

BUSINESS INTELLIGENCE AND PRODUCTION SYSTEMS

POSLOVNA INTELIGENCIJA I PROIZVODNI SUSTAVI

CORIC, Ivica; GASPAR, Drazena & MABIC, Mirela

Abstract: *This work analyses development of model of customer profitability in production systems which is based on combination of business intelligence methods – neural networks and genetic algorithm. General framework for defining customer profitability, besides pure financial items, has to include a lot of non-linear and non-financial elements. Data mining, as one of the techniques of business intelligence, can identify and adopt patterns and rules that exist in historical data stored in data bases and/or data warehouses.*

Key words: *business intelligence, product system, neural network, genetic algorithm*

Sažetak: *U radu se analizira razvoj modela pra enja profitabilnosti kupaca za proizvodne sustave koji se temelji na kombinaciji metoda poslovne inteligencije – neuralnih mreža i geneti kog algoritma. Op i okvir definiranja profitabilnosti kupaca, pored istih financijskih, mora sadržavati i veliki broj nefinancijskih i nelinearnih elemenata. Rudarenje podataka, kao jedna od tehnika poslovne inteligencije, omogu ava identificiranje i odabir obrazaca ponašanja i pravila koji postoje u povijesnim podacima organizacije pohranjenim u bazama ili skladištima podataka.*

Ključne riječi: *poslovna inteligencija, proizvodni sustavi, neuronske mreže, geneti ki algoritam*



Authors' data: Ivica Coric, HERA, K.P. Krešimira IV bb, 88000 Mostar, BiH, ivica.coric@hera.ba; Dražena Gaspar, Ekonomski fakultet Sveu ilišta u Mostaru, Matice hrvatske bb, 88000 Mostar, BiH, drazena.gaspar@gmail.com; Mirela Mabic, Ekonomski fakultet Sveu ilišta u Mostaru, Matice hrvatske bb, 88000 Mostar, BiH, mirela.mabic@gmail.com

1. Uvod

Suvremeni proizvodni sustavi intenzivno koriste informacijsku tehnologiju (IT), naj eš e u obliku automatizacije i robotizacije proizvodnih linija, odnosno proizvodnih procesa. Uporaba automata i robota ima za cilj smanjivanje troškova, te bržu, kvalitetniju i efikasniju proizvodnju. Time se pokušavaju osiguravati kompetitivne prednosti na globalnom tržištu, što bi u kona nici trebalo dovesti do pove anja profita. Me utim, u situaciji kada su suo ene sa sve ve om globalnom konkurencijom, proizvodne organizacije su prisiljene koristiti sve alate koji im stoje na raspolaganju, a koji bi im omogu ili donošenje boljih odluka. Naime, suvremeni proizvodni sustavi su iznimno kompleksni i kada je rije o njihovim internim operacijama, ali i eksternim povezivanjima s dobavlja ima i kupcima, što ih ini vrlo složenim za pra enje i kontrolu. Stoga proizvodne organizacije stalno traže nove na ine za optimiziranje produktivnosti, poboljšanje usluga kupcima, menadžmenta kupaca, menadžmenta dobavlja a, pove anje prihoda i minimiziranje troškova. Uporaba alata poslovne inteligencije može na razli ite na ine pomo i proizvodnim organizacijama [8]:

- Uve ati vrijednost odnosa s kupcima
- Odgovoriti brzo na promjene na tržištu
- Poboljšati menadžment kupaca i dobavlja a
- Skratiti vrijeme izlaska novog proizvoda na tržište
- Smanjiti investiranje u zalihe
- Poboljšati planiranje nabave i prodaje
- Razviti i održavati sustav osiguranja kvalitete
- Odabrati i primijeniti vrhunske tehnologije.

