

**Предвиђање ликвидности банака
применом неуронских мрежа**

Ментор:

Проф. Др Братислав Петровић

Студент:

Јована Мирковић 164/05

Садржај

1. Увод.....	3
2. Неуронске мреже.....	4
2.1 Увод у неуронске мреже.....	4
2.2 Основни појмови	5
2.2.1 Архитектура мреже	6
2.2.2 Активационе функције	8
2.2.3 Закон учења.....	10
2.3 Врсте неуронских мрежа	11
2.3.1 Подела неуронских мрежа према броју слојева.....	11
2.3.2 Подела неуронских мрежа према врсти веза.....	12
2.3.3 Подела неуронских мрежа према врсти обучавања	12
2.3.4 Подела неуронских мрежа према смеру простирања информација.....	12
2.3.5 Подела неуронских мрежа према врсти података	13
2.4 Учење и тренирање мрежа	14
2.4.1 Backpropagation алгоритам.....	15
2.4.2 Проблем конвергенције и локалног минимума	17
2.4.3 Backpercolation алгоритам	18
2.5 Модели неуронских мрежа.....	19
2.5.1 Вишеслојна Feedforward неуронска мрежа (ВФНМ)	19
2.5.2 Хопфилдова неуронска мрежа.....	20
2.5.3 Само-организујуће неуронске мреже	21
2.6 Примена неуронских мрежа	23
2.7 Неуронске мреже у пословању.....	24
2.7.1 Маркетинг.....	24
2.7.2 Малопродаја	24
2.7.3 Финансије и банкарство.....	25
3. Банкарски систем.....	27

3.1	Банкарски послови савремених пословних банака и начела њиховог пословања	27
3.1.1	<i>Пасивни банкарски послови</i>	27
3.1.2	<i>Активни банкарски послови</i>	28
3.1.3	<i>Неутрални банкарски послови</i>	29
3.1.4	<i>Начела пословања банака</i>	29
3.2	Показатељи пословне успешности банака	30
3.2.1	<i>Показатељи профитабилности</i>	30
3.2.2	<i>Показатељи ликвидности</i>	32
3.2.3	<i>Показатељи задужености</i>	33
3.2.4	<i>Показатељи економичности</i>	34
3.3	Ризици у банкарским пословима	34
3.4	Значај банкарског система	35
3.5	Значај ликвидности банака	36
4	Дефинисање модела за имплементацију	38
4.1	Дефинисање модела неуронске мреже	39
4.2	Параметри за мерење резултата предвиђања	42
4.2.1	<i>Корен средње квадратне грешке</i>	43
4.2.2	<i>Средња апсолутна процентуална грешка</i>	44
5	Резултати модела	45
5.1	Дефинисање алтернативног модела неуронских мрежа	46
5.2	Резултати алтернативног модела	48
6	Закључак	49
7	Литература	50

1. Увод

Циљ овог дипломског рада јесте проучавање могућности примене неуронских мрежа на предвиђање успешности пословања банака, тј. њихове ликвидности.

У раду је дат предлог модела неуронских мрежа за предвиђање, као и алтернативни модел, који за улаз имају финансијске показатеље израчунате на основу података из кварталних биланса стања и биланса успеха банке.

У другом поглављу је дат кратак увод у неуронске мреже и њихове основне појмове (архитектура, активационе функције, закон учења). Говори се о врстама неуронских мрежа, начину учења и тренирања, постојећим моделима неуронских мрежа, као и о њиховој примени, од којих је за овај рад најбитнија примена у финансијама и банкарству.

Треће поглавље се бави банкарским системом и у оквиру њега описане су врсте банкарских послова, начела њиховог пословања и, што је најзначајније, финансијски показатељи који се даље у раду користе за тренирање неуронских мрежа.

Четврто поглавље посвећено је моделовању неуронских мрежа. У овом поглављу је дефинисан модел неуронских мрежа за имплементацију у оквиру ког су дефинисани улази у мрежу, као и тражени излаз. Такође, дефинисани су параметри за оцену квалитета предвиђања, односно за мерење резултата предвиђања.

У петом поглављу представљени су резултати претходно дефинисаног модела у зависности од броја скривених слојева, броја скривених неурона и активационе функције неуронске мреже. Описани су недостаци модела и предлог алтернативног модела за предвиђање са добијеним резултатима.

2. Неуронске мреже

2.1 Увод у неуронске мреже

Предвиђање се може описати као покушај прогнозирања будућих догађаја испитивањем историјских података и патерна и закључивањем на основу пројекција добијених из тих патерна. Сам процес предвиђања се састоји од генерисања непристрасних процена будућих вредности неке варијабле на основу чињеница из прошлости и садашњег знања и искуства.

Предвиђање има дугу историју, и значај ове области се огледа у разноврсним апликацијама које се примењују у разним дисциплинама од пословања до инжењерства. Способност да се тачно предвиди будућност је фундаментална за доношење закључака у областима планирања, набавке, формирања стратегије, дефинисања политике предузећа и многим другим.

Предвиђање успешности пословања је важна компонента управљања предузећем. Данас се користе најмодернија и најсавременија достигнућа математике, статистике, информационих технологија и осталих интердисциплинарних наука како би се предвидели потенцијални догађаји у предузећу који би могли довести до огромних трошкова. Тако се од 1919. године када је учињено прво, основно истраживање до данас употребљава широк спектар од најједноставнијих, до изузетно комплексних метода попут неуронских мрежа које покушавају да репродукују процесе функционисања мреже неурона у људском мозгу. Заједничко за све ове методе је то да готово све оне којима се предвиђа пословна успешност предузећа најчешће за улазне податке узимају финансијско рачуноводствене мере.

Током више година предвиђањем уопште, а самим тим и предвиђањем успешности предузећа, доминирале су линеарне методе које су лаке за развој и имплементацију и које су релативно лаке за разумевање и тумачење. Међутим, линеарне методе не могу да опишу нелинеарне односе између података.

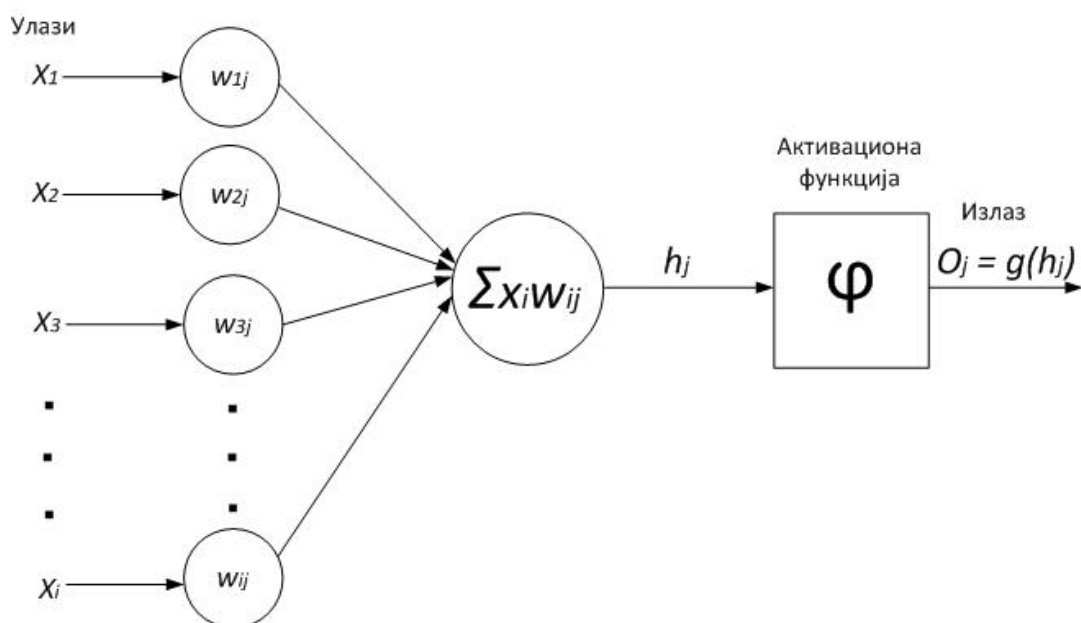
Успешан алтернативни алат за предвиђање су вештачке неуронске мреже (ВНМ). Оне не само да проналазе нелинеарне структуре у проблему, већ и моделују линеарне процесе. ВНМ поседују и друге особине које их чине корисним за предвиђање. Прво, неуронске мреже су непараметарске методе које не захтевају ограничења у процесу генерисања података. Такође, математички је показано да неуронске мреже имају функционалну

способност прецизне апроксимације многих типова комплексних функционалних односа. Комбинација ових особина чини ВММ флексибилним моделом за предвиђање. ВММ се успешно користе за решавање проблема у разним областима пословања, индустрије и науке.

2.2 Основни појмови

Неуронске мреже су програми или хардверски склопови који итеративним поступком из прошлих података настоје пронаћи везу између улазних и излазних варијабли модела, како би се за нове улазне варијабле добила вредност излаза, тј. уче на примерима. То су системи састављени од веома великог броја једноставних елемената за обраду података. Сама идеја за развој ВММ је била та да се имитира интелигентно размишљање слично људском.

Основне јединице грађе неуронских мрежа су неурони (Слика 1.) који су међусобно повезани и организовани у слојеве (Слика 2.). Сваки неурон обавља једноставне операције обраде информација превођењем добијених улаза у излазе и кроз њихове везе може се генерисати и складиштити знање. Сваки неурон има локалну меморију у којој памти податке које обрађује. Преко њихових међусобних веза, сигнал се преноси са једног неурона на други. Веза може бити и повратна, у претходне слојеве. Свака веза је означена бројем који се назива *тежина конекције* и који показује до ког степена конекција појачава или смањује сигнал.



Слика 1. Изглед вештачког неурона

$x_{1..n}$ – улазни подаци, вредности инпута које неурон прима (сигнали или потенцијали код биолошког неурона)

$W_{1..n}$ – тежински коефицијенти (синапсе код биолошког неурона)

$\varphi ()$ – активациона функција (аксон код биолошког неурона)

O_j – излазни подаци (потенцијал излаза код биолошког неурона)

Излазни сигнал неурона је дат следећом релацијом:

$$O_j = \varphi \left(\sum_{i=1}^n x_i w_{ij} \right)$$


Неуронску мрежу чине:

- Архитектура мреже, тј. шема везивања елемената (неурона)
- Активациона функција неурона
- Закон учења

2.2.1 Архитектура мреже

Архитектуру ВММ представљају специфично уређење и повезивање неурона у облику мреже. По архитектури неуронске мреже се разликују према броју неуронских слојева. Постоје три врсте слојева неурона:

- улазни
- скривени и
- излазни



Слика 2. Двослојна неуронска мрежа


Сваки слој неуронске мреже прима улазе из претходног слоја, а своје излазе шаље у наредни. Први, улазни слој је једини слој који прима сигнале из окружења. Он преноси сигнале следећем, скривеном слоју који добијене податке обрађује, издваја значајне особине и шеме из примљених сигнала и шаље податке излазном, последњем слоју мреже. На излазима неурона последњег слоја се добијају коначни резултати.

