vse spremenljivke, s katerimi razpolagamo, niso vedno primerne za vključitev v model. Zaradi krajšega časa učenja mreže je koristno izključiti spremenljivke, ki ne vplivajo na model po kriteriju, ki nam ga ponuja orodje. V mojem primeru sem izbrala determinacijski koeficient. Determinacijski koeficient pokaže delež pojasnjene variance. Čim večji je vpliv pojasnjevalne spremenljivke na odvisno spremenljivko, tem večja je pojasnjena varianca (Arh et al., 1998, str. 187).

Po izvedbi izbora spremenljivk so za model ostale relevantne samo spremenljivke F10 in F176, F177, F178. F176 pomeni vrednost porabe 167 ur nazaj, F177 vrednost porabe 168 ur nazaj, kar je en teden nazaj. F178 pomeni porabo električne energije 169 ur nazaj, kar je poraba energije pred tednom dni in uro. Spremenljivke F10 ne moremo vključiti v model, ker s tem podatkom distribucijsko podjetje v trenutku odločitve nakupa električne energije še ne razpolaga. F10 pomeni porabo električne energije eno uro nazaj. Na sliki 24 lahko vidimo vrednosti determinacijskega koeficienta za vsako od vključenih spremenljivk. R-Square pomeni determinacijski koeficient.

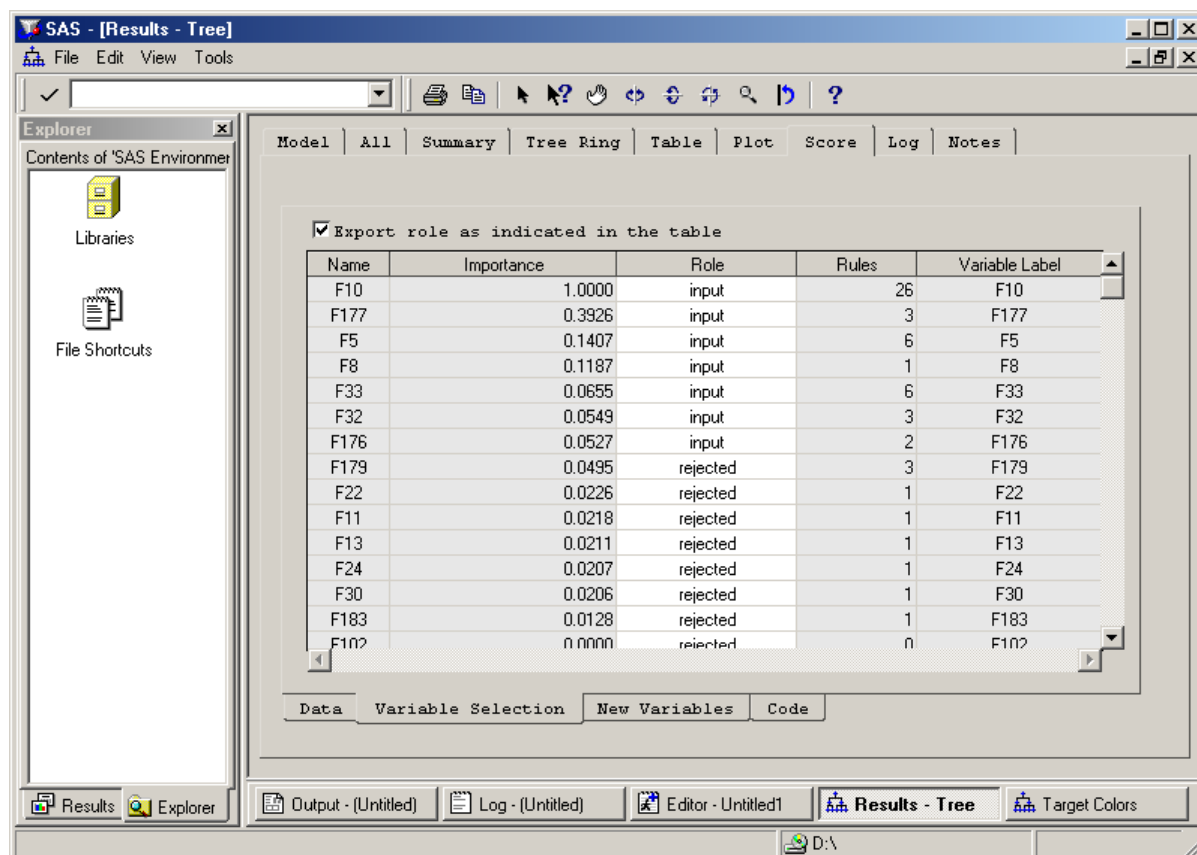
Slika 24: Vrednosti determinacijskega koeficienta po izvedbi izbire spremenljivk



Vir: Zasnovala sama.