Kako bi unaprijedili performanse, menadžeri proizvodnih, kao i drugih organizacija, trebaju imati dublje razumijevanje svojih kupaca i dobavlja a i to je razlog zašto se koriste sofisticiranije analize profitabilnosti kupaca i dobavlja a. Razumijevanje troškova i profitabilnosti kupaca omogu ava menadžerima proizvodnih organizacija kvalitetnije upravljanje kupcima, planiranje prodaje, a samim time i kvalitetnije planiranje proizvodnje i nabave. Pove ana diversifikacija i kompleksnost proizvoda, usluga i kupaca, ukazali su da na troškovnoj strani indirektni troškovi, u odnosu na direktne troškove, preuzimaju primat u ukupnoj masi [1]. Kupci se, sukladno svojim karakteristikama, dosta razlikuju u alociranju ovih troškova proizvode i injenicu da svaka nova jedinica prihoda ne u estvuje jednako u profitu poduze a kao cjeline [2,3,4]. Pažnja se stoga u analizama usmjerava na pojedina nog kupca i mjerenje „vrijednosti“ nove jedinice prihoda nastalog u poslovanju s njim. Podrobnije analize profitabilnosti [5,4,6, 10,1,7] daju rezultate koji ovo podru je ine iznimno zanimljivim sa stajališta analize i upravljanja distribucijom kupaca. Nužnost definiranja strategije upravljanja neprofitabilnim, ali i profitabilnim kupcima, ini prirodan slijed ovih istraživanja. To no i precizno utvr ivanje troškova, utvr ivanje disperzije profitabilnosti ine osnovu za utvr ivanje strategije upravljanja neprofitabilnim kupcima i uspostavljanje odgovaraju e infrastrukture za njeno provo enje. Ponovno procjenjivanje odnosa s kupcima, educiranje kupaca, ponovno

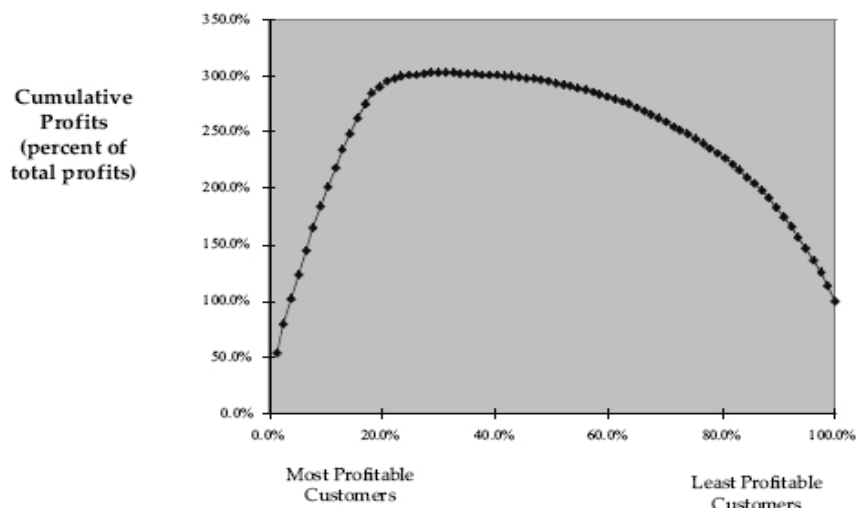
ugovaranje uvjeta kupovine, migracija kupaca te kao krajnja mjera terminiranje poslovnog odnosa s kupcem, samo su dio aktivnosti zahtjevnog procesa menadžmenta kupaca [9]. Provođenje strateških radnji upravljanja kupcima na osnovama retrospektivne analize postaje nedostatan za opstanak u globalnom tržištu. Jedan drugi pogled na profitabilnost, pogled na buduću profitabilnost kupaca, donosi nova saznanja važna za procese odlučivanja. Prospektivna analiza predviđa elemente poslovnog odnosa s kupcem za vrijeme njegovog budućeg životnog vijeka (kao kupca poduzeća), a osnovu za predviđanje nalazi u retrospektivnoj analizi. U ovom radu prikazano je kako se alati i metode poslovne inteligencije mogu koristiti u proizvodnim sustavima s ciljem analize profitabilnosti kupaca. Osnovu analize profitabilnosti u ovom slučaju predviđanje pripadnosti kupca pojedinom segmentu. Od metoda poslovne inteligencije korištene su neuronske mreže i genetski algoritmi.