Везе између слојева могу бити:

- стандардне везе (не дозвољавају прескакање слојева или рекурентне процесе)



- прескочне везе (сигнали улазног слоја могу да се прослеђују директно излазном)



- рекурентне везе (неурони скривеног слоја враћају излазе улазном слоју)



Број неурона у скривеним слојевима, као и сам број скривених слојева зависе од различитих фактора међу којима је и проблем који се жели решити помоћу неуронске мреже. Код избора броја неурона у скривеном слоју посебну пажњу треба обратити на то да се мрежа не „претренира“ или да се мрежа недовољно истренира, тј. потребно је пронаћи оптималан број који није ни премали ни превелики.


2.2.2 Активационе функције

Активациона функција неурона дефинише какав ће бити његов излаз на основу добијених улаза. Активационе функције у скривеним слојевима су неопходне како би се у мрежу „увела“ нелинеарност јер она омогућава мрежи да реши нетривијалне проблеме коришћењем малог броја неурона. Код неуронских мрежа може се користити велики број функција активације, а најчешће коришћене су:

- Функција прага
- Линеарна функција
- Сигмоидна функција (Логистичка, Тангенс хиперболички, Гаусова)

Функција прага (слика 3.) узима 0 вредност уколико је величина улаза мања од вредности прага, а узима вредност 1 уколико је величина улаза већа или једнака вредности прага. Ова функција је корисна код бинарне класификације, тј. када улазе желимо да класификујемо у две групе.


$$\varphi(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$



Слика 3. Функција прага

Линеарна функција (слика 4.) се углавном користи у излазном слоју неуронске мреже. Примењује се у случајевима када нам је на излазу потребан велики скуп бројева.


$$\varphi(x) = x$$



Слика 4. Линеарна функција

Логистичка функција (Слика 5.) увек враћа позитивну вредност. Логистичка функција је посебно корисна у скривеним слојевима неуронских мрежа које се користе за предвиђање финансијских временских серија.


$$\varphi(x) = \frac{1}{1 + e^{-x}}$$



Слика 5. Логистичка функција

Тангенс хиперболички (Слика 6.) је симетрична функција која проширује скуп вредности Сигмоидне функције тако да обухвата и негативне вредности, тј. са $[0, 1]$ на $[-1, 1]$. Тиме што обезбеђује како позитивне, тако и негативне вредности, ова функција обезбеђује и боље тренирање мреже.


$$\varphi(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$



Слика 6. Функција Тангенс хиперболички

Гаусова функција (Слика 7.) се примењује у одређеним динамичним процесима са два скривена слоја где је нека од тангенсних функција примењена у другом слоју.

$$\varphi(x) = e^{-x^2}$$



Слика 7. Гаусова функција

2.2.3 Закон учења

Закон учења је формула која се користи за прилагођавање тежина веза између неурона (w_{ij}). Тежина везе је снага везе између два неурона. Промена тежине обавља се према неком од правила учења, а најчешће се користи Делта правила по формули:

$$\Delta w_{ji} = \eta * y_{cj} * \varepsilon_i$$

где је Δw_{ji} вредност прилагођавања тежине везе од неурона j до неурона i , израчунатом према:

$$\Delta w_{ji} = w_{ji}^{nova} - w_{ji}^{stara}$$

η је коефицијент учења,

y_{cj} вредност излаза израчунатог у неурону j ,

ε_i је сирова грешка израчуната према:

$\varepsilon_i = y_{ci} - y_{di}$, где је y_{di} жељени (стварни излаз) који се употребљава за израчунавање грешке.

Делта правило је познато као правило најмањих средњих квадрата јер за циљ има минимизирање суме квадрата грешака.

Поред самог правила учења, потребно је одредити и параметре учења: коефицијент учења и моментум.

Коефицијент учења је параметар који одређује величину промене тежина током учења. Што је коефицијент учења већи, мрежа се брже тренира, али се истовремено повећава и могућност губитка информација о финијим везама.

Моментум је параметар који утиче на брзину и квалитет учења. Моментум спречава сатурацију, тј. екстремно кретање тежина које доводи до блокаде учења. У основи, моментум омогућава промену тежина кроз све процесе њиховог прилагођавања. Дакле, он олакшава промене тежина, спречава осцилације вредности грешке и омогућава избегавање малих локалних минимума.

2.3 Врсте неуронских мрежа


Постоји велики број различитих реализација неуронских мрежа, а самим тим постоји и много подела. ВНМ можемо класификовати према:

- броју слојева
- врсти веза између неурона
- врсти обучавања неуронских мрежа
- смеру простирања информација
- врсти података


2.3.1 Подела неуронских мрежа према броју слојева

Постоји велики број различитих типова ВНМ. Једна од најопштијих подела неуронских мрежа је према броју слојева на:

- једнослојне (Слика 8.) и
- вишеслојне (Слика 9.)



Слика 8.



Слика 9.

Данас се углавном примењују и проучавају вишеслојне мреже које поред улазних и излазних слојева садрже науроне на средњим (скривеним) слојевима.

2.3.2 Подела неуронских мрежа према врсти веза

Неуронске мреже се могу поделити према врстама веза, тј. архитектури на:

- слојевите: неурони су повезани тако да формирају слојеве. На улаз једног неурона се доводе излази свих неурона са претходног слоја, а његов излаз се води на улазе свих неурона на наредном слоју, при чему неурони са првог (улазног) слоја имају само по један улаз, а неурони на последњем слоју представљају излазе. Пример ове мреже је *Backpropagation* (ширење унатраг) мрежа.
- потпуно повезане: излаз једног неурона се води ка улазу свих неурона у мрежи. Представник ове мреже је Хопфилдова мрежа.
- целуларне: међусобно су повезани само суседни неурони, али без обзира на локалну повезаност, сигнали се простиру и на неуроне ван суседства због индиректног простирања информација.


2.3.3 Подела неуронских мрежа према врсти обучавања

- надгледане: *perceptron*, *backpropagation* мреже
- делимично надгледане
- ненадгледане: Кохоенове самоорганизујуће мапе

2.3.4 Подела неуронских мрежа према смеру простирања информација


Неуронске мреже се могу поделити према смеру простирања информација на:

- Feedforward (нерекурзивне, неререферентне или неповратне)(Слика 10.): виши слојеви не враћају информације у ниже слојеве. Врше простирање сигнала само у једном смеру (од улаза према излазу) односно пропацију сигнала. Представник ове мреже је вишеслојни перцептрон са *backpropagation* алгоритмом. Ове мреже представљају најпопуларнији и најчешће коришћен модел неуронских мрежа.



Слика 10. Feedforward мрежа

- Feedback (рекурзивне, рекурентне или повратне)(Слика 11.): виши слојеви враћају информације у ниже, излаз из неурона се враћа у ниже слојеве или у исти слој. Feedback мреже имају петље које враћају информације у скривене слојеве. Ове мреже имају много веће процесне способности од претходних. Представници су Хопфилдове, Целуларне, Кохоенове, двоструко асоцијативне.



Слика 11. Feedback мрежа

2.3.5 Подела неуронских мрежа према врсти података

Према врсти података које обрађују, неуронске мреже се могу поделити на:

- аналогне и
- дискретне

2.4 Учење и тренирање мрежа

Неуронска мрежа мора бити обликована тако да сет улазних података ствара жељени излаз. Постоје разне методе за подешавање тежина конекције. Један начин је да се тежине подесе експлицитно, коришћењем *a priori* знања. Други начин је да се неуронска мрежа тренира помоћу одговарајућих патерна како би сама подешавала своје тежине на основу наученог правила.

Учење мрежа се може поделити у три групе:

- надгледано (supervised) учење
- ненадгледано (unsupervised) учење и
- делимично надгледано учење

Надгледано обучавање (Supervised training) је обучавање код ког алгоритам који надзира обучавање (супервизор) упоређује податке добијене на излазу са очекиваним подацима. Разлика између добијених и очекиваних података се шаље процедури за учење, која коригује тежинске коефицијенте мреже. Контролисан тренинг је сличан студенту кога професор води у учењу, указује на грешке и пропусте и усмерава ка жељеном циљу. Код надгледаног учења, мрежа учи на темељу познатих узорака тако што се, поред улазних података, на улаз доводе и жељени одговори, по један за сваки неурон у излазном слоју. На тај начин су грешке или одступања између жељених и стварних резултата познате и користе се за промену параметара мреже (тежине). Израз *надгледано* потиче од чињенице да жељене сигнале поставља спољни учитељ.

Ненадгледано обучавање (Unsupervised training) је обучавање код ког је мрежа независна. Приликом обучавања представљају се само они улазни подаци које мрежа покушава да генерализује и „уочи“ неке заједничке особине. Код ненадгледаног учења излазна јединица се тренира да одговори на скуп патерна на улазу. Мрежа треба да препозна истакнуте особине или правила улазних података. За разлику од надгледаног учења, у овом случају не постоји претходно познат скуп категорија у које се патерни класификују, већ мрежа мора сама да развије своју интерпретацију улаза.

Делимично надгледано обучавање (Partially supervised training) ради на принципу да мрежа учи самостално, а да повремено добија оцену претходног рада. Пример овакве мреже је мрежа која балансира штап. Док је штап усправан све је у реду, али када штап падне, мрежа треба да коригује понашање како би штап остао усправан

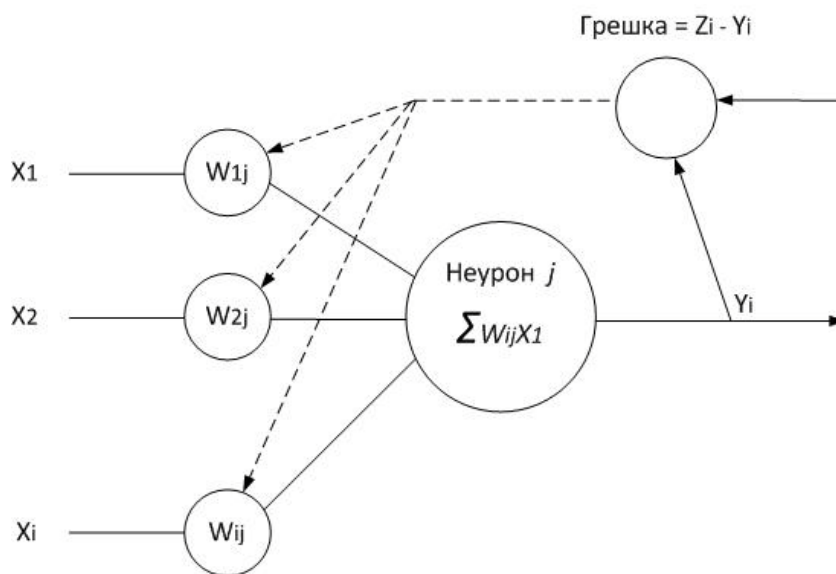
Најбољи начин за тренирање мреже је да се прикупи велики број примера (што је проблем сложенији потребно је више примера) који испитују различите особине проблема. Мала количина улазних података води ка стварању непоуздане и непредвидиве мреже, али треба водити рачуна и о томе да се мрежа не претренира. Тиме мрежа може постати сувише прилагођена подацима који се користе за тренирање да ће постати неспособна да тачно класификује узорке ван тог сета података.