Zanimalo me je, katere spremenljivke izloči odločitveno drevo, zato sem izvedla izbiro spremenljivk z odločitvenim drevesom.

Slika 25: Okno spremenljivk, ki jih drevo odločanja vključi oziroma izključi iz modela

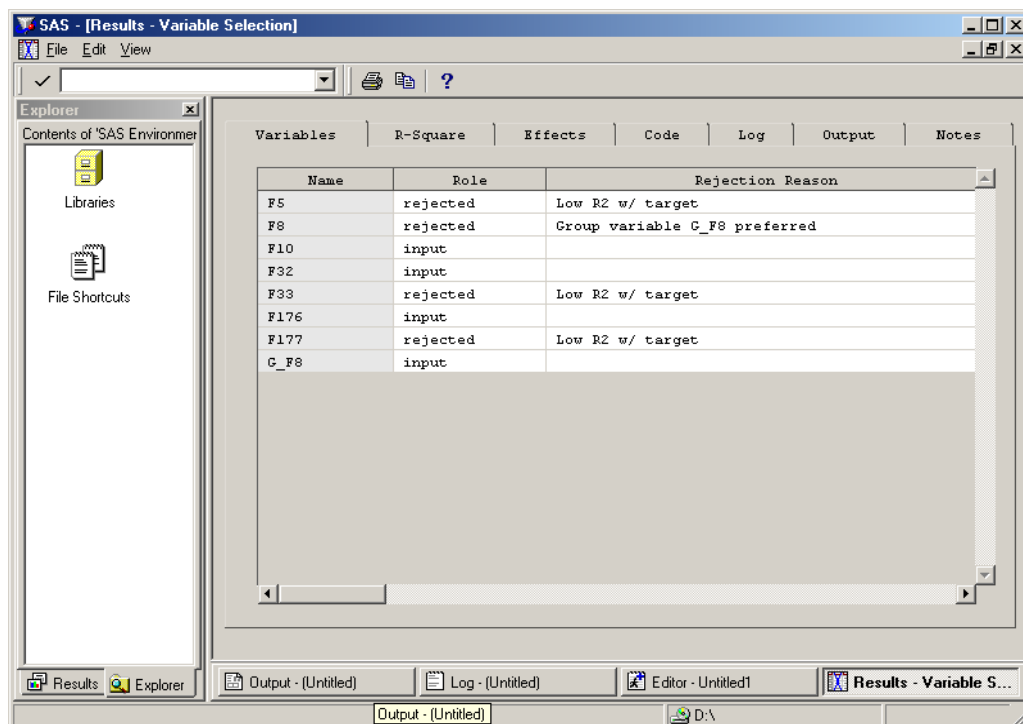


Vir: Zasnovala sama.

S slike 25 lahko vidimo rezultate, ki nam jih da odločitveno drevo. Spremenljivk, pri katerih piše pod »role« »rejected, ne vključimo v model. Drevo je zavrnilo spremenljivke, ki jih podjetje zdaj upošteva pri napovedi, razen spremenljivke ura in tip dneva. Sprejelo pa je vrednost porabe električne energije eno uro nazaj, 23, 24 ur nazaj, en teden nazaj ter šest dni in 23 ur nazaj.

Nato sem izvedla nadaljnji izbor že izbranih spremenljivk glede na velikost determinacijskega koeficienta. Izbor je iz modela izločil spremenljivke F5 in F8, zavrnil je tudi vrednost porabe električne energije 24 ur pred napovedjo ter spremenljivko F177, torej vrednost porabe šest dni in 23 ur nazaj.

Slika 26: Vključenosti in izključenosti iz nadaljnega izbora spremenljivk



Vir: Zasnovala sama.

V model sem po izvedbi izbire spremenljivk vključila vrednost porabe električne energije 23, 24, 167, 168, 169 in 170 ur nazaj, prav tako pa sem v model vključila sedem spremenljivk, ki po mnenju distribucijskega podjetja vplivajo na vrednost porabe električne energije, nisem pa vključila datuma kot vhodne spremenljivke. Glede na dane rezultate izbora spremenljivk bi bilo v model dobro vključiti še spremenljivke za več tednov nazaj v isti uri ter uri prej in dve uri kasneje, vendar bi z vključitvijo teh podatkov dobila premajhno količino podatkov za učenje mreže. Če bi želela vključiti v mrežo vpliv gibanja porabe električne energije za leto nazaj, bi mi ostalo podatkov samo še za dve leti. Hkrati pa sem bila v bazi omejena z 256-imi stolpci.

