

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/298968671>

# МЕТОДИ ЗА ОБУЧЕНИЕТО НА НЕВРОННИ МРЕЖИ

Conference Paper · January 2007

DOI: 10.13140/RG.2.1.2668.7125

---

CITATIONS

0

READS

3,714

3 authors, including:



Veselina Nedeva

Trakia University

68 PUBLICATIONS 182 CITATIONS

SEE PROFILE

Some of the authors of this publication are also working on these related projects:



Application of virtual laboratories in universities [View project](#)



Digital skills and Digital competence - Case study [View project](#)

Симеон Й.Мръчев, Веселина И.Недева и др. МЕТОДИ ЗА ОБУЧЕНИЕТО НА НЕВРОННИ МРЕЖИ, Международна научна конференция „Наука, техника, технологии и образование“, Ямбол, 2007, стр.84-96

## МЕТОДИ ЗА ОБУЧЕНИЕТО НА НЕВРОННИ МРЕЖИ

Симеон Й.Мръчев\*, Веселина И.Недева, Ташо Б.Георгиев, Димитър Г.Гинчев

Абстракт: В Увода се въвежда понятието за невроинтелект и се посочват целите на настоящата работа, а именно: описването на идеите за методите на обучението на невронните мрежи без задълбочено математическо изложение. В същността на работата се излагат: Обучението с учител и без учител; Метода на обучението на Д.Хебб (алгоритъм на обучението; сигнално обучение; диференциално обучение); Входните и изходните звезди на С.Гросберг (Обучение на входната и изходната звезди); Обучението на перцептрона на Р.Розенблатт; Метода на обучението на Б.Уидроу и М.Хофф; Метода на статистическото обучение; Самоорганизацията на Т.Кохонен; И други. В „Заклучението“ се посочва приложението за създаването на Памет-Невро-Компютри.

Ключови думи: Невронни мрежи; Обучение с учител; Обучение без учител; Памет-Невро-Компютри (ПаНеКо); Методи за обучение и др.

## EDUCATIONAL METHODS FOR NEURO-NETWORKS

In the Introduction of the following paper we have introduced and explained the definition of the term neuro-intellect and have shown the aim of the paper: description of the methods for the education of neuro-networks without profound mathematical presentation. In the main part of the paper we have shown: Education with or without a teacher; The method of education by D.Hebb (educational algorithm; signal education; deferential education); The Input and Output stars by S.Grosberg (Education of Input and Output stars); Education of perceptrons by R.Rosenblatt; The Method of education by B.Widrow and M.Hoff; The Method of statistical education; Self-organization by T. Kohonen etc. In the conclusion we have described the application of these methods in Memory-Neuro-Computer (MeNeCo project of S. Mrchev from May 9, 1990).

Key words: Neuro-networks, Education with a teacher; Education without a teacher; Memory-Neuro-Computer (MeNeCo) ect.

УВОД – по [11] и др.

Съществуват две направления в теорията на Изкуствения Интелект (ИИ). Първото направление се явява традиционното. То използва методите на логическите разсъждения и символната обработка на информацията. Второто направление е свързано с построяването на мрежи, състоящи се от невронни елементи. То се опира на биологическите основи на естествения интелект и позволява да се проектират системи, способни на обучение и самоорганизация. Използването на невромрежови методи в теорията на ИИ се нарича невроинтелект.

Изкуствените невронни мрежи (НМ) се обучават с разнообразни методи. За щастие, повечето от методите за обучение изхождат от общи предпоставки и имат много идентични характеристики. Целта на настоящата работа се явява

обзора на някои фундаментални алгоритми от гл.т. на тяхната текуща приложимост и историческа важност. След запознаването с тези фундаментални алгоритми, другите основани на тях алгоритми, ще бъдат достатъчно леки за разбиране, и новите разработки също могат да бъдат добре разбрани и развити. Така ще се създаде цялостна представа за изучаваната област.

## 1. ОБУЧЕНИЕ С УЧИТЕЛ И БЕЗ УЧИТЕЛ - по [11] и др.

Обучаващите алгоритми могат да бъдат класифицирани като алгоритми за обучение с учител и обучение без учител. В първият случай съществува учител, който подава входните образи на НМ, сравнява резултатите с необходимите, а след това настройва теглата на НМ по такъв начин, че да се намаляват различията. Трудно е да се представи такъв обучаващ механизъм в биологическите системи. Следователно, въпреки че дадения подход доведе до големи успехи при решаването на приложни задачи, той се отхвърля от тези изследователи, които предполагат, че изкуствените невронни мрежи обезателно трябва да използват тези механизми, които са характерни при човешкия мозък [11].