Број скривених неурона утиче на способност мреже да раздвоји податке. Велики број скривених неурона осигурава прецизно учење, мрежа је способна да прецизно предвиди податке на којима се тренира, али њен учинак на новим подацима је тиме угрожен. Уколико има премало скривених неурона, мрежа може постати неспособна да научи везе између података што доводи до сувише великих грешака.

2.4.1 *Backpropagation* алгоритам

Backpropagation је скраћеница од *back error propagation* (ширење грешке уназад). Ово је најчешће коришћен алгоритам учења мрежа и да би се мрежа која учи на основу овог алгоритма користила, потребан је претходни тренинг мреже. *Backpropagation* мрежа је типа *feedforward* и има један или више скривених слојева.

Почевши од излазног слоја, разлика (грешка) између жељених и стварних излаза се рачуна да би се на основу ње поправиле вредности тежина у претходном слоју (Слика 11.).



Слика 11 Алгоритам ширења грешке уназад

За сваки неурон излазног слоја грешка се израчунава изразом:

$$\frac{(Z_j - Y_j)}{(df/dx)}$$

где су Z и Y , жељени и стварни излаз, респективно. Сигмоидна функција $f(x) = \frac{1}{1 + e^{-x}}$ је ефикасан начин да се израчуна излаз неурона (где је x пропорционално суми умножака улаза и тежина). Извод сигмоидне функције $(df/dx) = f(1 - f)$ и грешка су једноставна функција жељених и стварних излаза. Фактор $f(1 - f)$ је *логистичка функција* која држи корекцију грешке у одређеним границама. Тежина сваког улаза у j -ти неурон се поправља пропорционално овој израчунатој грешци.

Алгоритам се састоји из следећих корака:

- иницијализација тежина (случајна)
- учитавање улазног вектора и жељеног излаза
- пропуштање улазног вектора кроз мрежу и добијање израчунатог излаза
- израчунавање грешке
- подешавање тежина идући уназад од излазног слоја ка скривеним слојевима

Фактори који утичу на обучавање алгоритма ширења грешке уназад су:

- *Иницијализација тежина*: типична иницијализација је малим случајним вредностима. Велике вредности воде у засићење и заглављивање у локалним екстремима блиским стартној позицији. Практична препорука за иницијализацију је избор почетних тежина у опсегу $\left[-\frac{3}{\sqrt{k_i}}, \frac{3}{\sqrt{k_i}}\right]$, где је k_i број улазних конекција у неурон i .
- *Коефицијент учења*: велике вредности могу да убрзају конвергенцију, али и да доведу до премашаја циља, док исувише мале вредности имају супротан ефекат. Досадашња пракса показује да се η може кретати, зависно од конкретног проблема у опсегу од 0,001 до 10.
- *Моментум*: Један од начина да се константа учења повећа, а да не дође до дивергентног осциловања је додавање тзв. моментум члана који омогућава одвијање процеса обучавања у правцу „средње силе на доле“. Ово се може остварити укључивањем претходних промена тежина у тренутну промену, нпр. на следећи начин

$$\Delta w(t) = -\eta \nabla E(t) + \alpha \Delta w(t - 1), \quad \alpha \in [0, 1]$$
 Где је α моментум параметар (уобичајена практична вредност је 0,9).

- *Обучавајући скуп и генерализација:* Алгоритам пропагације грешке уназад има добра својства генерализације. Неуронска мрежа добро генерализује уколико даје добре интерполације за нове улазе, који нису били присутни у поступку обучавања. Неуронска мрежа са исувише слободних параметара за задати обучавајући скуп може бити добро обучена, са великом вероватноћом лоше генерализације. Овај феномен се назива *overfitting*. Међутим, уколико мрежа има исувише мало слободних параметара, није у стању да се обучи на датом скупу, а самим тим има лоше перформансе и на тест скупу (који обухвата примере који не припадају обучавајућем скупу). Развијено је више процедура за побољшање генерализације:
 - Смањивање осетљивости мреже – мале промене улазних сигнала не изазивају велике промене на излазу неуронске мреже
 - Регулација – проширивање критеријумске функције тзв. регуларизационим чланом
 - Рано заустављање – заустављање процедуре обучавања док грешка и даље опада (спречава *overfitting*).
 - Кресање – идеја се темељи на принципу остваривања што бољих перформанси са што сиромашнијом архитектуром

2.4.2 Проблем конвергенције и локалног минимума

Површина на којој се тражи екстремум (површина грешке) није детерминистичка. Алгоритам ширења грешке уназад припада класи алгоритама стохастичке апроксимације.

За површину грешке знају се три базична својства:

- Велики број локалних минимума, будући да постоји велики број комбинаторних пермутација тежина које дају исти излаз мреже
- Постојање локалних минимума изнад нивоа глобалног минимума
- Постојање вишеструких платоа са малим нагибом што је директна последица засићења активационих функција у домену великих сигнала, када су излази неосетљиви на мале промене тежина. Присуство оваквих делова површине грешке узрокује спору конвергенцију алоритма.

Проблем локалног минимума настаје када мрежа почне да се стабилизује конвергирајући ка локалном минимуму уместо да глобалном минимуму који представља оптимално решење.

Проблем локалног минимума обухвата следеће кораке:

- Алгоритам ширења грешке уназад мења тежинске коефицијенте, тако да излаз из неуронске мреже конвергира ка траженом излазу.
- Сигмоидна логистичка активациона функција $f(x) = \frac{1}{1 + e^{-x}}$ нормализује вредност излаза неурона у распону од 0 до 1. Тачке 0 и 1 представљају тачке засићења сигмоидне функције.
- Уколико је вредност излаза из неурона приближно једнака тачкама засићења, онда је вредност излаз из сигмоидне функције веома мала, а самим тим и њен извод.
- Као резултат добијамо да су промене тежинских коефицијената изразито мале, јер њихове промене зависе од величине функције грешке и извода сигмоидне функције.
- Несклад се јавља када сви неурони у скривеном слоју, на излазу добију вредности које се приближавају тачкама засићења (1 или 0) пре него што се неуронска мрежа приближила траженом излазу.

2.4.3 *Backpercolation* алгоритам

Backpercolation је такође алгоритам за *feedforward* мреже, али се код овог алгоритма тежине не мењају сходно грешци излазног слоја, већ се грешка израчунава за сваки неурон посебно, па се на основу те грешке подешавају и тежине. Ово је ефикасан начин да се смањи број циклуса тренирања.

Алгоритам се састоји из следећих корака:

- иницијализација тежина (случајна)
- пропуштање улазног вектора кроз мрежу и добијање излаза при чему се рачуна глобална грешка
- грешка се враћа уназад у скривени слој
- рачуна се локална грешка за сваки неурон. Ова грешка представља вредност за коју треба да се промени излаз овог неурона да би се глобална грешка смањила
- све тежине се подешавају према локалној грешци
- ако је потребно, параметар увећања грешке се адаптира у свакој епохи учења

Главне карактеристике *Backpercolation* алгоритма су:

- стабилност тренинга не деградира када има више скривених слојева
- тренинг захтева само локална израчунавања (везана за један неурон у једном тренутку)
- тренинг не доводи до аутоматског повећања броја елемената у архитектури
- тежине конвергирају релативно брзо ка добијању арбитрарно тачног излаза


Пошто су у питању само локална израчунавања, нема инверзије матрица, угњеждених итеративних претраживања или само-реконфигурација и осталих техника које захтевају дуге време да би се обавиле.

2.5 Модели неуронских мрежа

2.5.1 Вишеслојна *Feedforward* неуронска мрежа (ВФНМ)

Око 95% пословних апликација користи овај тип мреже са *backpropagation* алгоритмом. Овај модел мреже је популаран јер може да се примени на многе области од значаја за пословање као што су предвиђање, класификација и моделовање. ВФНМ су корисне за решавање проблема који захтевају учење односа између скупа улаза и познатих излаза.

Мрежа се састоји из два или више слојева неурона који су повезани тежинама (Слика 12.). Информације се крећу с лева на десно, тако што се улази x преносе преко скривеног слоја неурона до излазног слоја. Тежине које повезују улазни елемент i са скривеним слојем неурона j означене су са W_{ij} , док су тежине које повезују скривени слој j са излазним слојем k означене са V_{kj} .



Слика 12. Вишеслојна *Feedforward* неуронска мрежа

Сваки неурон израчунава свој излаз на основу количине стимулације коју прима од улазног вектора x . Net улаз сваког неурона се израчунава као сума производа тежина и његових улаза, а излаз се заснива на сигмоидној функцији која представља значај тог net улаза. Дакле, за j -ти скривени неурон имамо:

$$net_j^h = \sum_{i=1}^n w_{ij}x_i \quad \text{и} \quad y_j = f(net_j^h)$$

а за k -ти излазни:

$$net_k = \sum_{j=1}^{J+1} V_{kj}y_j \quad \text{и} \quad o_k = f(net_k^0)$$

Сигмоидна функција $f(net)$ дата је изразом:


$$f(net) = \frac{1}{1 + e^{-\lambda net}}$$

где λ параметар за контролу градијента функције, која је монотono растућа, диференцијална и налази се у границам између 0 и 1.

За дати улазни патерн, мрежа ствара излаз (или скуп излаза) Ok који се потом пореде са познатим, жељеним излазим сваког неурона. Тежине се на основу тога подешавају како би се исправила или смањила грешка. Овај поступак се понавља док се грешка код свих патерна не сведе испод претходно дефинисаног нивоа толеранције.