Rezultati izbora spremenljivk so zelo podobni ugotovitvam iz porazdelitev gibanja porabe v odvisnosti od neodvisnih spremenljivk, kjer se je dalo največ sklepati o porabi električne energije v odvisnosti od ure in tipa dneva, ti dve spremenljivki pa je drevo odločanja vključilo v model.

5.5 MODELIRANJE IN OCENJEVANJE REZULTATOV

5.5.1 Izbor spremenljivk za učno, testno in validacijsko množico

Orodje Enterprise Miner kot privzeto vzame naključni vzorec podatkov in jih razdeli v učno, validacijsko in testno množico. Lahko izbiramo, kakšen odstotek podatkov bomo vključili v posamezno množico. Za model sem izbrala 40% za učno množico, 30% za validacijsko in 30% za testno množico podatkov ter pustila privzeto nastavitve naključnega jemanja podatkov v vzorec. Poizkusila sem tudi z določanjem drugačnih deležev učne, validacijske in testne

množice, vendar so bile napovedi prej slabše kot boljše. Izrazito slabše so bile pri zelo veliki razliki v deležu med učno in validacijsko množico. Bolje je, da je velikost učne in validacijske množice čim bolj enaka (Pogovor z Janezom Jamškom, 2003). Ker nisem ugotovila, kolikšen odstotek bi bil boljši od privzetih 40% za učno ter 30% za validacijsko, sem pustila zgoraj omenjene deleže jemanja podatkov v množice.

5.5.2 Zasnova nevronske mreže

Za arhitekturo nevronske mreže sem izbrala večplastni perceptron, ker je od vseh arhitektur mrež še najbolj razumljiv. Izbirala sem sicer med linearnim modelom, radialno zasnovano mrežo in njenimi štirimi tipi arhitekture. Radialno zasnovane mreže potrebujejo več skritih nevronov kot večplastni perceptron in rabijo zelo veliko učno množico. Moja učna množica ni bila zelo velika, prav tako pa pri mojem številu vhodov nisem smela preseči števila skritih nevronov 27, kar pa za tako mrežo ne zadostuje. Zato nisem izbrala take arhitekture.

Za učni algoritem se je najbolje obnesel Levenberg-Marquardt algoritem, ki je glede na število nevronov najbolj primeren za učenje, medtem ko je dal algoritem z vzratnim širjenjem napake zelo slabe rezultate. Učenje pri učnem algoritmu z vzratnim širjenjem napake, algoritmu s hitrim vzratnim širjenjem napake in inkrementalnim vzratnim širjenjem napake je bilo daljše kot pri ostalih učnih algoritmih, zato se tudi zaradi zamudnosti dela nisem odločila za te učne algoritme.

Aktivacijska funkcija med skritimi nevroni je hiperbolični tangens. Aktivacijska funkcija je bila v vseh plasteh nevronske mreže enaka in je nisem spreminjala, ker rezultati z različnimi kombinacijami aktivacijskih funkcij po plasteh niso bili boljši. Aktivacijska funkcija na izhodnem nivoju je eksponentna zaradi pozitivne, v neskončnost neomejene vrednosti napovedne spremenljivke.

Maksimalno število ponavljanj sem določila na 150, minimalnega števila pa nisem določala. Pokazalo se je, da pri učenju z določenimi učnimi algoritmi število 150 ni bilo dovolj visoko, saj mreža pri tem številu ponavljanj še ni ustavila učenja. Vendar je za mojo končno izbrano arhitekturo in učni algoritem takšno število ponavljanj zadostovalo.