Във втория случай обучението става без учител: при подаването на входните образи НМ се самоорганизира, строявайки своите тегла съгласно определен алгоритъм. Исканият изход в процеса на обучението не е указан, поради което резултатите от определянето на възбуждащите образи за конкретни неврони са непредсказуеми. При това обаче, НМ се организира във форма, отразяваща съществените характеристики на обучаващия набор. Например, входните образи могат да бъдат класифицирани съгласно степента на тяхното сходство така, че образите от един клас активират един и същ изходен неврон [11].

## 2. МЕТОД НА ОБУЧЕНИЕТО НА Д.ХЕББ – по [11] и др.

Работите на Д.О.Хебб осигуриха основата на повечето алгоритми на обучението, които бяха разработени по-късно. Д.Хебб определи, че обучението в биологичните системи става посредством някакви физически изменения в невроните, но не определи как това се осъществява в действителност. Основвайки се на физиологичните и психологичните изследвания, Д.Хебб интуитивно издига хипотезата за това по какъв начин може да се обучи набор от биологични неврони. Неговата теория предполага само локално взаимодействие между невроните при отсъствие на глобален учител. Следователно, обучението се явява неуправляемо. Независимо от това, че неговата работа не включва математическия анализ, идеите изложени в нея са толкова ясни и изящни, че получиха статус на универсални допускания. Неговата книга стана класическа и широко се изучава от специалистите, които сериозно се интересуват от тази област [11].

**АЛГОРИТЪМ НА ОБУЧЕНИЕТО НА Д.ХЕББ.** По същество, Д.Хебб предполага, че синаптичното съединение на два неврона се усилва, ако тези два неврона са възбудени. Това може да се представи като усилване на синапса в съответствие с корелацията на нивата на възбудените неврони, съединени с

дадения синапс. Затова алгоритъмът на обучението на Д.Хебб понякога се нарича корелационен алгоритъм [11].

Идеята на алгоритъма се изразява със следното равенство:

$$W_{ij}(t+1) = W_{ij}(t) + NET_i \cdot NET_j,$$

където:  $W_{ij}$  е силата на синапса от неврона  $i$  към неврона  $j$  в момента на времето  $t$ ;  $NET_i$  е нивото на възбуждане на пресинаптичния неврон;  $NET_j$  е нивото на възбуждане на постсинаптичния неврон [11].

Концепцията на Д.Хебб отговаря на сложния въпрос: по какъв начин обучението може да стане без учител? В метода на Хебб обучението се явява изключително локално явление, обхващащо само два неврона и съединяващия ги синапс и не се изисква глобална система на обратната връзка за развитието на невронните образования [11].

Следващото използване на метода на Хебб за обучението на невронните мрежи доведе до големи успехи, но наред с това показва ограничеността на метода. Някои образи просто не могат да се използват за обучение чрез този метод. В резултат на това се появило голямо количество разширения и нововъведения, повечето от които в значителна степен се основават на работата на Д.Хебб.

**МЕТОД НА СИГНАЛНОТО ОБУЧЕНИЕ ПО Д.ХЕББ.** Както видяхме по-горе, изхода  $NET$  на простия изкуствен неврон се явява претеглената сума на неговите входове. Това може да бъде изразено по следния начин:

$$NET_j = \sum_i OUT_i \cdot W_{ij},$$

където:  $NET_j$  е изхода  $NET$  на неврона  $j$ ;  $OUT$  е изхода на неврона  $i$ ;  $W_{ij}$  е теглото на връзката на неврона  $i$  с неврона  $j$ .

