



μ

μ

μ

μμ

.

:

.....

.....





μ μ μ μ μ μ μ μ

·  
:  
· · ·

μ .....  
.....  
.....

, 2009



.....

μ

. . . .

Copyright © . , 2009

μ . All rights reserved.

μ μ , μ , μ  
 μ μ , μ μ .  
 μ .  
 μ μ μ μ  
 μ .













## ABSTRACT

---

The main object of this thesis is referred to the optimal power flow and more concretely to the problem of minimisation of transport losses in the lines of System of Electric Energy. Then we refer to the distribution of these losses in the buses of a network S.E.E. The structure of this work is organised in six chapters:

In the first chapter we have a theoretical report in the systems of electric energy. The parts of production, of transport and distribution of energy that compose a S.E.E are described. Simultaneously is studied the process of analysis of load flow. We describe the most basic method of bibliography, Newton-Raphson, and all the elements that enter into these equations, that is to say the metres and the phases of Volts, the active and reactive power force etc.

In the second chapter is presented the problem of optimal power flow. The general problem is posed as finding an optimal solution that minimises the general objective function of the problem, while satisfying some equality and inequality constrains, in order to stay secure the sure system. After the general description of the problem, we have a presentation of the particular problem of minimisation of losses with all parameters. Then is presented the solution of the problem with various constrains. Initially with a deterministic method of internal point and then applying an algorithm of artificial intelligence, a differential evolutionary algorithm. We also take a theoretical explanation of these two methods.

In the third chapter takes place an economic application of loss minimisation problem. The presence of capacitors has a huge role in the minimisation of losses in a network S.E.E. We have to select the place and the type of capacitor in each bus. For the best selected bus is used initially a matrix technique and then we import the very recent study of fuzzy logic which provides an exceptionally simple way of choice of bus place. Then the problem of size of capacitors is solved by two algorithms of artificial intelligence, genetic algorithms and particle swarm optimization. The all study becomes in economic terms.

In the fourth chapter we have a reference in the theory of neural networks. It is a methodology that helps us in the case of process where the data of entry are altered continuously. Their use particularly in the sector of energy is very widespread. After the theoretical presentation that includes all the steps: import of data, choice of parameters, learning, evaluation etc. we execute an application of capacitor placement in a network S.E.E. We change the power data quantities in the network.

In the fifth chapter and after the study of loss minimisation problem we discuss the problem of distribution of power losses in the network. Initially we have a description of distributed networks which will be the base of networks after the new laws about energy and then it takes part a theoretical approach of deterministic methods of losses distribution in a network buses. It follows a practical application of finding the loss distribution with the most essential of these described methods.

In the sixth chapter we have the distribution of losses in a network with the presence of a neural network. The input data of power change continuously and we

must know every time the distribution of losses for the best available estimate of cost in each bus. Simultaneously is developed the theory of neural-fuzzy (ANFIS) which is an extension of neural networks and also solves the distribution losses problem .

Finally in the seventh chapter we have a conclusive report of total work while in the annex is developed an equally important problem of S.E.E.,that of stochastic load flow. We solve this problem with the help of neural networks and we show the widespread usage of artificial intelligence in energy based problems.

#### KEY WORDS:

Load flow, optimal load flow, loss minimization, interior point, differential evolutionary algorithm, capacitors placement, genetic algorithms, particle swarm algorithm, neural networks, loss distribution, neural-fuzzy networks.

|                |                             |      |
|----------------|-----------------------------|------|
| 1.             | .....                       | -1-  |
| 1.1            | .....                       | -1-  |
| 1.2            | .....                       | -1-  |
| 1.3            | .....                       | -2-  |
| 1.4            | .....                       | -3-  |
| 1.5            | .....                       | -4-  |
| 1.6            | .....                       | -5-  |
| 1.7            | .....                       | -6-  |
| 1.7.1          | $\mu\mu$ .....              | -6-  |
| 1.7.2          | .....                       | -7-  |
| 1.7.3          | $\mu$ .....                 | -7-  |
| 1.7.4          | .....                       | -8-  |
| 1.7.5          | .....                       | -8-  |
| 1.8            | .....                       | -9-  |
| 1.8.1          | .....                       | -9-  |
| 1.8.2          | .....                       | -9-  |
| 1.8.3          | <b>Newton-Raphson</b> ..... | -12- |
| 2.             | .....                       | -15- |
| 2.1            | .....                       | -15- |
| 2.2            | .....                       | -16- |
| 2.2.1          | $\mu$ .....                 | -16- |
| <u>2.2.1.</u>  | $\mu$ .....                 | -17- |
| <u>2.2.1.</u>  | $\mu$ .....                 | -18- |
| <u>2.2.1.</u>  | $\mu$ .....                 | -19- |
| 2.3            | .....                       | -21- |
| 2.3.1          | .....                       | -21- |
| 2.3.2          | - .....                     | -24- |
| <u>2.3.2.A</u> | $\mu$ .....                 | -26- |
| <u>2.3.2.</u>  | $\mu$ .....                 | -27- |