2. Profitabilnost kupaca

Poslovni subjekti na tržištu prezentiraju profitabilnost svog poslovanja u agregiranim vrijednostima. Mjere poput tržišnog udjela, relativnog tržišnog udjela, indeksa prodora na tržište, prodora branda, zadovoljstva kupaca, ukupnog prihoda, ukupnih troškova, troškova marketinga i sl. prikazuju kako poduzeće radi sa svojim kupcima u cijelosti, odnosno promatraju ih i agregirano, bez detaljne analize svakog kupca pojedinačno. Stalna težnja menadžmenta poduzeća za poboljšanjem rezultata poslovanja, dovodi do nužnosti analize pojedinih kupaca. Iz te perspektive, za poduzeće nije više dovoljno da bude agilno i efikasno u svom poslovanju. Potrebno je da bude dio lanca opskrbe u kojem i kao partnere imati dobavljače i kupce koji ne obojati profitnu marginu. Analiza kupaca, koja se u radu razmatra, dovodi do zaključaka da svaki kupac nije jednako vrijedan, jednako profitabilan za poduzeće. Nije dovoljno niti djelovati samo aktivno analitički u analizama svog poslovanja, već se nameće potreba proaktivnog i prediktivnog djelovanja u odnosu s kupcima.

2.1. Segmentiranje kupaca

Profitabilnost kupca je razlika između prihoda ostvarenih prodajom roba i/ili usluga kupcu i troškova nastalih u odnosu s tim kupcem u određenom vremenskom razdoblju. Većina empirijskih fenomena, uključujući i prodaju, slijedi Paretoovo pravilo 20-80: 20% proizvoda ili kupaca ostvaruje 80% prodaje. Promatranje fenomena profitabilnosti kupca demantira Paretoovo pravilo. Kaplan [10] u objašnjenjima spominje „whale curve“ krivulje koja u odnosu postavlja kumulativni profit i kupce (slika 1). Ako su na apscisi predstavljeni kupci po visini profita koji ostvaruju, krivulja daje zanimljive rezultate: 20% najprofitabilnijih kupaca generira 150-300% ukupnog profita, sljedećih 70% su smješteni oko točke pokrića, a zadnjih 10% generira gubitak od 50-200% ukupnog profita dovodeći kumulativni profit na razinu ostvarenog profita (krivulja završava u točki 100% profita).



Slika 1. Kumulativna profitabilnost kupaca - „whale curve“

Dakle, bitna injenica na koju ukazuje ovakva analiza je injenica da nisu svi kupci jednako vrijedni. U osnovi potrebno ih je razdvojiti u tri različita sloja [11] sukladno rezultatima „whale curve“ krivulje:

1. Top segment kupci: Najvredniji i najlojalniji kupci koje treba zadržati, posvetiti im povećanu pozornost i nagraditi ih za njihovo ponašanje.
2. Drugi segment kupaca: Kupci sa srednjim-malim profitom, s potencijalom za rast i prijelaz u grupu top kupaca.
3. Treći segment kupaca: Kupci čije servisiranje uzrokuje gubitke za poduzeće.

Ukupan rezultat poduzeća može se unaprijediti akcijama prilagođenim različitim segmentima kupaca. Kaplan [10] ih po svojoj prirodi svrstava u tri grupe:

1. unaprjeđenje procesa
2. cjenovne odluke
3. modificiranje odnosa s kupcima.

Treća grupa za pretpostavku ima proširenje mogućnosti mjerenja lojalnosti i profitabilnosti kupaca kako bi se detaljno prikazali i predvidjeli odnosi pojedinog kupca s poduzećem. Količina i priroda parametara profitabilnosti kupca ukazuju na kompleksnost problema mjerenja i predviđanja. Profitabilnost je generalno prikazana kao financijski element. Mnogi nefinancijski faktori poput zadovoljstva kupaca, lojalnosti ili reputacije kupca, imaju značajan utjecaj na financijske performanse poduzeća, gledano na dugi rok. Tako je, na primjer, zadovoljstvo kupca prethodnik lojalnosti kupca, a iz lojalnosti kupca pak proistječe njegova profitabilnost. Važno mjesto u istraživanju profitabilnosti kupca zauzima definiranje i mjerenje troškova kupca.

3. Predviđanje segmentacije

3.1. Ulazni podaci i metodologija

Podatkovnu osnovicu istraživanja čine podaci iz skladišta podataka poduzeća koje se bavi proizvodnjom i prodajom proizvoda od sušenog voća, orašastih proizvoda, sjemenki i žitarica na području JI Europe za razdoblje 2008.-2013. godina (tablica 1).

