

МЕТОДЕ ОДЛУЧИВАЊА

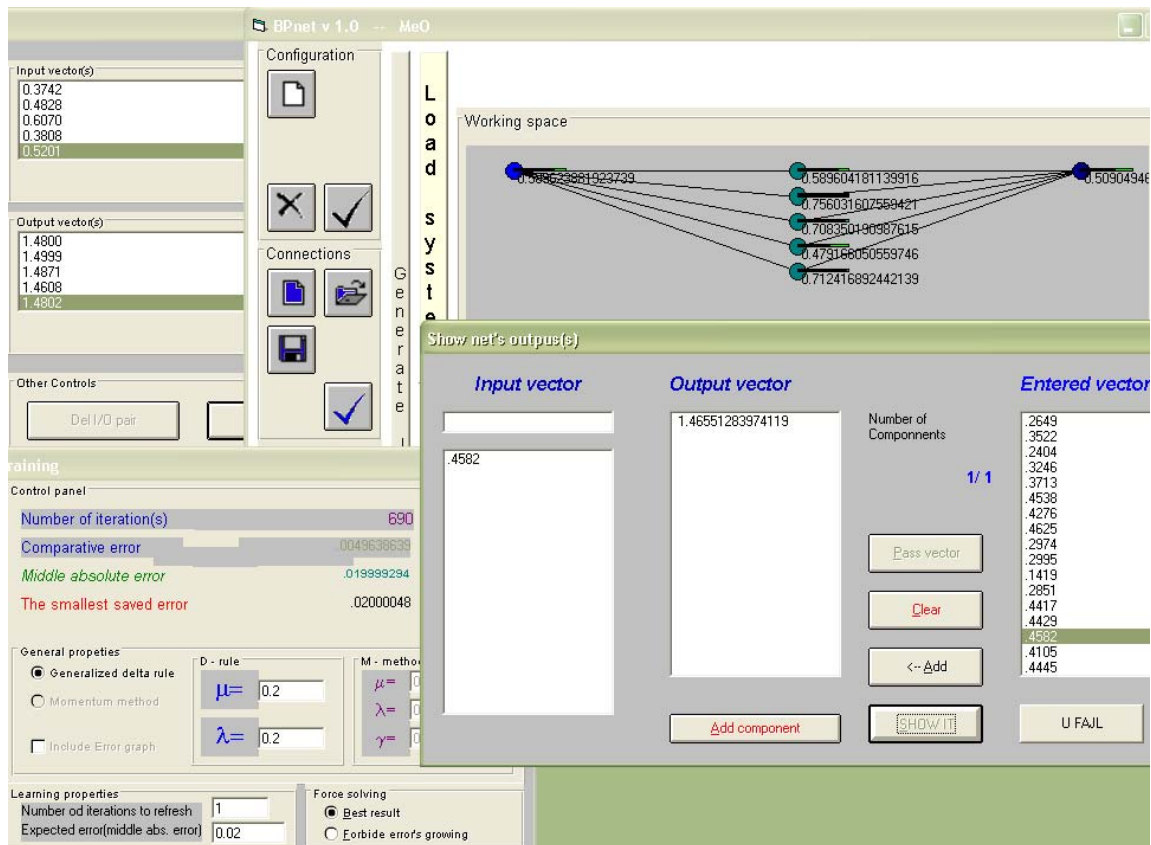
ПЛ-3 ПРИМЕРИ ПРИМЕНЕ НЕУРОНСКИХ МРЕЖА У МЕТОДАМА ОДЛУЧИВАЊА

Примена VPnet-а у одлучивању

Користи се VPnet за мапирање 4 улазних вредности (параметара храпавости) на 1 излаз (фрактална димензија) за 30 експерименталних мерења.

Поступак коришћења VPnet-а:

- ❑ Дефинисање броја слојева у мрежи.
 - ❑ Конфигурација мреже одабиром бројева неурона у слојевима. Конкретно за дат пример одабрати са четири неурона у улазном, произвољам број у скривеном или скривеним и један неурон у излазном слоју.
 - ❑ Дефинисање тежинских коефицијената.
 - ❑ Снимање вредности тежинских коефицијената.
 - ❑ Дефинисање обучавајућих вектора, тј. унос података из табеле 1.
 - ❑ Снимање обучавајућег скупа
 - ❑ Обучавање мреже
 - ❑ Задавање вредности параметара генерализаног делта правила μ и λ , који утичу на процес обучавања, као и величине грешке која је услов за заустављање итеративног процеса обучавања.
 - ❑ Преглед обучености мреже.
 - ❑ Одабрати графички приказ побуђености неурона по слојевима мреже.
 - ❑ Донети одлуку о најбољој површини на основу процењених вредности изл.вектора
- На слици 1 је дат приказ прозора софтвера VPnet.



Слика 1. Приказ прозора софтвера VPnet

Примена nftool


Користи се BPN за мапирање улаза (Ra или Rq или Sratio) у излаз (Ds), који чине 32 пара експерименталних података.

Поступак коришћења nftool-а у Matlab-у:

- Унос улазног и излазног вектора као матрице 1×30 према подацима датим у табели 1 или 2
- Одабир из листе **toolbox**-ова управо **nftool**
- Под **Select data** одабир имена ул.вектора као **Input**, односно изл.вектора као **Target**
- Одабир под **Validation and Test data** 70% ул.података за обучавање и по 15% за валидацију и тестирање. Конкретно 20 се користи за обучавање, 5 за валидацију и 5 за тестирање.
- Одабир под **Network size** број неурона у скривеном слоју


BPN у овом случају има један скривен слој неурона, чији број задајемо и један изл.слој. Алгоритам учења је задат као Levenberg-Marquart-ов који је варијанта Widrow-Hoff-овог алгоритма. Задате су и функције преноса, и то за скривени слој сигмоидна, а за излазни линеарна.