Pri izbiri števila skritih nevronov in števila skritih plasti sem za kriterij izbrala MAPE, ki sem jo uvedla kot novo spremenljivko in za vsako mrežo posebej računala. Izračunala sem razliko dejanske porabe in napovedi in vse skupaj delila z dejansko porabo. Rezultat sem pomnožila s 100. Pri izbiri se je pokazalo, da število skritih plasti ne izboljšuje napovedi, bolj pomembno je število skritih nevronov, ki pa ne sme biti večje od $2 \cdot n - 1$, kjer je n število vhodnih spremenljivk (SAS Institute Inc., 1997, str. 122). Za končni model sem izbrala mrežo s petimi skritimi plastmi, in sicer v prvi plasti 7 nevronov, v drugi pet, tretji pet, četrti tri in v zadnji skriti plasti tri nevrone, kar skupaj znese 23 nevronov pri 13 vhodih. V primeru učenja mreže s samo tremi nevroni je bil rezultat za 2 odstotka slabši, pri učenju s štirimi skritimi plastmi in 17 nevroni je bil rezultat od končnega slabši za 0,5 odstotka. Pri učenju z algoritmom z vzratnim širjenjem napake in majhnim številom nevronov pa je napaka napovedi znašala 8 odstotkov.

Pri izbiri končnega modela nevronske mreže je bilo potrebno iti skozi veliko učenj mreže, računanja MAPE, ki je moj končni kriterij izbire mreže, ter nastavljanja parametrov mreže. Kriterijska funkcija je bila povprečje kvadrata napake. Pri izbiri arhitekture mreže pa sem si pomagala z uporabo validacijske množice, kjer ob vsaki predstavitvi učne množice mreža računa tudi stroškovno funkcijo validacijske množice. Ta sprva pada, nato pa začne lahko naraščati, kar je znak generalizacije.

Slika 27: Podatki o mreži

	Fit Statistic	Training	Validation	Test
1	[TARGET=F9]	.	.	.
2	Average Profit	0.4796373081	0.4752908899	0.4724097744
3	Average Error	209701695.73	235866183.29	248501346.46
4	Average Squared Error	209701695.73	235866183.29	248501346.46
5	Sum of Squared Errors	2.1915924E12	1.8487191E12	1.9480021E12
6	Root Average Squared Error	14481.080613	15357.935515	15763.925477
7	Root Final Prediction Error	14793.44123	.	.
8	Root Mean Squared Error	14638.094124	15357.935515	15763.925477
9	Error Function	2.1915924E12	1.8487191E12	1.9480021E12
10	Mean Squared Error	214273799.57	235866183.29	248501346.46
11	Maximum Absolute Error	128003.69886	140065.85039	144524.00872
12	Final Prediction Error	218845903.42	.	.
13	Divisor for ASE	10451	7838	7839
14	Model Degrees of Freedom	223	.	.
15	Degrees of Freedom for Error	10228	.	.
16	Total Degrees of Freedom	10451	.	.
17	Sum of Frequencies	10451	7838	7839
18	Sum Case Weights * Frequencies	10451	7838	7839
19	Akaike's Information Criterion	200699.66548	.	.
20	Schwarz's Bayesian Criterion	202317.40849	.	.

Vir: Zasnovala sama.

S slike 27 lahko vidimo nekaj kriterijev, na podlagi katerih sklepamo na prileganje mreže. V šesti, sedmi, osmi in dvajseti vrstici so kriteriji, ki me zanimajo. To je primer rezultatov, ko prileganje mreže ni najboljše. Ko so ti kriteriji blizu želenim, je prileganje mreže dobro.

Kriteriji so (SAS Institute Inc., 1997, str. 26):

- »Root Mean Squared Error«, kar v prevodu pomeni celotno napako (Arh et al., 2001, str. 330),
- »Root Average Squared Error«, kar je v dobesednem prevodu koren povprečne kvadratne napake,


- »Root Final Prediction Error«, kar je koren končne napake napovedi ter
- »Schwarz's Bayesian Criterion« (SBC), kar je Schwarz Baysijanov kriterij.

Bolj kot so prvi trije kriteriji proti 0 ter bolj kot je SBC negativen, bolj se mreža prilega.

Kako dobro mreža napoveduje, se lahko vidi že med samim učenjem, vendar gre samo za grobo oceno natančnosti napovedi, in sicer iz napake učenja, ki pada, in jo lahko spremljamo vse do maksimalnega števila ponavljanj, ki ga že prej določimo, razen če učenja prej ne ustavimo kot v mojem primeru na sliki.