Може да се покаже, че в този случай линейната многослойна мрежа не се явява по-мощна, отколкото еднослойната мрежа и разглежданите възможности на мрежата могат да се подобрят само с въвеждането на нелинейности в предварителната функция на неврона. Казва се, че мрежата, използваща сигмоидална функция на активация и метода на обучение на Д. Хебб, се обучава по сигналния метод на Д. Хебб. В този случай уравнението на Д. Хебб се модифицира по следния начин [11]:

$$OUT_i = \frac{1}{1 + \exp(-NET_i)} = F(NET_i); W_{ij}(t+i) = W_{ij}(t) + OUT_i \cdot OUT_j$$

където:  $W_{ij}(t)$  е силата на синапса от неврона  $i$  към неврона  $j$  в момента от времето  $t$ ;  $OUT_i$  е изходното ниво на пресинаптичния неврон на  $F(NET_i)$ ;  $OUT_j$  е изходното ниво на постсинаптичния неврон, равно на  $F(NET)$ .

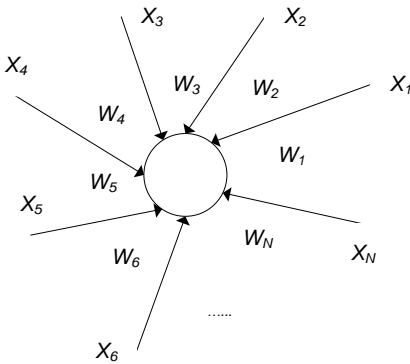
МЕТОД на ДИФЕРЕНЦИАЛНОТО ОБУЧЕНИЕ на Д. Хебб [11]. Методът на сигналното обучение на Д. Хебб предполага изчислението на изменението на предущите изходи за определянето на измененията на теглата. Методът на диференциалното обучение на Д. Хебб използва следното равенство [11]:

$$W_{ij}(t+1) = W_{ij}(t) + [OUT_i(t) - OUT_i(t-1)][OUT_j(t) - OUT_j(t-1)],$$

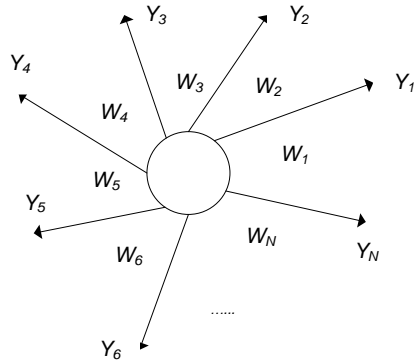
където:  $W_{ij}(t)$  е силата на синапса от неворна  $i$  към неврона  $j$  в момента от времето  $t$ ;  $OUT_i(t)$  е изходното ниво на пресинаптичния неврон в момента от времето  $t$ ;  $OUT_j(t)$  е изходното ниво на постсинаптичния неврон в момента от времето  $t$ .

#### 4. ВХОДНИ и ИЗХОДНИ ЗВЕЗДИ – по [11] и други.

Много общи идеи, използвани в изкуствените невронни мрежи, се разглеждат в работите на С. Гросберг. В качеството на пример може да разгледаме конфигурациите на входните и изходните звезди, използвани в много мрежови парадигми. Входната звезда, както е показано на фиг.1, се състои от неврон, на който се подават група от входове чрез синаптични тегла. Изходната звезда, показана на фиг.2, се явява неврон, управляващ група от тегла. Входните и изходните звезди могат да бъдат взаимно съединени в мрежа с различна сложност. С. Гросберг ги разглежда като модел на определени биологични функции. Вида на звездата определя нейното название, като звездите обикновено се изобразяват в мрежата по друг начин [11].



Фиг.1. Входна звезда – по [11].



Фиг.2. Изходна звезда – по [11].

ОБУЧЕНИЕ на ВХОДНАТА ЗВЕЗДА [11]. Входната звезда изпълнява разпознаването на образи, тоест тя се обучава да реагира на определен входен вектор  $X$  и на никой друг. Това обучение се реализира, като се настройват теглата по такъв начин, че те да съответстват на входния вектор. Изходът на входната звезда се определя като претеглена сума на нейните входове. От друга гледна точка, изходът може да се разглежда като отношение на входния вектор с тегловния вектор, или мярката на сходството на нормализирани вектори.

Следователно, неврона е длъжен да реагира най-силно на входния образ, за който е бил обучен [11]. Процесът на обучението се изразява така [11]:

$$W_i(t+1) = W_i(t) + \alpha[x_i - W_i(t)],$$

където:  $W_i$  е теглото на входа  $x_i$ , като  $x_i$  е  $i$ -тия вход;  $\alpha$  е нормиращия коефициент на обучението, който има начално значение 0,1 и постепенно намалява в процеса на обучението [11].