На основу података из табеле 2 обучавана је мрежа са једним скривеним слојем од 80 неурона, као пример. Излази су дијаграмски приказани на сликама. На слици 2 је дат приказ фитовања као график функције, која пролази кроз задате парове тачака.



Слика 2. Фитовање кроз парове тачака који представљају експерименталне податке

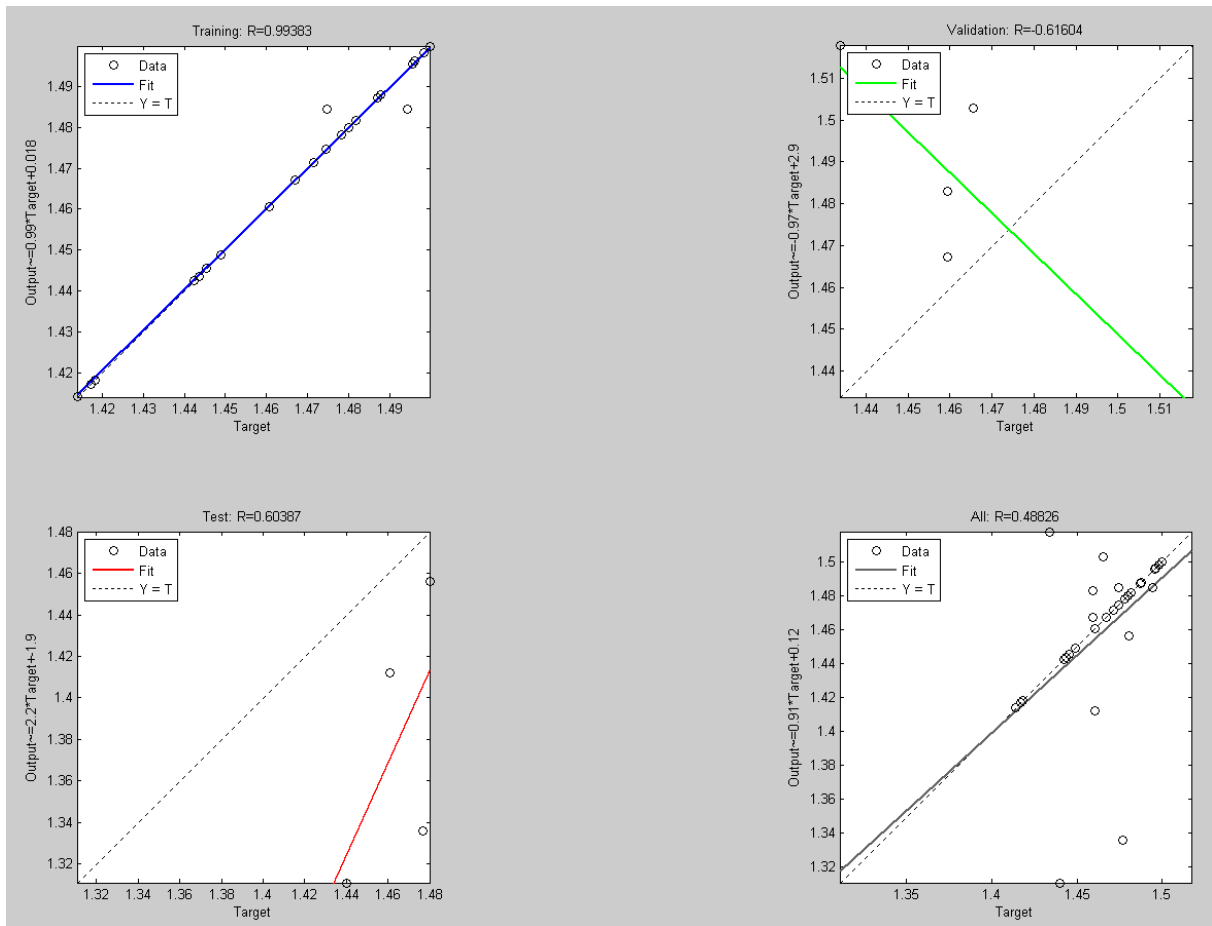
Након 6 итерација грешка се усталила и тиме је заустављено обучавање мреже, што се на слици 3 и види.




Слика 3. Приказ промене грешке

Ваљаност мреже се проверава преко два параметра. Грешка у ознаци MSE, која чини средње квадратно одступање, је дата нумерички и потребно је да буде што мања. Коефицијент регресионе анализе показује валидност фитовања и потребно је да буде што ближи јединици. На слици 4 је приказана регресиона анализа за конкретан случај.

Обучавање иде у правцу негативног градијента и његова вредност је показана на слици 5 на првом дијаграму. Када достигне задату вредност обучавање се зауставља. Други дијаграм на слици 5 је везан за μ . То је μ , тј. позитивна константа у Widrow-Hoff-овом правилу за алгоритам који је примењен у BPN. Када μ достигне задату вредност обучавање се зауставља. На трећем дијаграму на слици 5 је показана вредност Val fail. То је број лоших валидација, којих је дозвољено само 5. Када пређе задату вредност обучавање се зауставља. Један од три параметра мреже први достигне задату вредност и изазове прекид обучавања.



Слика 4. Регресиона анализа фитовања



Слика 5. Перформансе мреже