Pri ločenem učenju mrež se na grafu pojavita dve liniji. Zgornja linija na spodnjih dveh slikah je linija rdeče barve in je linija napake validacijske množice, medtem ko je modra črta linija napake testne množice in je spodnja linija. Idealno je, da se čim bolj približata druga drugi. Mrežo moramo namreč dobro naučiti. Ne smemo je naučiti ne premalo ne preveč. V obeh primerih nam daje slabe napovedi. Če mrežo premalo naučimo, pomeni, da je sposobna ugotavljati samo globalne trende, ne pa finih, dnevnih trendov. V primeru, da mrežo naučimo preveč, pomeni, da njena napoved vsebuje tudi dnevne trende, ki pa vsebujejo šum. Šum pomeni, da se mreža predobro nauči vseh vplivov pojavov stohastične narave, ki pa se jih ne sme naučiti. Ko se liniji validacijske in testne množice čim bolj približata druga drugi in sta na minimumu, je potrebno učenje ustaviti. To na sliki 28 vidimo kot navpično črto pri 96-em ponavljanju. Pri tem številu ponavljanj je učenje mreže končano, saj bi z nadaljnjim učenjem mrežo ali preveč naučili ali pa bi se začela linija napake učenja validacijske množice oddaljevati od linije napake učne množice. Primer tega lahko vidimo na sliki 29.

Slika 28: Povprečna napaka učenja



Vir: Zasnovala sama.

Slika 29: Napaka učenja, kjer se linija napake učenja validacijske množice oddaljuje od linije napake učenja testne množice



Vir: Zasnovala sama.

5.5.3 Končni rezultati napovedovanja

Rezultat, ki smo ga dobili z zgoraj opisano mrežo, znaša 4,35%. To pomeni, da nevronska mreža napoveduje porabo električne energije za 13 ur vnaprej s povprečno napako 4,35 odstotka oziroma je njena natančnost 95,65 odstotna.

Za boljšo predstavbo o tem, kako mreža napove, si lahko pogledamo tabelo 5, kjer prvi stolpec predstavlja dejansko porabo električne energije, drugi porabo energije, ki jo je napovedala mreža, tretji stolpec je absolutna vrednost razlike med porabama, zadnji stolpec pa je absolutna vrednost relativne napake napovedi.

Tabela 5: Primerjava napovedovane vrednosti porabe električne energije in dejanske vrednosti porabe električne energije

Dejanska poraba	Napoved porabe	ABS(Dejanska poraba-Napoved porabe)	ABS((Dejanska poraba-Napoved porabe)/Dejanska poraba)
225666	237584	11918	0,052813
247779	274083	26304	0,106159
245133	267525	22392	0,091346
240156	249605	9449	0,039345
229068	240104	11036	0,048178
211176	228279	17103	0,080989
209412	232661	23249	0,11102
183204	195011	11807	0,064447
173565	172683	882	0,005082
161280	171593	10313	0,063945
156114	162577	6463	0,041399
152460	162470	10010	0,065657
151830	163129	11299	0,074419
155421	167822	12401	0,07979
166698	179601	12903	0,077403
180117	202435	22318	0,123908
200970	210118	9148	0,045519
225729	219551	6178	0,027369
240425	217601	22824	0,094932
250425	219057	31368	0,125259
241290	218190	23100	0,095735
228123	215532	12591	0,055194

Vir: Zasnovala sama.

Izračun MAPE pa je viden na sliki 30 v osenčeni vrstici. Ime spremenljivke je MAPE, pod »Mean« je izračunano povprečje napak, ki smo jih dobili z napovedovanjem.

Slika 30: Izračun MAPE

Name	Keep	Role	Formula	Mean	Std Dev	Skew	Kurtosis
MAPE	Yes	input	ABS((F9-P_F9)/F9)	0.0435149605	0.0569943548	4.3890796782	30.668034068
F1	Yes	rejected		1309924791.2	27153537.546	-1.957768E-6	-1.199998368
F3	Yes	input		6.5590936926	3.43064278	-0.013549802	-1.202627477
F4	Yes	input		15.810471525	8.778022464	-0.003089262	-1.187275318
F5	Yes	input		12.502449479	6.9218467522	-0.000472612	-1.203956353
F6	Yes	input		11.554634874	8.5001408239	-0.017506121	-0.447197821

Vir: Zasnovala sama.