Redni broj	Podatak	Opis	Ulazna/ Izlazna varijabla
1	Godina	Godina na koju se odnose podaci	N/A
2	Kupac	Kupac na koga se odnose podaci	N/A
3	Trošak	Ukupan trošak poslovanja s kupcem u promatranj godini	N/A
4	Prihod	Ukupan prihod ostvaren s kupcem u promatranj godini	Ulazna
5	Broj isporuka	Ukupan broj isporuka od strane kupca u promatranj godini	Ulazna
6	Broj proizvoda	Ukupan broj razli itih proizvoda u prometu kupca u promatranj godini	Ulazna
7	Broj lokacija isporuke	Ukupan broj razli itih lokacija na koje je vršena isporuka robe kupcu u promatranj godini	Ulazna
8	Neto marža	Neto marža ostvarena u prometu s kupcem u promatranj godini	N/A
9	Broj povrata	Ukupan broj povrata robe u prometu s kupcem u promatranj godini	Ulazna
10	Vrijednost povrata	Ukupna vrijednost povrata robe u prometu s kupcem u promatranj godini	Ulazna
11	Vrijednost rabata	Ukupna vrijednost rabata datog kupcu u ostvarenom prometu promatrane godine	Ulazna
12	Segment kupca	Pripadnost segmentu na temelju ostvarenih rezultata poslovanja s kupcem u promatranj godini	Izlazna

Tablica 1. Skup podataka korištenih u istraživanju

Svi su kupci, na temelju podataka iz prethodne tablice, svrstani u odgovaraju i segment prema segmentaciji definiranoj u prethodnom odjeljku rada.

Ulazni skup podataka ine varijable prihod, broj artikala, broj mjesta isporuke, broj isporuka, vrijednost povrata, broj povrata i vrijednost rabata, a skup je podijeljen na:

- a. *podatke za trening* (podaci za 2009. - 2011. godinu),
- b. *podatke za selekciju* (podaci za 2012. godinu),
- c. *podatke za testiranje* (podaci za 2013. godinu).

Kombinacija metoda strojnog u enja, neuronska mreža i geneti ki algoritam, upotrijebljena je u istraživanju dvojako. Cilj prve primjene je bio potvrditi klasifikacijsku sposobnost pobrojanih metoda strojnog u enja tkao što e se kupac svrstati u odgovaraju i segment. Ulazne vrijednosti mreže pri tome ne ine varijable kojima se direktno ra una neto profit, a niti sam neto profit koji ini osnovni pokazatelj za definiranje pripadnosti kupca pojedinom segmentu. Izlazna varijabla mreže je pripadnost segmentu. Cilj druge primjene je bio pokazati prediktivnu

moгу nost kombinacije metoda. I ova primjena je polazila od istog skupa podataka, ali su podaci bili vremenski ograničeni. Naime, ideja je koristiti iste pokazatelje iz prethodne primjene, ali ograničene na prvi kvartal. Ukoliko mreža pokaže mogućnost da na osnovu vrijednosti ulaznih varijabli za prvi kvartal svake od promatranih godina predvidi ispravnu pripadnost segmentu kupaca na kraju godine, potvrdila bi prediktivnu mogućnost. Ovakva funkcionalnost bi menadžmentu kupaca osigurala neophodne podatke za definiranje pravaca djelovanja u cilju korekcije ponašanja pojedinih kupaca i njihovog usmjeravanja ka željenom segmentu.

Analiza je rađena u softveru NeuroSolutions for Excel ver. 6.20 kompanije NeuroDimension. Upotrebom Express Buildera uspoređeni su rezultati različitih tipova i konfiguracija neuronske mreže: MLP - Multi Layer Perceptron, LR - Linear Regression, PNN - Probabilistic Neural Network, RBF - Radial Basis Function, MLPPCA - Multi Layer Perceptron with Principle Component Analysis, SVM - Classification Support Vector Machine, GFF - Generalized Feedforward, TDNN - Time-Delay Network, TLRN - Time-Lag Recurrent Network and RN - Recurrent Network. Broj epoha u procesu učenja mreže je postavljen na 100.

3.2. Rezultati

Rezultati istraživanja nad prvim setom podataka, koji je korišten u svrhu dokazivanja klasifikacijskih sposobnosti mreže, pokazali su TLRN-1-B-L arhitekturu kao najbolju. (slika 2). To je arhitektura s Time-Lag Recurrent mrežom s jednim skrivenim slojem i back-propagation algoritmom za kalkuliranje težinskih faktora uz Levenberg Marquardt pravilo učenja.