2.5.2 Хопфилдова неуронска мрежа

Хопфилдове мреже (Слика 13.) се у потпуности реазликују од претходних, по архитектури, приступу и функцији. У архитектури Хопфилдових мрежа не постоје слојеви и тежине се не мењају.



Слика 13. Хопфилдова неуронска мрежа

Сви неурони су међусобно повезани, тежине су W_{ij} су фиксирани и симетрични ($W_{ij} = W_{ji}$) и у њима се чува информација о меморијама или стабилним стањима мреже. Сваки неурон има стање x_i које може имати вредност из интервала $[0, 1]$. Неурони се ажурирају по диференцијалној једначини:

$$\frac{dnet_i}{dt} = -\frac{net_i}{\tau} + \sum_{j=1}^N W_{ij}x_j + I_i$$

$$x_i = f(net_i)$$

Током времена функција енергије се смањује, при чему локални минимум функције одговара стањима мреже.

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N W_{ij}x_i x_j - \sum_{i=1}^N I_i x_i$$


Хопфилдове мреже се углавном користе за решавање проблема оптимизације на начин сличан операционим истраживањима. Принцип решавања проблема оптимизације је да се изврши избор тежина W_{ij} и константи I_i тако да функција енергије и оптимизације буду еквивалентне. Када се поставе вредности тежина и константи, стања неурона x_i насумично иницијализују, и неурони почињу да се ажурирају према датој диференцијалној једначини. Током времена, функција енергије се смањује, све док се стања неурона не стабилизују и док крајње стање неурона не буде еквивалентно локалном минимуму решења проблема оптимизације.

2.5.3 Само-организујуће неуронске мреже

Док се вишеслојне *feedback* неуронске мреже користе када су подаци којима се мрежа тренира доступни (улази и познати излази), самоорганизујуће неуронске мреже се користе када су ти подаци недоступни. Како би се подаци груписали на основу своје структуре користи се кластеровање (*clustering*). Циљ кластеровања је да се степен сличности патерна у оквиру једног кластера (групе) максимизује, а да се сличност патерна који припадају различитим кластерима минимизује.

Самоорганизујуће мреже подешавају тежине како би се утицало на учење мреже (као и вишеслојне *feedback* неуронске мреже), али жељени излаз мреже је непознат, тј. учење није надгледано. Друга значајна разлика са претходним моделима је архитектура мреже (Слика 14.) и улога положаја неурона у процесу учења.

Код самоорганизујућих мрежа улази су повезани у низове неурона који је обично једнодимензионалан (ред) или дводимензионалан (решетка).



Слика 14. Самоорганизујућа мрежа са девет неурона

Када се улазни патерн представи мрежи, одређени делови решетке неурона ће постати активни и везе између тих активних улаза ће ојачати тако да се посебна пажња мора обратити на физичко уређивање неурона. Уколико је један неурон активан, вероватно је и да су и неурони у његовој близини такође активни. Процес учења се подешава тако да неурон победник (чија је тежина најсличнија улазном патерну) добије највише наученог знања, а неурони у његовој околини мање. Што је неурон удаљенији од победничког неурона добија мање знања.

На почетку, у околини неурона победника може да се налази велики број неурона како би се подстакао одговор региона на патерн, али како учење одмиче тај број се самњује како би одговор био што више ограничен. Кораци овог алгоритма су следећи:

1. Иницијализација:
 - a. тежине се постављају на мале случајне вредности
 - b. величина суседства $N_m(0)$ је у почетку велика (али мања од броја неурона у једној димензији)

- с. вредности параметарских функција $\alpha(t)$ и $\sigma^2(t)$ се подешава између 1 и 0 (ове функције контролишу количину знања коју сваки неурон добија у односу на победника)
2. Представља се улазни патерн x и израчунава се удаљеност улаза од тежина сваког неурона j :

$$d_j = \|x - w_j\| = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2}$$

3. Неурон који је најмање удаљен је победник m
4. Тежине веза улазног слоја и суседних неурона се подешавају према неурону победнику по следећем правилу:
 $w_{ji}(t + 1) = w_{ji}(t) + c[x_i - w_{ji}(t)]$
 где је за сваки неурон j у $N_m(t)$
 $c = \alpha(t) \exp(-\|r_i - r_m\|/\sigma^2(t))$
5. Повратак на корак 2; смањити величину околине, $\alpha(t)$ и $\sigma^2(t)$ и понављати поступак док се тежине не уравнотеже

2.6 Примена неуронских мрежа

Неуронске мреже се примењују у бројним и најразличитијим областима. Неке од њих су:

- разне области економије (имају успеха на финансијским тржиштима где нелинеарна природа финансијских података чини примену класичних метода веома тешком)
- у предвиђању вредности акција, где су супериорније у односу на статистичке методе
- доношење одлука на основу великог броја података
- оцена кредитне способности предузећа

- предвиђање временских серија везаних за тражњу – маркетиншка анализа: предвиђање будућих купаца, понашање купаца у будућности, сегментирање тржишта
- препознавање облика, нарочито препознавање рукописа
- разне врсте дијагнозирања, нарочито медицинског проучавање рада мозга
- психијатријске процене
- временска прогноза
- криминолошка истраживања

2.7 Неуронске мреже у пословању

Бројна истраживања и примене неуронских мрежа у пословању доказала су предност неуронских мрежа у односу на класичне методе које не укључују вештачку интелигенцију.

2.7.1 Маркетинг

Циљ модерног маркетинга је да идентификује потрошаче који ће позитивно да реагују на производ. Маркетинг захтева сегментацију тржишта, како би се тржиште поделило на групе потрошача са одговарајућим понашањем. Сегментацију тржишта поделом потрошача на основу њихових основних карактеристика као што су демографија, економски статус, географска локација, итд. могуће је постићи применом неуронских мрежа. Ненадгледане неуронске мреже се могу користити као техника кластеровања како би се потрошачи аутоматски груписали на основу сличних карактеристика. С друге стране, надгледане неуронске мреже могу да се истренирају како би научиле границе између група потрошача (чести купци, повремени купци, ретки купци и слично). Неуронске мреже се могу користити и за праћење правила понашања потрошача током времена, као и код анализе тржишта.

2.7.2 Малопродаја

У пословању је често неопходно да се предвиди продаја како би могле да се донесу одлуке везане за инвентар, набавку робе и цене. Неуронске мреже су веома успешне у овој области због њихове способности да истовремено разматрају више варијабли као што су потражња за производима, расположива примања потрошача, величина популације, цена производа и цене комплементарних производа.

2.7.3 Финансије и банкарство

Најважнија област примене неуронских мрежа у финансијама и банкарству су финансијско предвиђање и трговање. Неуронске мреже се успешно примењују код проблема предвиђања будућих цена, предвиђања курса, перформанси акција, итд. Такође, неуронске мреже се користе и у предвиђању банкрота предузећа, финансијских превара, валидације потписа банака, моделовању односа између стратегије, краткорочних финансија и перформанси предузећа. Неуронске мреже се најчешће употребљавају код следећих група проблема:

- Процена зајмова:
 - хипотекарни кредити
 - прогнозирање категорије ризика као добре, критичне или лоше
 - потписивање зајмова и хипотекарних кредита

- Тржиште деоница и обвезница
 - a) Одређивање тренутка трговине
 - одлучивање када куповати и продавати деонице
 - проблем наруџбине за куповине и продаје
 - откривање узорака у ценама деоница на тржишту деоница

 - b) Класификација и рангирање ризика
 - рангирање обвезница
 - класификација обвезница
 - класификација поврата на деонице на висок и низак

 - c) Прогнозе тржишта
 - предвиђање цена деоница
 - прогнозирање цена на тржиштима будућих роба
 - предвиђање месечних кретања цена деоница
 - предвиђање на тржишту деоница

 - d) Прогнозе поврата
 - тестирање тржишне ефикасности
 - предвиђање поврата на деонице

3. Банкарски систем

Банкарски систем је један од подсистема укупног привредног система. Наука о банкарству је првенствено макроекономска категорија која истражује укупност економских, монетарних и финансијских односа „којима је основни циљ повећање снага друштва, убрзање привредног развоја и остваривање стабилних односа у привреди и друштву“.

Банка је „привредни организам“ који се у свом пословању користи туђим средствима. Њена улога је у снабдевању привреде новчаним средствима и обављању трансакција са новцем и хартијама од вредности, као и вршењу других послова у вези са новцем. Значи, банка је институција чија је основна делатност узимање и давање кредита и посредовање у новчаним трансакцијама.

Основна улога банке у њеном пословању је да:

- обавља тржишну алокацију новца и новчаног капитала
- прима новчане депозите и обезбеђује ликвидност комитената
- организује платни промет и механизам клиринга
- пружа саветодавне услуге у широком распону (банкарски консалтинг)

3.1 Банкарски послови савремених пословних банака и начела њиховог пословања

Пословне банке у својим активностима имају пасивну, активну и неутралну улогу, зависно од тога да ли примају депозите или одобравају кредите из прикупљених средстава. Према томе, сви банкарски послови се деле на пасивне, активне и неутралне.

3.1.1 Пасивни банкарски послови

Пасивни банкарски послови могу бити краткорични и дугорочни.

Пасивни краткорочни послови су део опште активности банке који се односе на следеће облике мобилизације и централизације новчаних средстава:

- емисија новца (емисиона банка емитује новац као кредит задуживањем саме себе који затим одобрава пословним банкама)

- депозитни послови (депозити по виђењу и орочени новчани депозити са отказним или без отказног рока)
- издавање (емисија) краткорочних хартија од вредности
- остали пасивни краткорочни послови

Пасивни дугорочни послови се огледају у директној или индиректној активности банака, усмереној на мобилизацију средстава на тржишту. Под овим пословима подразумева се:

- прикупљање орочених депозита
- емисија дугорочних хартија од вредности
- дугорочни кредити у земљи и из иностранства
- докапитализација (капитал банке расте пропорционално са порастом девизног потенцијала)

3.1.2 Активни банкарски послови

Активни банкарски послови (кредитни послови) су сви они послови у којима се банка појављује као кредитор, односно где банка позајмљује новац. И ови послови се деле на краткорочне и дугорочне банкарске послове.

Краткорочни активни послови обухватају одобравање краткорочних кредита за задовољење краткорочних потреба корисника у обртним средствима и то у принципу за повремене залихе или за покриће потраживања купаца, сезонске потребе и сл.

Врсте краткорочних кредита су:

- кредит на текућем рачуну
- кредитне линије
- есконтни кредит
- ломбардни кредит
- рамбурсни кредит
- акцептни кредит
- остали облици краткорочних кредита

Дугорочни активни банкарски послови се односе на одобравање следећих кредита:

- кредити за изградњу и набавку основних средстава
- кредити за стална обртна средства
- кредити за оснивачка улагања
- санациони кредити

- кредити за финансијско реструктурирање (финансирање куповине предузећа или нека друга велика финансијска трансакција везана за дуги рок)

3.1.3 Неутрални банкарски послови

Неутралне банкарске послове, банка обавља у своје име, а за туђи рачун, тако да се могу назвати и комисионим пословима.