След завършването на обучението подаването на входния вектор  $X$  ще активизира обучен входен неврон. Това може да се разглежда като единен обучаващ цикъл, ако  $\alpha$  е установен в 1, обаче в този случай се изключва способността на входната звезда за обобщение. Добре обучената входна звезда ще реагира не само на определен единичен вектор, но също и на незначителни изменения на този вектор. Това се достига с постепенна настройка на невронните тегла при подаването в процеса на обучението на вектори, представляващи нормални вариации на входния вектор. Теглото се настройва по такъв начин, че да усредни величините на обучаващите вектори, и невроните получават способността да реагират на всеки вектор от този клас [11].

ОБУЧЕНИЕ на ИЗХОДНАТА ЗВЕЗДА [11]. В това време когато входната звезда се възбужда всеки път при появяването на определен входен вектор, изходната звезда има допълнителна функция: тя изработва необходимия възбуждащ сигнал за другите неврони всеки път, когато се възбужда [11].

За да обучим неврона на изходната звезда, трябва неговото тегло да се настройва с искания целеви вектор. Алгоритъмът на обучението може да се представи символично по следния начин [11]:


$$W_i(t+1) = W_i(t) + \beta[y_i - W_i(t)],$$

където:  $\beta$  представлява нормиращ коефициент на обучението, който в началото е приблизително равен на единица и постепенно намалява до нула в процеса на обучението.

Както и за входната звезда, теглата на изходната звезда постепенно се настройват над множеството от вектори, представляващи обичайни вариации на идеалния вектор. В този случай изходният сигнал на невроните се явява статистическа характеристика на обучаващия набор и може в действителност да се приближи в процеса на обучението към идеалния вектор при подаването само на изкривени версии на вектора [11].

#### 5. ОБУЧЕНИЕ на ПЕРЦЕПТРОНА – по [11] и други.

В 1957 год. Р.Розенблат разработи модел, който предизвика голям интерес в изследователите. Независимо от някои ограничения на неговата изходна форма, той стана основа за много съвременни, по-сложни алгоритми за обучението с учител.



Фиг. 3. Структурен вид на Перцептрона [11].

Перцептрона се явява двустепенна нерекурентна мрежа, чийто вид е показан на фиг.3. Тя използва алгоритъм на обучението с учител, или с други думи, обучаващата извадка се състои от множество входни вектори, за всеки от който е указан свой искан вектор на целите. Компонентите на входния вектор са представени в непрекъснат диапазон от значения. Компонентите на вектора на целта се явяват двоични величини (0 или 1). След обучението мрежата получава на входа набор от непрекъснати входове и изработва искания изход във вид на вектор с бинарни компоненти [11].

Обучението се осъществява по следния начин [11]:

1. Рандомизират се всички тегла на мрежата в малки величини;
2. На входа се подава входния обучаващ вектор  $X$  и се изчислява сигнала  $NET$  от всеки неврон, използвайки стандартния израз:

$$NET_j = \sum_i x_i \cdot W_{ij} ;$$

3. Изчислява се значението на праговата функция на активация на сигнала  $NET$  от всеки неврон по следния начин:

$$OUT_j = \begin{cases} 1, \text{ ако } NET_j > \theta_j; \\ 0, \text{ в противен случай;} \end{cases}$$

като  $\theta_j$  представлява праг, съответстващ на неврона  $j$  (в простия случай всички неврони имат един и същ праг);

4. Изчислява се грешката за всеки неврон посредством прочитането на получения изход от искания изход:

$$error_j = target_j - OUT_j ;$$

5. Всяко тегло се модифицира по следния начин:

$$W_{ij}(t+1) = W_{ij}(t) + \alpha \cdot x_i \cdot error_j ;$$

6. Повтарят се стъпките от втората до петата дотогава, докато грешката не стане достатъчно малка.

#### 6. МЕТОД на ОБУЧЕНИЕТО на Уидроу – Хофф – по [11] и други.

Както видяхме, перцептрона се ограничава с бинарни изходи. Б. Уидроу заедно със студента М. Хофф разширяват алгоритъма на обучението на перцептрона за случая на непрекъснатите изходи, използвайки сигмоидна функция. Получава се впечатляващ резултат – разработка на математическо доказателство, че мрежата при определени условия ще се сходя към всяка

функция, която тя може да представи. Техният първи модел, Адалин, има един изходен неврон, а по-късният модел, Мадалин, разширява мрежата при случая с много изходни неврони [11].