Performance Metrics									
Model Name	Training			Cross Validation			Testing		
	MSE	r	Correct	MSE	r	Correct	MSE	r	Correct
MLP-1-O-M (Multilayer Perceptron)	0.25038	0.301039	73.73%	0.240791	0.410915	73.93%	0.175774	0.499986	80.04%
LR-0-B-M (Linear Regression)	0.195864	0.234948	71.85%	0.197385	0.325672	70.36%	0.167196	0.452311	77.25%
LR-0-B-L (Linear Regression)	0.191818	0.266285	72.30%	0.193251	0.347026	70.71%	0.186286	0.254907	77.25%
MLP-1-B-L (Multilayer Perceptron)	0.138873	0.57306	77.75%	0.124667	0.667403	80.71%	0.121247	0.663559	82.19%
PNN-0-N-N (Probabilistic Neural Network)	0.176928	0.386242	74.80%	0.175479	0.45615	73.21%	0.141149	0.533286	79.61%
RBF-1-B-L (Radial Basis Function)	0.161655	0.46588	72.83%	0.167982	0.484394	69.64%	0.126698	0.604485	79.40%
GFF-1-B-L (Generalized Feedforward)	0.140154	0.567982	77.48%	0.128943	0.654528	80.36%	0.126035	0.644781	80.47%
MLPPCA-1-B-L (MLP with PCA)	0.141468	0.561117	76.85%	0.132591	0.635275	77.86%	0.107047	0.691196	80.90%
SVM-0-N-N (Classification SVM)	0.101882	0.778399	82.48%	0.18135	0.417339	71.43%	0.202361	0.158347	75.97%
TDNN-1-B-L (Time-Delay Network)	0.142104	0.572528	78.28%	0.114858	0.696572	83.21%	0.104856	0.685186	85.41%
TLRN-1-B-L (Time-Lag Recurrent Network)	0.063364	0.834589	89.61%	0.072902	0.859821	91.07%	0.10821	0.721165	89.48%
RN-1-B-L (Recurrent Network)	0.46634	0.173433	41.85%	0.146252	0.624334	82.50%	0.125244	0.626889	83.05%
MLP-2-B-L (Multilayer Perceptron)	0.139808	0.569483	76.16%	0.131115	0.64788	79.64%	0.133032	0.610367	79.83%
MLP-1-B-M (Multilayer Perceptron)	0.174951	0.409701	73.48%	0.173454	0.470082	74.29%	0.135015	0.577377	81.76%
MLP-2-O-M (Multilayer Perceptron)	0.211986	0.118986	70.79%	0.229498	0.158911	67.50%	0.191118	0.224086	73.82%
MLP-2-B-M (Multilayer Perceptron)	0.205707	0.08208	70.79%	0.218311	0.101005	67.50%	0.190503	0.149867	74.03%
MLPPCA-1-O-M (MLP with PCA)	0.240032	0.325444	73.66%	0.221617	0.450086	76.07%	0.150148	0.56531	82.40%

Slika 2. Sumarni rezultati svih mreža u prvoj primjeni

Pokazatelji uspješnosti mreže dati su u tablicama 2 i 3. Mreža je u slučaju trening seta podataka imala minimalnu pogrešku u 100. epohi, dok je u slučaju validacijskog seta najbolji rezultat postignut u 60. epohi.

	Training	Cross Validation	Testing
# of Rows	1119	280	466
MSE	0.063364	0.072902	0.10821
Correlation (r)	0.834589	0.859821	0.721165
# Correct	1000	255	417
# Incorrect	116	25	49
% Correct	89.37%	91.07%	89.48%

Tablica 2. Pokazatelji uspješnosti mreže u prvoj primjeni

Best Networks	Training	Cross Validation
Epoch #	100	60
Minimum MSE	0.081282197	0.096099236
Final MSE	0.081282197	0.112787966

Tablica 3. Krajnja i minimalna MSE u prvoj primjeni

Rezultati drugog seta podataka koji je korišten u svrhu dokazivanja prediktivnih mogu nosti mreže ponovili su TLR-1-B-L arhitekturu kao najbolju (slika 3).

Rezultat Time-Lag Recurrent mreže s jednim skrivenim slojem, back-propagation algoritmom i Levenberg Marquardt pravilom u enja je prikazan u tablicama 4 i 5, a promjene MSE kroz epohe u tijeku u enja mreže na slici 4. Trening set podataka imao je minimalnu pogrešku u 67. epohi, dok je validacijski set postigao najbolji rezultat u 18. epohi.