Неутрални краткорочни послови су:

- посредовање при плаћању
- комисиони краткорочни послови
- послови наплате (инкасо послови)
- издавање акредитива
- пословање са валутама и девизама
- примање депоа или остава

Неутрални дугорочни послови су:

- емисија ефеката
- пласман ефеката
- управљање имовином комитента

3.1.4 Начела пословања банака

Три основна начела о којима банке у својој политици и пракси морају водити рачуна су:

- 1) Начело рентабилности: огледа се у тежњи предузећа да оствари добит као резултат пословања и говори о резултатима оствареним у пословној активности на циљним тржиштима, о способностима предузећа да опстане и развија се.
- 2) Начело сигурности: односи се на кредитну способност дужника и на мере обезбеђења у случају да се кредит по истеку рока са припадајућом каматом врати банци у истом износу.
- 3) Начело ликвидности: резултира из односа њених пласмана и дуговања и усклађености њихових рокова. Ликвидност пословне банке значи њену способност као дужника да новчане обавезе измири о роковима њихових доспећа.

3.2 Показатељи пословне успешности банака

Пословни успех банке мери се подацима из финансијских извештаја банке и целе индустрије. Пословни успех има бројне изразе, односно показатеље резултата пословања. Процена успеха пословања банке заснива се на анализама добијених података, рејтингу (са скорингом) и поређењу са општим и парцијалним циљевима пословања. Предуслов је утврђивање циљева и систематизација критеријума успешности.

3.2.1 Показатељи профитабилности

Основни циљ пословања банке, као и сваког друштвеног капитала је **профит**, исказан показатељима **профитабилности**. Профитабилно пословање омогућава реализацију парцијалних циљева акционара, депонената, дебитора, инвеститора, осталих клијената, менаџера, запослених. Специфичност банкарског пословања условљава профитабилност обезбеђивањем ликвидности и сигурности.

Међународна банкарска пракса користи најчешће следеће показатеље профитабилности:

- ROE (Return on Equity) – принос на акционарски капитал, стопа поврата главнице

Показује колико новчаних јединица добити банка остварује на једну јединицу властитог капитала. Поређењем профитабилности властитог капитала и профитабилности имовине и у односу на каматну стопу која представља цену коришћења туђег капитала, могуће је доћи до закључка о исплативости употребе властитог или туђег капитала. Уколико су стопе профитабилности властитог капитала врло високе, па чак и више од стопа профитабилности имовине, више се исплати користити се туђим капиталом, и обрнуто.

- Најважнији показатељ, првенствено за акционаре
- Показује колико акционари могу очекивати принос у односу на уложено у вредност акција

$$ROE = \frac{\text{нето профит по опорезивању}}{\text{акционарски капитал (главница)}}$$

- ROA (Return on Assets) – принос на активу, стопа поврата имовине
Показује успешност коришћења имовне у стварању добити. Односи се на добит коју предузеће генерише из једне новчане јединице имовине. Овај показатељ такође говори колики је интензивност имовине предузећа. Вредност овог показатеља варира у зависности од гране индустрије или делатности којом се предузеће бави.
 - Показује ефикасност управљања активом, односно прихода на јединицу активе

$$ROA = \frac{\text{нето профит по опорезивању}}{\text{актива (укупна имовина)}}$$

- Нето каматна маржа показује однос између каматних прихода и каматних расхода остварен управљањем активом и пасивом банке
Одређена је структуром биланса и каматним стопама које се примењују на поједине ставке активе, односно пасиве. Показује диференцијални каматни приход, као проценат просечне имовине. На нето каматну маржу утиче и имовина која не доноси приходе и обавезе на које се не плаћају камате.
 - НКМ показује ефикасност и рентабилност

$$НКМ = \frac{\text{каматни приходи} - \text{каматни расходи}}{\text{укупна имовина}} * 100$$

- Нето некаMATна маржа
 - такође мери ефикасност и рентабилност

$$ННМ = \frac{\text{некаMATни приходи} - \text{некаMATни расходи}}{\text{укупна актива}}$$

- ROI (Return on investment) – принос на улагања или способност остваривања зараде. Показује колико новчаних јединица власник заради на свакој новчаној јединици ангажованој у имовини. Већи ROI може да утиче на повећање ROE показатеља

$$ROI = \frac{\text{Нето профит по опорезивању}}{\text{Укупна актива (извори)}}$$

3.2.2 Показатељи ликвидности

Банке у тржишној економији морају да перманентно обезбеђују дневну ликвидност у свом пословању. Одржавање ликвидности сматра се основном претпоставком за одрживост банке на финансијском тржишту. Најкраће речено, **ликвидност** банке је њена способност да своје обавезе извршава о роковима доспећа. Банка се сматра ликвидном уколико поседује одговарајући износ одмах расположивих средстава увек када су она потребна или да може на време да обезбеди ликвидна средства путем позајмице или продајом капитала.

- Коефицијент текуће ликвидности (текући однос, енг. *current ratio*)
Овим индикатором се указује на могућност одржавања солвентности банке јер доводи у везу средства (имовину) која се трансформишу у новчани облик у року краћем од годину дана са обавезама које доспевају на наплату у том року. Коефицијент текуће ликвидности би требао бити 2 или више.

$$CR = \frac{\text{Текућа (краткотрајна) имовина}}{\text{Текуће (краткорочне) обавезе}}$$

- Коефицијент убрзане ликвидности (брзи однос, енг. *quick ratio*)
Указује на могућност одржања солвентности тиме што доводи у везу ону имовину банке која ће се врло брзо претворити у новац, са обавезама које брзо доспевају на наплату. Коефицијент убрзане ликвидности би требао бити мин 1.

$$QR = \frac{\text{Текућа (краткотрајна) имовина} - \text{залихе}}{\text{Текуће (краткорочне) обавезе}}$$

- Новчани однос (енг. *cash ratio*)
Овај индикатор има дневни значај јер ставља у однос новац и новчане еквиваленте са краткорочним обавезама предузећа. Сматра се да овај индикатор не би требао бити мањи од 0,10, односно од 10%.

$$ChR = \frac{\text{Новац и новчани еквиваленти}}{\text{Текуће (краткорочне) обавезе}}$$

- Коефицијент финансијске стабилности би требао бити мањи од 1 јер се из дела дугорочних извора треба финансирати не само дугорочна већ и краткорочна

имовина. Зато је смањење овог коефицијента позитивна тенденција, јер ако дуготрајна имовина ангажује ликвидну краткорочну имовину може доћи до смањења могућности подмирења текућих обавеза.

$$\text{КФС} = \frac{\text{Дуготрајна имовина}}{\text{Капитал} + \text{дугорочне обавезе}}$$

3.2.3 Показатељи задужености

Показатељи задужености указују на релативну задуженост банке и на терет камата и других фиксних издатака за накнаде финансијерима у укупној добити (зарадама пре камата и пореза). Представљају својеврсну меру степена ризика улагања у посматрану банку.

- Коефицијент задужености (енг. *debt ratio*)

Показује колики се део укупне имовине предузећа финансира из туђих извора. Због билансне једнакости активе и пасиве може се рећи да показује удео дуга у укупној финансијској структури банке, односно у његовој структури капитала. По правилу би требао бити 50% или мањи.

$$\text{DR} = \frac{\text{Укупне обавезе}}{\text{Укупна имовина}}$$

- Коефицијент финансирања (енг. *debt – equity ratio*)

Овај индикатор је комплементаран коефицијенту задужености, али расте брже од степена задужености. Банка се не би смела задуживати преко износа властитог капитала (главнице): **конзервативно правило (1:1)**

$$\text{DER} = \frac{\text{Укупне обавезе}}{\text{Власничка главница}}$$

- Коефицијент властитог финансирања

Вредност овог показатеља би по правилу трбала бити већа од 50% што значи да је већи део имовине финансиран из сопствених извора

$$\text{КВФ} = \frac{\text{Главница}}{\text{Укупна имовина}}$$

3.2.4 Показатељи економичности

Показатељи економичности мере однос прихода и расхода и показују колико се прихода оствари по јединици расхода. Уколико је вредност показатеља економичности мања од 1, то значи да банка послује са губитком.

$$\text{- Економичност укупног пословања} = \frac{\text{Укупни приходи}}{\text{Укупни расходи}}$$

$$\text{- Економичност продаје} = \frac{\text{Приход од продаје}}{\text{Расход од продаје}}$$

$$\text{- Економичност редовног пословања} = \frac{\text{Редовни приходи}}{\text{Редовни расходи}}$$

$$\text{- Економичност финансирања} = \frac{\text{Финансијски приходи}}{\text{Финансијски расходи}}$$

3.3 Ризици у банкарским пословима

Банкарски ризик би био вероватноћа губитка (смањења добити) као резултат неизвесних догађаја у пословању банке. Основни банкарски ризици су:

- Кредитни ризик: ризик смањења профита банке услед неизвршења обавеза дужника по основу доспелог дуга. Да би банка минимизирала кредитни ризик она:
 - Врши селекцију кредитних захтева
 - Лимитира износ задужења клијената
 - Диверсификује кредитне пласмане
 - Прибавља квалитетне инструменте обезбеђења кредита
- Ризик (не)ликвидности: ризик од смањења профита банке услед немогућности да измири своје доспеле обавезе. Ликвидност представља основни принцип банкарског пословања и налаже стално праћење и усклађивање позиције активе и пасиве, како би се негативне промене на обе стране биланса кориговале и свеле на минимум.

- Каматни ризик: неизвесност у погледу прихода банке због могућих промена каматне стопе. Фактори који дефинишу овај ризик су:
 - Рочна трансформација – краткорочна средства дугорочно пласирана и обрнуто
 - Каматна неусклађеност активе и пасиве
 - Пласмани банака у хартије од вредности
- Валутни ризик: ризик од смањења профита банке услед промене девизног курса. Постоји када су позиције активе и пасиве биланса банке у различитим валутама.

3.4 Значај банкарског система

Банке играју веома битну улогу у економском животу једне нације. Економски успех државе је блиско повезан са поузданошћу њеног банкарског система. Данас су модерне банке веома корисне за коришћење државних ресурса. Банке покрећу штедње грађана и користе их за улагање. На тај начин се подстиче штедња и раст стопе уштеде. Да банке не постоје велики део државног капитала би остао неупотребљен. Банка се може описати као срце економске структуре док је капитал који она производи крв система. Све док крв циркулише органи ће бити здрави и исправни.