Изразите, описващи процеса на обучението на Адалина, много приличат на перцептронните изрази. Съществена разлика има в четвъртата стъпка, където се използват непрекъснати сигнали *NET* вместо бинарните *OUT*. Модифицираната стъпка 4 (от алгоритъма на обучението на перцептрона) в този случай се реализира по следния начин [11]:

4. Изчислява се грешката за всеки неврон посредством прочитането на получения изход от исканите изходи:

$$error_j = t\ arg et_j - NET_j.$$

### 7. МЕТОД на СТАТИСТИЧЕСКОТО ОБУЧЕНИЕ – по [11] и други.

Еднослойните мрежи са ограничени от гледна точка за задачите, които могат да решават. Обаче, в течение на много години отсъстваха методи за обучението на многослойните мрежи. Статистическото обучение се явява такъв метод и осигурява решение на този проблем [11].

По аналогия, обучението на мрежата чрез статистически способ е подобно на процеса на отгряването (оттопяването) на метала. В процеса на отгряването температурата на метала в началото се повишава, докато атомите не започнат да се преместват почти свободно. След това температурата постепенно намалява и атомите непрекъснато се стремят към минимална енергетическа конфигурация. При някаква ниска температура атомите преминават на ниско енергетическо ниво [11].

В изкуствените невронни мрежи пълната величина на енергията на мрежата се определя като функция от определено множество от мрежови променливи. Изкуствената променлива температура се инициира в голяма величина и позволява мрежовите променливи да претърпят големи случайни изменения. Измененията, довеждащи към намалянето на пълната енергия на мрежата се съхраняват. Измененията, довеждащи към увеличението на енергията, се съхраняват в съответствие с вероятностна функция. Изкуствената температура постепенно намалява с течение на времето, и мрежата конвертира в състояние на минимума на пълната енергия [11].

Съществуват много вариации на темата на статистическото обучение. Например, глобалната енергия може да бъде определена като средна квадратична грешка между получения и желанния изходен вектор от обучаемото множество, а променливите могат да бъдат теглата на мрежата. В този случай мрежата може да бъде обучена, започвайки с висока изкуствена температура, по пътя на изпълнението на следните стъпки [11]:

1. Подаване на обучаващия вектор на входа на мрежата и изчисляване на изхода съгласно съответните мрежови правила;
2. Изчисляване на значението на средната квадратична грешка между желанния и получения изходен вектор;
3. Изменяне на мрежовите тегла по случаен начин и след това изчисляване на новия изход и резултатната грешка. Ако грешката се е намалила, оставяме измененото тегло. Ако грешката се е увеличила, оставяме



измененото тегло с вероятност, определена от разпределението на Болцман. Ако изменението на теглото не стане, то връщаме теглото в предишното значение;

4. Повтаряме стъпките от 1 до 3 и постепенно намаляваме изкуствената температура.

Ако величината на случайното изменение на теглата се определя в съответствие с разпределението на Болцман, сходимостта към глобалния минимум ще се осъществи само в този случай, когато температурата се изменя обратно пропорционално на логаритъма на миналото време на обучението. Това може да доведе към невероятна продължителност на процеса на обучението, заради което голямо внимание се отделя на търсенето на по-бързи методи. Изборът на размера на стъпката в съответствие с разпределението на Коши може да доведе до намаление на температурата, обратно пропорционално на обучаващото време, което съществено намалява времето, необходимо за сходимостта [11].

Ще отбележим, че съществува клас статистически методи за невронни мрежи, в които променливите в мрежата се явяват изходите на невроните, а теглата [11].

#### 8. САМООРГАНИЗАЦИЯ – по [11] и други.

Самоорганизиращите се структури класифицират образите, представени с векторни величини, в които всяка компонента от вектора съответства на елемент от образа. Алгоритмите на Т. Кохонен се основават на техниката на обучение без учител. След обучението подаването на входен вектор от даден клас ще доведе до създаването на възбуждащо ниво във всеки изходен неврон. Невронът с максимално възбуждане представлява класификацията. Тъй като обучението става без указание на целевия вектор, то няма възможност да се определи предварително, кой неврон ще съответства на дадения клас на входните вектори. Но това планиране лесно става по пътя на тестването на мрежата след обучението [11].