Performance Metrics									
Model Name	Training			Cross Validation			Testing		
	MSE	r	Correct	MSE	r	Correct	MSE	r	Correct
MLP-1-O-M (Multilayer Perceptron)	0.25135	0.27512	73.10%	0.23423	0.42444	73.57%	0.16267	0.5191	81.97%
LR-0-B-M (Linear Regression)	0.19519	0.23546	72.92%	0.19321	0.35264	70.71%	0.16376	0.43162	79.40%
LR-0-B-L (Linear Regression)	0.193	0.25529	72.39%	0.19104	0.35942	70.36%	0.17342	0.37162	79.18%
MLP-1-B-L (Multilayer Perceptron)	0.16592	0.44335	74.26%	0.13932	0.61081	78.93%	0.13122	0.6202	81.97%
PNN-0-N-N (Probabilistic Neural Network)	0.18042	0.3566	74.98%	0.17921	0.43333	73.21%	0.1439	0.5242	80.26%
RBF-1-B-L (Radial Basis Function)	0.17391	0.39869	73.91%	0.164	0.50388	74.29%	0.13408	0.5872	81.97%
GFF-1-B-L (Generalized Feedforward)	0.17037	0.42138	74.44%	0.14573	0.5889	75.00%	0.13175	0.62384	83.05%
MLPPCA-1-B-L (MLP with PCA)	0.16675	0.43857	75.16%	0.14075	0.60716	79.29%	0.12173	0.64392	82.19%
SVM-0-N-N (Classification SVM)	0.14584	0.59924	80.88%	0.1959	0.35163	72.50%	0.17865	0.30055	76.61%
TDNN-1-B-L (Time-Delay Network)	0.1385	0.57654	80.34%	0.11511	0.71308	86.07%	0.14149	0.64397	84.76%
TLRN-1-B-L (Time-Lag Recurrent Network)	0.12047	0.65727	81.54%	0.07467	0.8283	88.21%	0.07031	0.83927	91.63%
RN-1-B-L (Recurrent Network)	0.1604	0.47386	75.54%	0.10659	0.7478	86.43%	0.11071	0.68686	83.26%
MLP-2-B-L (Multilayer Perceptron)	0.16625	0.44284	74.28%	0.13926	0.61159	76.43%	0.1355	0.60492	81.55%
MLP-1-B-M (Multilayer Perceptron)	0.1835	0.33962	73.30%	0.17246	0.47588	73.21%	0.14121	0.55452	81.76%
MLP-2-O-M (Multilayer Perceptron)	0.21083	-0.1377	70.79%	0.22879	-0.2324	67.50%	0.19466	-0.18192	73.82%
MLP-2-B-M (Multilayer Perceptron)	0.20683	0.0197	70.88%	0.22055	0.05584	67.86%	0.1925	0.07923	74.25%
MLPPCA-1-O-M (MLP with PCA)	0.24008	0.27001	72.76%	0.21276	0.43228	75.36%	0.15275	0.52164	82.62%
MLPPCA-1-B-M (MLP with PCA)	0.19294	0.25996	73.30%	0.18975	0.37778	72.86%	0.15346	0.5028	81.12%
GFF-1-O-M (Generalized Feedforward)	0.26675	0.26298	73.12%	0.2431	0.40345	73.57%	0.16987	0.50326	80.69%
GFF-1-B-M (Generalized Feedforward)	0.19531	0.23938	73.30%	0.19423	0.35444	72.50%	0.15869	0.47961	80.69%


Slika 3. Sumarni rezultati svih mreža u drugoj primjeni

	Training	Cross Validation	Testing
# of Rows	1119	280	466
MSE	0.120472	0.074673	0.070313
Correlation (r)	0.657274	0.828295	0.839272
# Correct	910	247	427
# Incorrect	206	33	39
% Correct	81.32%	88.21%	91.63%

Tablica 4. Pokazatelji uspješnosti mreže u drugoj primjeni

Best Networks	Training	Cross Validation
Epoch #	67	18
Minimum MSE	0.115984412	0.108177511
Final MSE	0.116321311	0.193587018

Tablica 5. Krajnja i minimalna MSE u drugoj primjeni



Slika 4. MSE vs. Epoch za drugu primjenu

Nakon inicijalnog treniranja mreže za drugu aplikaciju i dobivenih rezultata koji su prethodno predstavljani, upotrijebljen je geneti ki algoritam za optimizaciju mreže. Parametri u enja su postavljeni na slijede e vrijednosti: broj epoha je 100, maksimalni broj generacija je 100 uz vrijednost populacije od 50. Tijekom procesa optimizacije, geneti ki algoritam optimizira selekciju ulaznih varijabli, veli inu koraka, vrijednost momentum i broj neurona u skrivenom sloju mreže. Cilj procesa optimizacije jeste otkrivanje parametara mreže koji rezultiraju minimalnom greškom mreže. Nakon opisanog procesa optimizacije upotrebom geneti kog algoritma, greška mreže je smanjena kako je i prikazano u tablici 6.