Кључни аспекти на које утиче банкарски систем једне земље су:

- Формирање капитала, нарочито код неразвијених земаља или земаља у развоју. Ефикасан банкарски систем за комерцијалне сврхе је од највећег значаја да се постојећа штедња учини доступном предузетницима како би улагали и вршили производњу, што за узврат има економски раст.
- Отварање банака у различитим деловима земље је значајно и за ефективну монетизацију новца, нарочито у руралним и неразвијеним областима.
- Новине и иновације су кључни аспект за константно напредовање у сваком облику. У том случају, банке су неопходне јер оне финансирају нове, иновативне пројекте који убрзавају привредни раст посматране економије.
- Банке су извор кредита и других новчаних позајмица. Оне су извори новца за постављање новог или развој постојећег пословног уређења.

Функционисање целог света би се зауставило уколико би банке престале да постоје.

3.5 Значај ликвидности банака

Значај ликвидности за банкарско пословање проистиче из чињенице да банка може престати са радом у случају неликвидности, а уколико послује са губитком то не мора бити случај. Разлог томе је, што се губитак у пословању може покрити средствима фондова банке или санационим поступком, а у случају да се не обезбеде додатна средства, након искоришћења примарних и секундарних резерви ликвидности, банка ће престати са радом у прописаном року.

Могућност престанка рада банке услед неликвидности представља један од основних ризика у банкарском пословању. Због тога, битан фактор ликвидности банке је њена спремност да у сваком тренутку одговори доспелим обавезама, било да се ради о захтеву депонената за повлачењем својих депозита, захтеву комитената за повлачењем средстава из одобреног кредита, или о извршавању обавеза по основу отплате претходно узетих кредита.

У активи биланса банке, налазе се инструменти са различитим степеном ликвидности. На једном крају скале налазе се најликвидније позиције, а на другом, најнеликвидније позиције. Структура aktive показује позицију ликвидности банке.

У пасиви биланса неке обавезе банке су ликвидне, што значи да повериоци могу у сваком моменту или кратким роковима да траже новац у вези са депозитима или кредитима. У пасиви су и обавезе банке са дужим роковима враћања, било да се ради о депозитима или примљеним кредитима. Позиција ликвидности банке проистиче из компаративног односа ликвидности active и пасиве биланса банке.

Фактори ликвидности о којима банка води рачуна у конципирању пословне политике, везани су за понашање комитената при обављању новчаних трансакција и за специфичност услова у којима послују банке као што су:

- број комитената и обим њихових међусобних новчаних трансакција,
- степен привредне развијености подручја на којем банка послује,
- сезонски карактер производње на подручју пословања банке,
- као и макроекономски утицај привредног система, у смислу оштрине санкција према неликвидним банкама)

Већи степен ликвидности, а тиме и повољнију билансну позицију, имају оне банке:

- Чије активе имају повољније рочне и тржишне перформансе, у смислу краћих просечних рокова доспећа и/или степен тржишне трансвербилности позиција активе;
- Банке са просечно дужим роковима доспећа обавеза:
 - Банке са стабилним депозитним потенцијалом, тј. банке које имају већи коефицијент дугорочних депозита према краткорочним депозитима
 - Банке са диверсификованом структуром пласмана, у смислу рочности, секторско-комитентских односа, бољег бонитета комитената и повољније каматносно структуре

Осим наведених уобичајених ситуација када банка улази у зону неликвидности, тј. када не може испунити обавезе и оперативне налоге, за банку је најтежа позиција када истовремено уђе и у зону несолвентности, када није у стању да одговори укупним обавезама према акционарима, а понекад и према депозитарима. Нешто блажи облик неравнотеже је када је банка ликвидна, али несолвентна, што се може превазићи санацијом такве банке, преузимањем или ликвидацијом. Најблажи облик неравнотеже је када је банка солвентна, али неликвидна. У том случају могу бити ефикасне правовремене краткорочне трансакције у правцу усклађивања ликвидног потенцијала.

Посебно је значајан утицај Централне банке на ликвидност пословних банака преко веће или мање рестриктивности монетарне политике коју води. Пред Централном банком обично се јавља дилема, санирати краткорочну или дугорочну неликвидност. При томе, краткорочна ликвидносна неравнотежа настаје као последица краткорочних несинхронизованих прилива и одлива новчаних средстава. У том случају постоји већи одлив од прилива, тј. краткорочни дефицит ликвидних средстава, који се убрзо компензује већим приливом од одлива. Банка ће повремено имати дефицитне и суфицитне гепове, при чему ће бити примарно да краткорочним позајмицама попуњава дефицитне гепове. Развијено новчано тржиште веома ефикасно изравнава дефицитне и суфицитне ликвидносне гепове између појединих банака у различитим временским тачкама.

4 Дефинисање модела за имплементацију

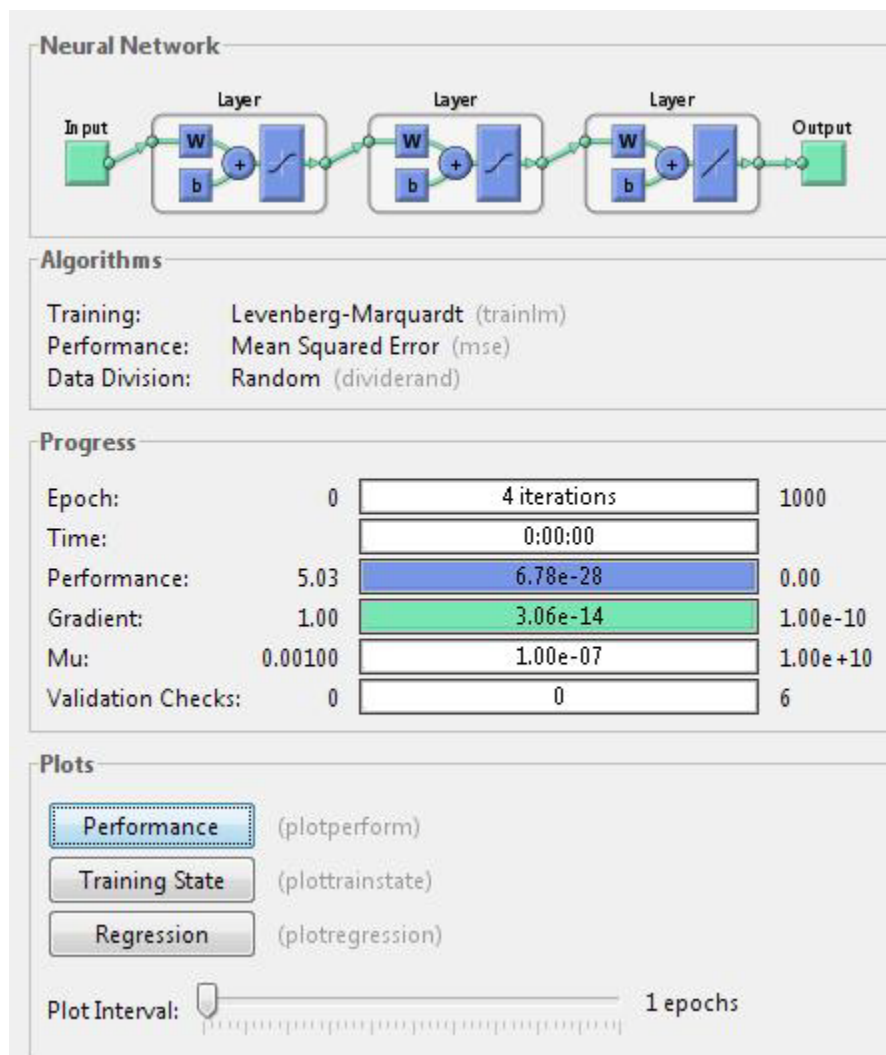
Подаци за ову студију су прикупљени из биланса стања и успеха Комерцијалне банке Србије у периоду од краја 2003. године до почетка 2010. Године. За сваку годину узима се 12 књиговодствених података (4 књиговодствена показатеља у 3 квартала). Изабрана су 4 показатеља која се најчешће примењују за предвиђање ликвидности банака у финансијској и књиговодственој литератури и која дају најбољи увид у ликвидност банака, а то су:

- **ROE** (Return on Equity) – принос на акционарски капитал, стопа поврата главнице за квартал k
- **NKM** (Нето каматна маржа) - показује однос између каматних прихода и каматних расхода остварен управљањем активом и пасивом банке за квартал k ,
- **ROI** (Return on investment) – принос на улагања или способност остваривања зараде за квартал k
- **KZ** (Коефицијент задужености) - показује колики се део укупне имовине предузећа финансира из туђих извора за квартал k

Тражени излаз је коефицијент финансијске стабилности (**КФС**) за квартал $k+1$. Овај коефицијент би требао бити мањи од 1 јер се из дела дугорочних извора треба финансирати не само дугорочна већ и краткорочна имовина. Такође, начело финансијске стабилности налаже да однос дугорочно везаних средстава и квалитетних извора, што представља коефицијент финансијске стабилности, мора бити мањи или једнак 1. Дакле, уколико је овај показатељ нижи од 1 то значи да су трајни и дугорочни капитал већи од дугорочно везане имовине, тј. у оквиру дугорочног финансирања постоји сигурност за одржавање ликвидности.

4.1 Дефинисање модела неуронске мреже

За имплементацију неуронске мреже користимо софтверски програм MATLAB R2008a. За учење, тестирање и валидацију неуронске мреже користе се подаци у периоду од 22 квартала, а предвиђају се наредна 3 квартала.