Napaka, s katero napoveduje model, je približno dvakrat večja kot napaka, s katero napovedujejo distribucijska podjetja. Podjetje dela napovedi ločeno po odjemalcih, jaz pa sem razpolagala s podatki, ki so bili zbrani za vse odjemalce skupaj. Povprečna napaka napovedovanja modelov, ločenih po odjemalcih v podjetju, znaša od 2 do 3% (Pogovor z odgovornim za napovedovanje porabe električne energije v distribucijskem podjetju, 2003). Podjetje samo z uporabo orodij za rudarjenje podatkov dobi napoved, ki jo po lastni presoji popravi. Lastna presoja je potrebna v primeru posebnih dogodkov, kot so športni dogodki, v času mehiških nadaljevanj je potrebno povečati količino električne energije, ki jo bodo kupili, kajti mreže se v prejšnjih letih tega niso mogle naučiti, ker se šele v zadnjem času kaže povečana gledanost teh nanizank. Taki trendi, ki se pojavljajo v zadnjih letih, opozarjajo na pazljivost pri izboru količine podatkov, torej, za koliko časa nazaj še vključiti podatke v učno množico. Način življenja ljudi se spreminja in to je potrebno pri napovedovanju tudi upoštevati. Prav tako je rezultat odvisen od definicije problema. Ker nisem dobro poznala načina kupovanja električne energije, sem najprej naredila model, ki je napovedoval z 1,2 odstotno napako. Model je bil narejen tako, kot da podjetje kupuje elektriko za vsako uro vnaprej in ne 13 ur prej. Razpolaga torej s podatki vse do časa nakupa električne energije, kar pa ni res. Spremenjen način kupovanja elektrike, ki je znan po svetu, bi zmanjšal odhodke distribucijskih podjetij na račun napačne napovedi porabe električne energije (Lewis, 2003).

Podjetje se za uporabo takega orodja in izdelavo modela odloči, če se jim investicija povrne v manj kot enem letu (Pogovor z zaposlenim v SAS Institute, 2003). V konkretnem podjetju to pomeni, da se jim z uporabo modela, ki izboljša sedanjo napoved za en odstotek, povrne investicija v orodje in izobraževanje zaposlenih v pol leta. Vendar naj bi podjetje, če se odloči za nakup takega orodja, uporabljalo orodje tudi na drugih področjih v podjetju in ne samo za napovedovanje porabe električne energije. Za vključitev omenjenega orodja v podjetje pa je potrebnih nekaj mesecev, da se zaposleni, ki bodo to orodje uporabljali v podjetju, naučijo njegove uporabe. Podjetje običajno samo ne naredi modela, temveč model, ki ga potem uporabljajo, naredi zunanji strokovnjak. Zaposleni, ki se potem vsakodnevno ukvarjajo z uporabo tega orodja, morajo poznati problem, ki ga obdelujejo, in morajo imeti čim več znanja statistike. Več kot imajo teh znanj, manj je potrebnih zunanjih svetovanj.

6. SKLEP

Podjetja se z odprtostjo trgov srečujejo z vse večjo konkurenco, ki spreminja trge in jih sili v razvoj izdelkov in izboljšanje storitev. Tako se tudi podjetja v energetskega sektorja srečujejo na borzi, kjer kupujejo elektriko. Količina elektrike, ki jo kupijo, pa je določena vnaprej, želene količine od enajste ure dopoldan dalje ne morejo več spreminjati. Njihove napovedi morajo biti zato čim boljše. Z uporabo rudarjenja podatkov podjetja napovedujejo porabo elektrike. Lahko z metodo časovnih vrst, regresije, nevronske mreže, obenem pa sami napoved popravijo, če vedo, da bodo kakšni izredni dogodki, ki jih modeli ne morejo predvidevati, vplivali na veliko spremembo porabe električne energije.

Sama sem naredila model za napovedovanje porabe električne energije za trinajst ur vnaprej s podatki, ki jih v enem od slovenskih distribucijskih podjetij uporabljajo za napoved porabe električne energije.

Uporabila sem podatke za tri leta. Poleg sedmih vhodov, ki jih uporabljajo v podjetju pri napovedovanju energije, sem dodala še šest dodatnih, ki so vrednosti porabe električne energije v predhodnih dneh. Z vključitvijo teh šestih spremenljivk sem želela vključiti vpliv časovne vrste vrednosti porabe električne energije v nevronske mreže.

Poleg izbire arhitekture nevronske mreže ter učnih algoritmov sem ugotavljala vpliv skritih plasti in število skritih nevronov ter ugotovila, da v primeru napovedi z izbranimi spremenljivkami večanje števila skritih plasti ne izboljša natančnosti modela. Bistveno je bilo število skritih nevronov. Poleg tega pa se čas učenja mreže z dodajanjem skritih nevronov povečuje in je ob dobri strojni opremi povprečnega uporabnika računalnika učenje mreže zelo zamudno delo.