Optimization Summary	Best Fitness	Average Fitness
Generation #	41	48
Minimum MSE	0.068023024	0.068023024
Final MSE	0.068023024	0.078712643

Tablica 6. Krajnja i minimalna MSE za drugu primjenu (nakon optimizacije)

4. Zaključak

Rezultati provedenog istraživanja pokazuju da se klasifikacija primjenom neuronskih mreža i genetičkog algoritma može efikasno primjenjivati u segmentaciji kupaca. Kombinirana primjena neuronskih mreža i genetičkog algoritma u provedenom istraživanju potvrđuje njihovu primjenjivost s klasifikacijskom preciznošću od 89,37-91,07% i s preciznošću predviđanja 81,32-91,63%. Provedeno istraživanje pokazuje da se metode poslovne inteligencije mogu primjenjivati bez obzira o kakvom je poduzeću riječ, proizvodnim ili neproizvodnim. Njihova kontinuirana primjena može olakšati donošenje novih poslovnih odluka na obostrano zadovoljstvo, i proizvođača i kupca. Kako je već rečeno, ovo istraživanje potvrđuje primjenjivost testiranih metoda u segmentaciji kupaca, a samim time otvara mogućnosti i za daljnja istraživanja. U nastavku bi u istraživanje trebalo uključiti nove varijable, uzimajući u obzir broj parametara koji definiraju profitabilnost kupaca. S obzirom da se neuronskim mrežama jednako dobro mogu analizirati financijske i nefinancijske varijable, otvara se mogućnost novih složenijih primjena ove metode, a sve s ciljem osiguravanja informacija adekvatne količine i zadovoljavajuće kvalitete na temelju kojih bi se donosile poslovne odluke, prvenstveno vezane za područje upravljanja klijentima.

5. Literatura

- [1] Shapiro, P.; Rangan, K.; Moriarty, R. & Ross, E. (1987). Manage Customers for Profits (Not Just Sales). *Harvard Business Review*, September-October.
- [2] Howell, R. A. & Soucy, S. R. (1990). Customer profitability; as critical as product profitability. *Management Accounting*, October 1990: 43-47.
- [3] Foster, G.; Gupta, M. & Sjoblom, L. (1996). Customer profitability analysis: Challenges and new directions. *Journal of Cost Management*, Spring: 5-17.
- [4] Triest S. (2005). Customer size and customer profitability in non-contractual relationships. *Journal of Business & Industrial Marketing*, 20/3: 148-155.
- [5] Cooper, R. & Kaplan, R. (1991). Profit Priorities from Activity-Based Costing. *Harvard Business Review*
- [6] Storbacka, E.K. (1997). Segmentation based on customer profitability: retrospective analysis of retail bank customer bases. *Journal of Marketing Management*, Vol. 13 No. 5, str. 479-92.
- [7] Krakhmal V. (2006). Customer profitability analysis in service industries. BAA Annual Conference 11-13 April, Portsmouth, UK.
- [8] MAIA Intelligence (2009). Business Intelligence in Manufacturing, White Paper, *Dostupno na: <http://video.tv18online.com/general/biztech/videos/whitepapers/July2009/BIforManufacturingWhitePaper.pdf>*, *Pristup: 30-11-2013*.
- [9] Mittal, V.; Sarkees, M. & Murshed, F. (2008). The right way to manage unprofitable customers. *Harvard Business Review*, April
- [10] Kaplan, R. & Narayanan, V.G. (2001). Measuring and managing customer profitability. *Journal of Cost Management*, Vol. 15, No. 5, str. 5-15.
- [11] Farris, P.W.; Bendle, N.T.; Pfeifer, P.E. & Reibstein, D.J. (2006) *Marketing metrics*, Wharton School Publishing, USA.



Photo 014. The curb / Rubnjak