Слика 15. Изглед и тренирање мреже у MATLAB -у

Како би се олакшао и убрзао процес формирања, тренирања и симулације мрежа, у MATLAB – у је дефинисана функција у која има следећу структуру:


```
function mojaFja()
%definisanje excel fajla
fajl = 'C:\Users\Jovana\Desktop\za mrezu1.xlsx';

%podaci za treniranje mreze
trenInputi = (xlsread(fajl, 'Sheet5', 'B3:E6'));
trenTargeti = (xlsread(fajl, 'Sheet5', 'G3:G6'));

%podaci za simulaciju meze
simInputi = (xlsread(fajl, 'Sheet5', 'B12:E12'));

%definisanje mreza
nmreza1 = newff(trenInputi, trenTargeti, 5, {'logsig'});
nmreza2 = newff(trenInputi, trenTargeti, 10, {'logsig'});
nmreza3 = newff(trenInputi, trenTargeti, 15, {'logsig'});
nmreza4 = newff(trenInputi, trenTargeti, 20, {'logsig'});
nmreza5 = newff(trenInputi, trenTargeti, [5 5], {'logsig', 'logsig'});
nmreza6 = newff(trenInputi, trenTargeti, [10 10], {'logsig', 'logsig'});
nmreza7 = newff(trenInputi, trenTargeti, [15 15], {'logsig', 'logsig'});
nmreza8 = newff(trenInputi, trenTargeti, [20 20], {'logsig', 'logsig'});
nmreza9 = newff(trenInputi, trenTargeti, 5, {'tansig'});
nmreza10 = newff(trenInputi, trenTargeti, 10, {'tansig'});
nmreza11 = newff(trenInputi, trenTargeti, 15, {'tansig'});
nmreza12 = newff(trenInputi, trenTargeti, 20, {'tansig'});
nmreza13 = newff(trenInputi, trenTargeti, [5 5], {'tansig', 'tansig'});
nmreza14 = newff(trenInputi, trenTargeti, [10 10], {'tansig', 'tansig'});
nmreza15 = newff(trenInputi, trenTargeti, [15 15], {'tansig', 'tansig'});
nmreza16 = newff(trenInputi, trenTargeti, [20 20], {'tansig', 'tansig'});

%definisanje parametara mreza
nmreza1.trainparam.showWindow = false;
nmreza2.trainparam.showWindow = false;
nmreza3.trainparam.showWindow = false;
nmreza4.trainparam.showWindow = false;
nmreza5.trainparam.showWindow = false;
nmreza6.trainparam.showWindow = false;
nmreza7.trainparam.showWindow = false;
nmreza8.trainparam.showWindow = false;
nmreza9.trainparam.showWindow = false;
nmreza10.trainparam.showWindow = false;
nmreza11.trainparam.showWindow = false;
nmreza12.trainparam.showWindow = false;
nmreza13.trainparam.showWindow = false;
nmreza14.trainparam.showWindow = false;
nmreza15.trainparam.showWindow = false;
nmreza16.trainparam.showWindow = false;
```

%treniranje mreza

```
tmreza1 = train(nmreza1, trenInputi, trenTargeti);  
tmreza2 = train(nmreza2, trenInputi, trenTargeti);  
tmreza3 = train(nmreza3, trenInputi, trenTargeti);  
tmreza4 = train(nmreza4, trenInputi, trenTargeti);  
tmreza5 = train(nmreza5, trenInputi, trenTargeti);  
tmreza6 = train(nmreza6, trenInputi, trenTargeti);  
tmreza7 = train(nmreza7, trenInputi, trenTargeti);  
tmreza8 = train(nmreza8, trenInputi, trenTargeti);  
tmreza9 = train(nmreza9, trenInputi, trenTargeti);  
tmreza10 = train(nmreza10, trenInputi, trenTargeti);  
tmreza11 = train(nmreza11, trenInputi, trenTargeti);  
tmreza12= train(nmreza12, trenInputi, trenTargeti);  
tmreza13 = train(nmreza13, trenInputi, trenTargeti);  
tmreza14 = train(nmreza14, trenInputi, trenTargeti);  
tmreza15 = train(nmreza15, trenInputi, trenTargeti);  
tmreza16= train(nmreza16, trenInputi, trenTargeti);
```

%simulacija

```
simlzlazi1 = (sim(tmreza1, simInputi))';  
simlzlazi2 = (sim(tmreza2, simInputi))';  
simlzlazi3 = (sim(tmreza3, simInputi))';  
simlzlazi4 = (sim(tmreza4, simInputi))';  
simlzlazi5 = (sim(tmreza5, simInputi))';  
simlzlazi6 = (sim(tmreza6, simInputi))';  
simlzlazi7 = (sim(tmreza7, simInputi))';  
simlzlazi8 = (sim(tmreza8, simInputi))';  
simlzlazi9 = (sim(tmreza9, simInputi))';  
simlzlazi10 = (sim(tmreza10, simInputi))';  
simlzlazi11 = (sim(tmreza11, simInputi))';  
simlzlazi12 = (sim(tmreza12, simInputi))';  
simlzlazi13 = (sim(tmreza13, simInputi))';  
simlzlazi14 = (sim(tmreza14, simInputi))';  
simlzlazi15 = (sim(tmreza15, simInputi))';  
simlzlazi16= (sim(tmreza16, simInputi))';
```

%konstruisanje matrice izalza

```
matricalzlaza = [simlzlazi1 simlzlazi2 simlzlazi3 simlzlazi4 simlzlazi5 simlzlazi6 simlzlazi7 simlzlazi8  
simlzlazi9 simlzlazi10 simlzlazi11 simlzlazi12 simlzlazi13 simlzlazi14 simlzlazi15 simlzlazi16];
```

%upisivanje matrice u fajl

```
xlswrite(fajl, matricalzlaza, 'Sheet5', 'K7:Z7');
```

end

Приликом тестирања мреже користимо комбинацију модела са једним и са два скривена слоја. За сваку комбинацију број неурона се креће од 5 до 20 са кораком од 5 неурона. Као активационе функције користимо логистичку функцију (Табела 1.) и хиперболички тангенс (Табела 2.), док на излазном слоју неуронске мреже користимо линеарну активациону функцију. На крају, усваја се она мрежа која је дала најбоље резултате.

DEFINISANJE IZLAZA - LOGISTICKA F-JA

	1				2			
	5	10	15	20	5	10	15	20
targeti								
1.178743	0.825184	0.07083	1.344812	1.273380838	0.853274561	1.267930118	0.802855219	1.976548
1.256975	0.839439	1.614541	0.799028	1.319062612	1.252275994	1.263259902	1.051967089	1.831783
1.355576	0.945974	2.576239	0.919641	0.78727261	1.767899975	1.33414751	1.461574466	2.613394

Табела 1. Излази добијени применом логистичке ф-је

DEFINISANJE IZLAZA - TANGENS HIPERBOLICKI

	1				2			
	5	10	15	20	5	10	15	20
0.897049	0.781858	0.70394	0.928405	1.278853	0.671937	1.006744	0.702885	
0.65946	0.76447	0.678531	0.955786	0.755344	0.907364	1.104203	0.898592	
0.777285	0.077919	0.18838	1.440385	0.729876	1.323786	1.334692	1.248453	

Табела 2. Излази добијени примено ф-је тангенс-хиперболички

4.2 Параметри за мерење резултата предвиђања

За упоређивање квалитета предвиђања различитих модела оцењених над истим скупом података и са једнаким бројем предвиђања могу се користити параметри као што су средња квадратна грешка, корен средње квадратне грешке, средња апсолутна процентуална грешка, средња апсолутна грешка, симетрична средња апсолутна процентуална грешка, итд. За било које коришћење ових показатеља, мања вредност указује на квалитетнију моћ предвиђања модела.

4.2.1 Корен средње квадратне грешке

Уколико је дата временска серија y_1, \dots, y_t и предвиђене вредности као F_1, \dots, F_t модел корена средње квадратне грешке се може дефинисати као:

$$\text{КСКГ} = \sqrt{\frac{1}{2} \sum_{i=1}^t (y_i - F_i)^2}$$

1				2			
5	10	15	20	5	10	15	20
(ТАРГЕТ - ИЗЛАЗ) ²							
0.12500375	1.22747024	0.02757886	0.008956317	0.105929716	0.007954339	0.141291637	0.636493253
0.17433635	0.12785347	0.209715648	0.003854855	0.0000221	0.00003950	0.042028299	0.330404441
0.16777349	1.49001921	0.190038981	0.32296837	0.170011331	0.000459166	0.011235744	1.582107739

Табела 3. Корен средње квадратне грешке за логистичку ф-ју

1				2			
5	10	15	20	5	10	15	20
(ТАРГЕТ - ИЗЛАЗ) ²							
0.079351384	0.15751805	0.22543828	0.062669175	0.010021984	0.25685238	0.02958376	0.22644065
0.357024666	0.242561164	0.33459782	0.090715011	0.251633318	0.12222761	0.0233393	0.12843868
0.334420264	1.632406497	1.36234668	0.007192561	0.39150062	0.00101056	0.00043611	0.01147535

Табела 4. Корен средње квадратне грешке за ф-ју тангенс-хиперболички

4.2.2 Средња апсолутна процентуална грешка

Уколико је дата временска серија y_1, \dots, y_t и предвиђене вредности као F_1, \dots, F_t модел средње апсолутне процентуалне грешке се може дефинисати као:

$$\text{САПГ} = 100 \frac{1}{t} \sum_{i=1}^t \left| \frac{y_i - F_i}{y_t} \right|$$

1				2			
АБС((ТАРГЕТ-ИЗЛАЗ)/ТАРГЕТ)							
5	10	15	20	5	10	15	20
0.29994552	0.93991018	0.140886384	0.080287068	0.276114854	0.075662888	0.318888674	0.676827146
0.33217526	0.28446548	0.364324797	0.049394355	0.003738453	0.004999913	0.163096343	0.457294787
0.30216064	0.90047605	0.321586331	0.419233742	0.304169152	0.015807426	0.078194671	0.927885229

Табела 5. Средња апсолутна процентуална грешка за логистичку ϕ - η

1				2			
АБС((ТАРГЕТ-ИЗЛАЗ)/ТАРГЕТ)							
5	10	15	20	5	10	15	20
0.238978109	0.336702259	0.40280486	0.212377182	0.084929333	0.42995467	0.14591756	0.40369937
0.475359769	0.391817606	0.46018755	0.239614388	0.399077631	0.27813649	0.12153943	0.28511576
0.426601646	0.942519602	0.86103351	0.062563062	0.461575194	0.02345079	0.01540549	0.07902404

Табела 6. Средња апсолутна процентуална грешка за ϕ - η тангенс-хиперболички

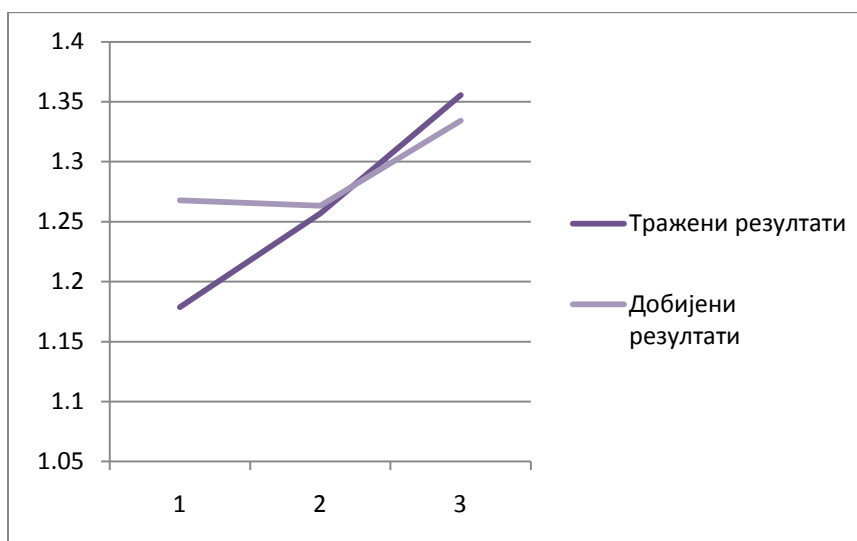
5 Резултати модела

Резултати тестирања неуронске мреже су дати у Табели 7. у зависности од броја скривених слојева, броја скривених неурона и активационе функције неуронске мреже.