Rezultati mreže niso toliko odvisni od parametrov, ki se nastavljajo, temveč od podatkov, s katerimi se mreža uči. Več kot je podatkov in boljše kot so pripravljene, boljše so napovedi mreže. Priprava podatkov vzame večino celotnega časa od začetka priprave podatkov do izgradnje končnega modela, kajti orodja za napoved omogočajo precej enostavno izgradnjo modela. Podatkov mora biti veliko. V mojem primeru se je izkazalo, da bi za izgradnjo boljšega modela potrebovala podatke za več kot tri leta, vendar je pri tem treba opozoriti na spreminjajoč način življenja ljudi skozi leta, ki vpliva na različno porabo električne energije. Pri izdelavi modela je pomembna pravilna definicija problema. Sama sem na začetku naredila popolnoma drug model, ker nisem bila dobro seznanjena z načinom kupovanja elektrike. Zato se velja tej fazi rudarjenja podatkov, da se izognemo nepotrebnemu ponavljanju dela, še posebej posvetiti.

Z nevronske mreže se da napovedovati porabo električne energije in ob dobri pripravi podatkov dobiti zelo dobre rezultate. Vendar je za to potrebno segmentirati kupce, narediti ločene urne modele, modele za različne tipe dni, vremena, pri vsem tem pa upoštevati še vse dejavnike, ki pa v mrežo niso vključeni. Dejavnike, kot so športni dogodki, bi lahko vključili v mrežo kot vhode, tako da ne bi bilo treba po občutku popravljati napovedi nevronske mreže. To bi bilo vredno poizkusiti in videti, koliko boljše rezultate bi dobila.

Z modelom, kot sem ga naredila, dobimo malo manj kot dvakrat večjo napako, kot jo imajo slovenska distribucijska podjetja. Z večjo bazo podatkov in boljšim poznavanjem dejavnikov, ki vplivajo na porabo elektrike, ter njihove medsebojne odvisnosti pa bi bilo mogoče z obstoječimi orodji narediti zelo dobre modele, ki bi podjetjem prihranili precej sedanjih odhodkov. Kajti imeti orodje in ne znati z njim ravnati, nič ne prispeva k uspešnosti podjetja. Prav tako je treba imeti prave podatke in jih dobro poznati, šele nato pa se lotiti iskanja povezav med njimi. Ravno podatki sami in njihova analiza je področje, ki se mi zdi zanimivo za obdelavo. Da bi ugotovila, koliko podatkov in kateri so ključni za mrežo, je po moji oceni ključ do uspešnega modela napovedovanja. To pa pomeni boljše razumevanje elektro panoge.

7. LITERATURA

1. Altman Edward I.: Corporate Financial Distress and Bankruptcy. New York: John Wiley & Sons, 1993. 356 str.
2. Arh Franc et al.: Statistika 1. Ljubljana: Ekonomska fakulteta, 1998. 252 str.
3. Bauer Gregor: Odkrivanje znanja v sistemih. Seminarska naloga. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko, 2002. 17 str.
4. Berry Michael J.A. et al.: Mastering Data Mining. New York: John Wiley& Sons, Inc, 2000. 494 str.
5. Berson Alex et al.: Building Data Mining Applications for CRM. New York: McGraw-Hill, 2000. 510 str.
6. Bigus Joseph: Data mining with Neural Networks, Solving Busines Problems From Application Development to Decision Support. New York: McGrow- Hill, 1996. 220 str.
7. Bregar Andrej: Aplikacija nevronske mreže v sistemih za podporo odločanju. Individualno raziskovalno delo. Maribor: Fakulteta za računalništvo in informatiko, 2001. 16 str.
8. Bregar Andrej: Aplikacija nevronske mreže v sistemih za podporo odločanju. Portorož: ERK, 2001, str. 211.
9. Breiman L.: Classification and regression Trees. Balmont: wadsworth, 1984. 74 str.
10. Dobnikar Andrej: Nevronske mreže. Radovljica: Didakta, 1990. 157 str.
11. Godnov Uroš: Uravnavanje odnosov s kupci z uporabo rudarjenja po podatkih. Magistrsko delo. Ljubljana: Ekonomska fakulteta, 2002. 100 str.
12. Golob Robert et al.: Elektrotehniški vestnik 68 (5): 277–285. Ljubljana, 2001, str. 279-280.
13. Hopfield J.J.: Neural Networks and Physical Systems With Emergent Collective Computational Abilities. Proc. Nat. Acad. Sci., 1982, 79, str. 2554-2558.
14. Hrovatin Nevenka: Problematika določanja cen v naravnomonopolnih javnostoritvenih panogah. Slovenska ekonomska revija, Ljubljana, 45 (1994), 5, str. 434.
15. Jamšek Janez: Predikcija vrednosti delnice z nevronske mreže. Diplomsko delo. Ljubljana: Ekonomska fakulteta, 2000. 25 str.
16. Kononenko Igor: Strojno učenje. Ljubljana: Fakulteta za računalništvo in informatiko, 1997. 309 str.