Алгоритъмът трактува набора от  $n$  входни тегла на неврона като вектор в  $n$ -мерното пространство. Преди обучението всеки компонент на този вектор на теглата се инициира в случайна величина. След това всеки вектор се нормализира във вектор с единична дължина в пространството на теглата – за това се изпълнява деление на всяко случайно тегло на квадратния корен от сумата на квадратите на компонентите на този тегловектор [11]:

1. Векторът  $X$  се появява на входа на мрежата;
2. Определя се разстоянието  $D_j$  ( в  $n$ -мерното пространство) между  $X$  и тегловите вектори  $W_j$  на всеки неврон. В евклидовото пространство това разстояние се изчислява по следната формула:

$$D_j = \sqrt{\sum_i (x_i - W_{ij})^2}$$

Където:  $x_i$  е компонента  $i$  на входния вектор  $X$ , а  $W_{ij}$  е теглото на входа  $i$  на неврона  $j$ ;

3. Невронът, който има тегловен вектор, най-близък до  $X$ , се обявява за победител. Този вектор, наричан  $W_c$ , става основен в групата от тегловни вектори, които лежат в пределите на разстоянието  $D$  от  $W_c$ ;
4. Групата тегловни вектори се настройва в съответствие със следния израз:  

$$W_j(t+1) = W_j(t) + \alpha[X - W_j(t)],$$
за всички тегловни вектори в пределите на разстоянието  $D$  от  $W_c$ ;
5. Повтарят се стъпките от 1 до 4 за всеки входен вектор.

В процеса на обучението на невронната мрежа значенията на  $D$  и  $\alpha$  постепенно намаляват. Препоръчва се, коефициента  $\alpha$  в началото на обучението да се установи приблизително равен на единица и да намалява в процеса на обучението до нула, а  $D$  може в началото на обучението да е равен на максималното разстояние между тегловните вектори, а в края на обучението става толкова малко, че да се обучава само един неврон [11].

В съответствие със съществуващата гледна точка, точността на класификацията ще се подобрява при допълнително обучение. Съгласно препоръките на Т. Кохонен, за получаването на добра статистическа точност количеството на обучаващите цикли трябва да бъде 500 пъти по-голямо от количеството на изходните неврони [11].

Обучаващият алгоритъм настройва тегловните вектори в околността на възбудения неврон по такъв начин, че те да приличат повече на входния вектор. Тъй като всички вектори се нормализират във вектори с единична дължина, те могат да се разглеждат като точки на повърхността на единична хиперсфера. В процеса на обучението групата съседни тегловни точки се преместват по-близо към точката на входния вектор. Предполага се, че входните вектори фактически се групират в класове в съответствие с тяхното положение във векторното пространство. Определен клас ще се асоциира с определен неврон, преместващ неговия тегловен вектор в направление към центъра на класа и способстващ за неговото възбуждане при появата на входа на всеки вектор от дадения клас [11].

След обучението класификацията се изпълнява с две стъпки: подаване на входа на мрежата на изпитвания вектор и изчисление на възбуждането за всеки неврон следващ избор на неврона с най-висока възбуденост, като индикатор за правилната класификация [11].

### 9. ЗАКЛЮЧЕНИЕ – по [1-11] и допълнителна литература.

С така изложеното съдържание (на настоящата работа) се цели осигуряването на достатъчна конкретна информация, без задълбочаването в сложни математически описания, за да може читателят сам да разбере основните идеи и възможностите на методите за обучение на невронните мрежи [11].

Освен това, буквалното използване на информацията от [11] ще попълни изгражданата „Банка със Знания”, чиито идеи и конкретни знания ще се използват при оптималното построяване на Памет-Невро- Компютрите (ПаНеКо проект на Симеон Йорданов Мръчев от 9 май 1990 година, апробиран вербално с

8 международни публикации през 1992-1993 години) в специални и универсални версии (виж и допълнителната литература).