Активациона функција		Логистичка функција Параметар		Хипер. тангенс Параметар	
Број скривених слојева	Број неурона	КСКГ	САПГ	КСКГ	САПГ
1	5	0.3946	31.1427	0.5069	38.0313
	10	0.9739	70.8284	0.8231	55.7013
	15	0.3774	27.5599	0.8005	57.4675
	20	0.3346	18.2972	0.2314	17.1518
2	5	0.3033	19.4674	0.4666	31.5194
	10	0.0531	3.2157	0.3559	24.3847
	15	0.2547	18.6727	0.1334	9.4287
	20	0.9218	68.7336	0.3495	25.5946

Табела 7. Добијени резултати применом неуронске мреже

Као што се види из табеле најбоље резултате при тестирању показала је мрежа са два скривена слоја, 10 скривених неурона и логистичком функцијом као активационом функцијом. Вредност корена средње квадратне грешке је **0,0531**, док је средња апсолутна процентуална грешка **3,2157**, што значи да је мрежа успешно предвидела резултат. Графички приказ резултата дат је на слици 15.



Слика 16. Графички приказ резултата тестирања неуронске мреже

Са графика се види да у првом периоду (септембар 2009.) прогнозирања мрежа даје лоше резултате. Највеће поклапање између стварних резултата и оних које је мреже изгенерисала, тј. најтачније предвиђање мреже, је у другом периоду (децембар 2009.), да би у трећем периоду (март 2010.) мрежа поново почела да одступа од тражених резултата.

Могући узрок оваквог одступања је тај што се у овом моделу посматрају претходни квартали да би се предвидео наредни, односно користимо први квартал како би предвидели резултате за други, затим користимо други квартал како би предвидели резултате за трећи итд.

Како би проверила прецизност мреже и евентуално постојање сезоналности (цикличне или периодичне флукуације у временским серијама која се одвија или понавља у истим фазама циклчног периода), променићу улазе у претходно дефинисане неуронске мреже, како за тренирање тако и за симулацију. Дакле, уместо предвиђања наредног квартала ($k+1$) на основу претходног (k), предвиђаћу први квартал текуће године на основу првих квартала из претходних година, односно други квартал на основу других квартала из претходних година итд.

5.1 Дефинисање алтернативног модела неуронских мрежа

За учење, тестирање и валидацију неуронске мреже за предвиђање резултата у првом кварталу ове године користе се подаци у периоду од 5 првих квартала из претходних година, за предвиђање резултата у другом кварталу ове године користе се подаци у периоду од 4 друга квартала из претходних година, за предвиђање резултата у трећем кварталу ове године користе се подаци у периоду од 4 трећа квартала из претходних година и за предвиђање резултата у четвртном кварталу ове године користе се подаци у периоду од 4 четврта квартала из претходних година.

Приликом тестирања мреже користимо комбинацију модела као у претходном случају. На крају, усваја се она мрежа која је дала најбоље резултате.

Активациона функција		Логистичка функција Параметар		Хипер. тангенс Параметар	
Број скривених слојева	Број неурона	КСКГ	САПГ	КСКГ	САПГ
1	5	0,2167	0,3434	0,0076	0,0642
	10	0,0166	0,6678	1,7105	1,9925
	15	5,3800	1,6494	3,4167	1,3320
	20	2,1912	0,8706	1,8738	0,9862
2	5	0,4987	6,2080	1,2897	20,9792
	10	0,0320	1,3631	0,5270	2,2054
	15	0,0100	0,1817	0,6374	0,6368
	20	0,3172	0,3690	3,4037	1,3897

Табела 8. Добијени резултати за март 2010.

Активациона функција		Логистичка функција Параметар		Хипер. тангенс Параметар	
Број скривених слојева	Број неурона	КСКГ	САПГ	КСКГ	САПГ
1	5	0,0460	0,2042	0,0001	0,0089
	10	0,3524	0,2998	0,3495	0,2979
	15	0,9030	0,2169	0,8602	0,2031
	20	0,1364	0,2904	0,6735	0,0648
2	5	0,3449	0,1536	0,4273	0,2004
	10	0,1250	0,1427	1,4101	0,3665
	15	0,9099	0,4276	0,4862	0,2447
	20	0,2764	0,2136	0,3404	0,1848

Табела 9. Добијени резултати за јун 2010.

Активациона функција		Логистичка функција Параметар		Хипер. тангенс Параметар	
Број скривених слојева	Број неурона	КСКГ	САПГ	КСКГ	САПГ
1	5	0,0002	0,0116	0,9080	0,8084
	10	0,7190	0,7226	2,8890	1,4369
	15	0,1260	1,4906	0,4366	0,5660
	20	1,8605	1,2249	2,0709	1,3160
2	5	0,1592	5,2096	0,1176	5,5119
	10	1,1236	0,8477	0,0885	0,1301
	15	0,5593	2,6284	0,9227	0,8369
	20	0,0461	1,2373	0,1470	0,8458

Табела 10. Добијени резултати за сеп. 2010.

Активациона функција		Логистичка функција		Хипер. тангенс	
		Параметар		Параметар	
Број скривених слојева	Број неурона	КСКГ	САПГ	КСКГ	САПГ
1	5	1,1353	0,8477	0,0147	0,0965
	10	2,2520	2,2726	0,2462	2,9733
	15	0,7631	2,5734	1,2253	1,6158
	20	0,8016	0,0567	6,0867	4,1563
2	5	0,6180	0,3019	0,7706	0,0484
	10	0,2040	0,7102	0,1484	2,4877
	15	0,3830	0,2076	0,0811	0,2073
	20	0,1587	0,3456	3,7496	2,0647

Табела 11. Добијени резултати за дец. 2010.

5.2 Резултати алтернативног модела

Из претходно табела се види да су грешке приликом предвиђања мање него у претходном случају.

Најбоље резултате при тестирању, односно најмању грешку у три случаја показала је мрежа са једним скривеним слојем, 5 скривених неурона и функцијом тангенс-хиперболички, а у једном случају најпрецизнија је мрежа са једним скривеним слојем, 5 скривених неурона и логистичком функцијом као активационом функцијом.

У оба случаја као најбоља мрежа, показала се мрежа са једним скривеним слојем и 5 неурона. Са знатно већом прецизношћу, можемо да предвидимо вредност коефицијента финансијске стабилности за други квартал (јун) 2010. године од **1,0983**. Како овај коефицијент мора бити мањи од 1 да би банка била ликвидна, мрежа нам предвиђа, а на основу других квартала из претходних година, да ће у овом периоду банка бити мање ликвидна.

6 Закључак

Једна од области развоја информационих технологија која је пронашла примену у пракси је развој вештачких неуронских мрежа. Развој вештачких неуронских мрежа довео је до великог напретка на пољу вештачке интелигенције. Многи сматрају да су вештачке неуронске мреже највећи технолошки напредак у протеклој деценији, јер су се показале незаменљивим у ситуацијама где је могућност идентификације скривених веза и патерна кључна за успешна предвиђања

Овај дипломски рад проучава могућност примене неуронских мрежа у пословању, као и могућа побољшања мрежа како би се добијали што прецизнији резултати.

За праћење и предвиђање ликвидности банака направљен је модел који на основу 4 финансијска показатеља покушава да пронађе везу између кварталних периода како би се што прецизније предвидело касније кретање ликвидности. Модел који је предложен у оквиру рада, је показао одређена одступања резултата у односу на стварне податке, због чега се уводи алтернативни модел. Решења алтернативног модела показују знатно мања одступања чиме указују на већу зависност истих годишњих периода (квартала) него што је зависност наредног квартала ($k+1$) од претходног (k).

Иако су решења оба модела неуронских мрежа корисна и пружају значајне информације о пословању банке, као бољи се ипак показао алтернативни модел који је благо измењен у односу на првобитни. Због тога не треба одустајати од примена неуронских мрежа за предвиђање успешности, не само ликвидности банака већ и њиховог целокупног пословања. Примена неуронских мрежа у пословању је све чешћа појава, а разлог томе су велика еластичност мрежа према поремећајима у улазним подацима и способност мреже да „учи“. Неуронске мреже је могуће унапредити и применом другог типа неуронске мреже, увођењем хибридног модел, комбиновањем са *fuzzy* логиком.

7 Литература

1. **Argyris Argyrou**,(2006) - Predicting financial distress using neural networks: another episode to the serial?, Swedish School of Economics and Business Administration, Sweden; *March, 2006*.
2. **Ben Crose, Patrick van der Smagt** – An introduction to neural networks; *November, 1996*.
3. **G. Peter Zhang** – Business forecasting with Artificial Neural Networks *October, 2003*.
4. **Jeffrey L. Callen, Clarence C.Y. Kwan, Patrick C.Y. Yip, Yufei Yuan** – Neural Network forecasting of quarterly accounting earnings, *1996 International Journal of Forecasting*
5. **Kate A. Smith, Jatinder N.D. Gupta** - Neural networks in business: techniques and applications for the operations researcher; *May, 2000*.
6. **Lin Zhao, Fred Collopy, Miles Kennedy** – The problem of Neural Networks in business forecasting: An attempt to reproduce the Hill; *October, 2003*.
7. **Ming Zhang** – Artificial higher order Neural networks for economy and business; *2009*.
8. **Muriel Perez** – Neural networks applications in bankruptcy forecasting: A state of the art; *April, 2009*.
9. **Choong Nyong Kim, Kinsun Tam** - A neural network approach to compare predictive value of accounting versus market; *May, 2009*.
10. **Crescenzo Gallo** - Artificial Neural Networks in Financial Modelling, Dipartimento di Scienze Economiche, Matematiche e Statistiche, Universit`a di Foggia ,Foggia, Italy; *November, 2006*.
11. **Harlan L. Etheridge, Kathy H. Y. Hsu** – Using Artificial neural Networks to examine semiotic theories of accounting accruals; *2004 Journal of Business & Economics Research*