17. Krašovec Janez: Izkop podatkov z metodologijo SEMMA. Diplomsko delo. Ljubljana: Fakulteta za elektrotehniko, 1996. 67 str.
18. Kumer Slavko: Stohastični modeli in nevronske mreže pri ravnanju z zalogami. Diplomsko delo. Ljubljana: Ekonomska fakulteta, 1997. 55 str.
19. Miller Mark, Neurale Netzwerke für Finanzdienstleister: Aufgezeigt am Beispiel von Wechselkursprognosen. Doktorska disertacija. Mannheim, Fakultät für Betriebswirtschaftslehre, 1994. 146 str.
20. Pivk Aleksander: Rudarjenje podatkov. Ljubljana: Inštitut Jožefa Štefana, 2001. 15 str.
21. Pogačnik Sandi: Uporaba podatkovnega rudarjenja v trgovini na debelo in drobno. Magistrsko delo. Ljubljana: Ekonomska fakulteta, 2001. 104 str.
22. Šušteršič Maja: Nevronske mreže v ekonomiji na primeru kreditnega tveganja fizičnih oseb. Magistrsko delo. Ljubljana: Ekonomska fakulteta, 2002. 90 str.
23. Taranenko Andrej: Genetski algoritmi. Diplomsko delo. Maribor: Pedagoška fakulteta Maribor, 2001. 52 str.
24. Turban Efraim et al.: Decision Support Systems and Intelligent Systems. Fifth edition. London: Prentice-Hall Internatioanl, 1998. 890 str.

8. VIRI

1. Poročilo o delu agencije za energijo RS in stanju na področju energetike v letu 2001. Maribor: Agencija za energijo RS, 2002. 48 str.
2. Arh Franc et al.: Statistični terminološki slovar. Ljubljana: Narodna in univerzitetna knjižnica, 2001. 403 str.
3. Borzen. [URL: <http://www.borzen.si/>], 3.4.2003.
4. Edelstein Herb: Building Profitable Customer Relationship With Data Mining. Two Crows corporation, 2002. 19 str.
5. Ernst: Prosojnice o napovedovanju v elektro sektorju, SAS, 2002.
6. Elektro Slovenija d.o.o: Upravljanje omrežja. [URL: <http://www.eles.si/>], 8.4.2003.
7. Lewis Nigel: Accurate demand forecasting to facilitate operational and strategic decision-making in the energy sector, 8.4. 2003.
8. Matlab 5.3.0.10183, Release 11, Windows Version, MathWorks, 1997, Neural Network Toolbox, str. 46-418.

9. Neural networks. [URL: <http://documents.wolfram.com/applications/neuralnetworks/>], 21.3. 2003.
10. Podatki distribucijskega podjetja, 2003.
11. Pogovor z Janezom Jamškom, 7.3.2003.
12. Pogovor z odgovornim za napovedovanje porabe električne energije v distribucijskem podjetju, 18.3.2003.
13. Pogovor z zaposlenim v SAS Institute, 12.5.2003.
14. Pravila za delovanje trga z električno energijo (Uradni list RS, št. 79/99 in 8/00).
15. SAS Enterprise Miner Help, 1999-2001.
16. SAS Institute Inc.: The SAS Neural Network Application User's Guide. NC: SAS Institute Inc., 1997. 153 str.
17. SAS: SEMMA.
[URL: <http://www.sas.com/technologies/analytics/datamining/miner/semma.html>],
2.6.2003.

ANGLEŠKO SLOVENSKI SLOVARČEK IZRAZOV

Assess	ocenjevanje
CRM – Customer Relationship Management	ravnanje odnosov s strankami
Explore	raziskovanje
Manipulate	upravljanje
MAPE – Mean Average Percentage Error	aritmetična sredina povprečne napake strukturnega odstotka – absolutna vrednost relativne napake
Model	modeliranje
MWh – Mega Watt hour	mega vatna ura
Root Average Squared Error	koren povprečne kvadratne napake
Root Final Prediction Error	koren končne napake napovedi
Root Mean Squared Error	celotna napaka
R-Square	determinacijski koeficient
Sample	vzorčenje
SBC – Schwarz's Bayesian Criterion	Schwarz Baysijanov kriterij