#### Литература:

3. Аверкин А.Н., Нечеткие множества в моделях управления и искусственного интеллекта; Под. Ред. Д.А.Поспелова; Москва; Наука; 1986
4. Батыршин И.З. Основные операции нечеткой логики и их обобщения, Казань, Отечество, 2001
5. Головкин В.А., Нейронные сети: обучение, организация и применение, Москва, Изд.ИПРЖР, 2002
6. Заенцев, Ц.В. Нейронные сети: Основные модели, Воронеж, 1999
7. Заде Л., Понятие лингвистической переменной и его применение к принятию приближенных решений, Москва, Мир, 1976
8. Кофман А., Введение в теорию нечетких множеств, Москва, Радио и связь, 1982
9. Круглов В.В., В.В.Борисов, Искусственные нейронные сети (Теория и практика), Москва, Горячая линия – Телеком, 2001
10. Круглов В.В., М.И.Дли, Р.Ю.Голунов, Нечеткая логика и искусственные нейронные сети, Москва, ФИЗМАТЛИТ, 2001
11. Осовский С., Нейронные сети для обработки информации, Москва, Финансы и статистика, 2002
12. Радченко А.Н., Ассоциативная память, Нейронные сети, Оптимизация нейропроцессов, Москва, Наука, 1998
13. Яхьяева Г.Э., Нечеткие множества и нейронные сети, Москва, Интернет-Университет, 2006

#### Допълнителна литература

1. Мръчев, С.Й., Г.Хр.Акабадиев, Мнемология, Бионика и Искусствен интелект: Образователна Програма и Оптимизация (4 части), Юбилейна научна конференция, 6-7 април 1995, Русенски университет и Педагогически институт – Ямбол, Ямбол, 1995, с.113-152
2. Мръчев, С.Й., Невронни мрежи и моделиране на човешката памет, Научна сесия на 21 декември 2001 г., Технически колеж – Ямбол, 2002, с.21-25
3. Мръчев С.Й., Г.Хр.Акабадиев, В.С.Чернишов, Въведение за обучението: невронна пластичности оптимизация (2 части), Научно-риложна конференция с международно участие, 3-4 октомври 2003, Технически колеж – Ямбол, 2003, том 1, с.203-216
4. Мръчев С.Й., В.Недева, Д.Гинчев, Г.Хр.Акабадиев, Въведение за неврона и невронния ансамбъл, Като елементи на Неврокомпютрите, сб.Моделиране на човешката памет, Технически колеж – Ямбол, 2004, с. 75-190
5. Мръчев С.Й., В.Недева, Т.Георгиев, Д.Гинчев, Генетични алгоритми на интерактивни обучаващи системи, Международна научна конференция «Образователните политики на Европейския съюз», 18 май 2006 г.,

Технически колеж – Ямбол и Технически колеж – Одрин, 2006, с.103-109

6. Петров Н.И., С.Й.Мръчев, Д.Гинчев, Т.Георгиев, Многослойни невронни мрежи и алгоритми за тяхното обучение, Международна научна конференция, 1-2- юни 2006 г., Стара Загора, 2006, том 3, с 242-252
7. Горбань А.Н., Обучение нейронных сетей, Москва, Сп.»Параграф», Изд.СССР-САШ, 1990
8. Amari Shun-ichi, Mathematical Theory of Neural Learning, New Generation Computing, OHMSHA Ltd. and Springer Verlag, 1991, № 8, pp 281-294
9. Martinez J.L., R.P. Kesner, Neurology of Learning and Memory, London, Academic Press, 1998
10. Ретковская Д. и др., Нейронные сети, генетические алгоритмы и нечеткие системы, Москва, Горячая линия-Телеком, 2004
11. Grossberg S., R, The Adaptive Brain: Vol.Cognition, Learning, Reinforcement and Rhithm, Amsterdam, Elsevier, 1987
12. Kohonen T., Self-organization and Associative Memory, Berlin, Heidelberg, Germany, Springer-Verlag, 1989
13. Kohonen T., The Self-organization Map, Proceedings of the IEEE, Vol.78, №9, September 1990, pp.1464-1480
14. Kohonen T.and other, Artificial Neural Networks, North-Holland, 1991

**За контакти:**

**Симеон Й.Мръчев\***

*6003 гр.Ст.Загора, бул. "Цар Симеон Велики" № 45, ап.28, тел.042/630451*

**Веселина И.Недева – доцент, доктор**

*Тракийски университет – Стара Загора, Технически колеж – Ямбол, 8600 Ямбол, ул. "Граф Игнатиев" №38, [ynedeva@yahoo.com](mailto:ynedeva@yahoo.com)*

**Ташо Б.Георгиев, Димитър Г.Гинчев**