|         |  |      |
|---------|--|------|
| 2.4     | .....                                    | -29- |
| 2.5     | ( INTERIOR POINT) .....                  | -30- |
| 2.5.1   | $\mu$ $\mu$ $\mu$ $\mu$ ....             | -32- |
| 2.5.2   | $\mu$ 1.....                             | -33- |
| 2.5.3   | $\mu$ 2.....                             | -36- |
| 2.5.4   | $\mu$ 2- .....                           | -40- |
| 2.6     | ..                                       | -42- |
| 2.6.1   | .....                                    | -42- |
| 2.6.2   | Differential evolutionary algorithm..... | -42- |
| 2.6.3   | $\mu$ $\mu$ .....                        | -43- |
| 2.6.3.  | $\mu$ .....                              | -45- |
| 2.6.3.  | $\mu$ $\mu$ .....                        | -47- |
| 2.6.4   | $\mu$ $\mu$ .....                        | -49- |
| 2.6.4.  | .....                                    | -49- |
| 2.6.4.  | 1.....                                   | -50- |
| 2.6.4.  | 2.....                                   | -55- |
| 3.      | .....                                    | -57- |
| 3.1     | .....                                    | -57- |
| 3.2     | .....                                    | -58- |
| 3.2.1   | .....                                    | -58- |
| 3.2.2   | $\mu\mu$ .....                           | -59- |
| 3.2.3   | .....                                    | -62- |
| 3.2.4   | .....                                    | -64- |
| 3.2.4.  | .....                                    | -64- |
| 3.2.4.  | .....                                    | -64- |
| 3.2.4.  | .....                                    | -64- |
| 3.2.4.  | .....                                    | -66- |
| 3.2.5   | ( fuzzy relations ).....                 | -67- |
| 3.2.6   | $\mu$ (FIS).....                         | -69- |
| 3.2.6.A | .....                                    | -69- |
| 3.2.6.  | IF-THEN .....                            | -69- |
| 3.2.7   | $\mu$ (fuzzy inference systems).....     | -72- |
| 3.2.7.  | $\mu$ Mamdani.....                       | -72- |
| 3.2.7.  | $\mu$ Sugeno.....                        | -78- |
| 3.3     | .....                                    | -79- |
| 3.4     | .....                                    | -83- |
| 3.4.1   | Case study.....                          | -85- |

|                                 |                                      |       |
|---------------------------------|--------------------------------------|-------|
| 3.5 FUZZY                       | .....                                | -86-  |
| 3.5.1                           | .....                                | -86-  |
| 3.5.2                           | Fuzzy $\mu$ .....                    | -87-  |
| 3.5.3 Case Study                | .....                                | -89-  |
| 3.6                             | .....                                | -91-  |
| 3.6.1                           | .....                                | -91-  |
| 3.6.2                           | $\mu$ .....                          | -92-  |
| 3.6.3                           | $\mu$ $\mu$ GA $\mu$ .....           | -93-  |
| 3.6.4                           | $\mu$ GA CPP $\mu$ $\mu$ $\mu$ ..... | -95-  |
| 3.7                             | .....                                | -99-  |
| 3.7.1                           | .....                                | -99-  |
| 3.7.2                           | $\mu$ $\mu$ $\mu$ .....              | -100- |
| 3.7.2.A                         | $\mu$ <i>switched</i> .....          | -100- |
| 3.7.2.B                         | $\mu$ <i>fixed</i> .....             | -105- |
| 3.8 PARTICLE SWARM OPTIMIZATION | .....                                | -109- |
| 3.8.1                           | .....                                | -109- |
| 3.8.2                           | PSO $\mu$ .....                      | -110- |
| 3.8.3                           | $\mu$ PSO $\mu$ CPP.....             | -111- |
| 3.9                             | PSO .....                            | -116- |
| 3.9.1                           | .....                                | -116- |
| 3.9.2                           | $\mu$ $\mu$ .....                    | -117- |
| 3.9.2.A                         | $\mu$ <i>switched</i> .....          | -117- |
| 3.9.2.B                         | $\mu$ <i>fixed capacitors</i> .....  | -121- |
| 4.                              | .....                                | -125- |
| 4.1                             | .....                                | -125- |
| 4.2                             | .....                                | -125- |
| 4.2.1                           | .....                                | -125- |
| 4.2.2                           | .....                                | -126- |
| 4.2.3                           | $\mu$ $\mu$ .....                    | -127- |
| 4.2.4                           | .....                                | -128- |
| 4.2.5                           | .....                                | -130- |
| 4.2.6                           | .....                                | -132- |

|         |                                     |       |
|---------|-------------------------------------|-------|
| 4.2.7   | .....                               | -133- |
| 4.2.7.1 | STEEPEST DECENT TRAINING.....       | -136- |
| 4.2.7.2 | $\mu$ $\mu$ .....                   | -137- |
| 4.2.7.3 | Resilient Backpropagation.....      | -137- |
| 4.2.7.4 | Conjugate Gradient Algorithmes..... | -138- |
| 4.2.7.5 | Quasi-Newton Algorithmes.....       | -138- |
| 4.2.7.6 | Levenberg-Marquardt $\mu$ .....     | -139- |
| 4.2.8   | .....                               | -140- |
| 4.2.9   | $\mu$ - $\mu$ - .....               | -143- |
| 4.2.10  | $\mu$ .....                         | -144- |
| 4.3     | CPP.....                            | -145- |
| 4.3.1   | $\mu$ .....                         | -145- |
| 4.3.2   | - $\mu$ - .....                     | -145- |
| 4.3.3   | .....                               | -146- |
| 4.3.4   | .....                               | -147- |
| 4.3.5   | $\mu$ .....                         | -149- |
| 5.      | .....                               | -152- |
| 5.1     | .....                               | -152- |
| 5.2     | .....                               | -153- |
| 5.2.1   | $\mu$ $\mu$ $\mu$ $\mu$ .....       | -153- |
| 5.3     | .....                               | -156- |
| 5.3.1   | $\mu$ $\mu$ .....                   | -156- |
| 5.3.2   | $\mu$ .....                         | -156- |
| 5.4     | .....                               | -159- |
| 5.4.1   | Pro rata technique.....             | -159- |
| 5.4.2   | Proportional sharing.....           | -160- |
| 5.4.2.1 | Downstream looking algorithm.....   | -160- |
| 5.4.2.2 | Upstream looking algorithm.....     | -160- |
| 5.4.3   | Marginal allocation.....            | -161- |
| 5.4.4   | Z-bus loss allocation.....          | -165- |
| 5.5     | .....                               | -168- |
| 5.5.1   | Pro rata.....                       | -169- |
| 5.5.2   | Proportional sharing.....           | -170- |



|        |  |       |
|--------|--|-------|
| 5.5.3. | -Bus allocation.....                               | -171- |
| 5.5.4. | Marginal loss allocation.....                      | -172- |
| 6.     | .....  | -175- |
| 6.1    | .....  | -175- |
| 6.2    | .....  | -175- |
| 6.2.1  | .....  | -175- |
| 6.2.2  | $\mu$ .....  | -176- |
| 6.2.3  | $\mu$ .....  | -176- |
| 6.2.4  | .....  | -179- |
| 6.2.5  | $\mu$ .....  | -181- |
| 6.2.6  | $\mu$ .....  | -182- |
| 6.2.7  | .....  | -183- |
| 6.2.8  | $\mu$ .....  | -186- |
| 6.3    | .....  | -191- |
| 6.3.1  | .....  | -191- |
| 6.3.2  | .....  | -192- |
| 6.3.3  | $\mu$ .....  | -193- |
| 6.4    | - .....  | -195- |
| 6.4.1  | .....  | -195- |
| 6.4.2  | .....  | -196- |
| 6.4.2. | $\mu\mu$ .....                                     | -196- |
| 6.4.2. | .....  | -197- |
| 6.4.2. | .....  | -197- |
| 6.4.3  | ANFIS (Adaptive Neuro-Fuzzy Inference System)..... | -198- |
| 6.5    | .....  | -201- |
| 6.5.1  | .....  | -201- |
| 6.5.2  | ANFIS.....   | -202- |
| 7.     | .....  | -207- |
| .      | .....  | -209- |
| .1     | .....  | -209- |
| .2     | .....  | -210- |

|                      |           |              |
|----------------------|-----------|--------------|
| <b>.3</b>            | .....     | <b>-211-</b> |
| <b>.4 CASE STUDY</b> | .....     | <b>-213-</b> |
| <b>.5</b>            | ANN ..... | <b>-217-</b> |
| <b>.6</b>            | .....     | <b>-219-</b> |
| <b>.7</b>            | .....     | <b>-220-</b> |

|             |          |              |  |          |  |       |           |
|-------------|----------|--------------|--|----------|--|-------|-----------|
| $\mu$ 1.1   | $\mu$    | $\mu$        | $\mu$                                      | $\mu\mu$ | $\mu$                                    | ..... | -6-       |
| $\mu$ 1.2   |          |              |  |          |  | ..... | -7-       |
| $\mu$ 1.3   |          | /            | $\mu$                                      | $\mu$    | $\mu$                                    | $\mu$ | ..... -7- |
| $\mu$ 1.4   |          |              |  |          |  | ..... | -8-       |
| $\mu$ 1.5   | $\mu$    |              | $\mu$                                      |          |  | ..... | -9-       |
| $\mu$ 2.1   |          |              |  |          |  | ..... | -25-      |
| $\mu$ 2.2   |          |              | $\mu$                                      | $\mu$    | Interior point –IEEE 14.....             |       | -39-      |
| $\mu$ 2.3   |          |              | $\mu$                                      | $\mu$    | Interior point –                         | ....  | -41-      |
| $\mu$ 2.4   | $\mu\mu$ |              |  |          | differential evolutionary algorithm..... |       | -48-      |
| $\mu$ 2.5   | $\mu$    |              |  | $\mu$    | DEA.....                                 |       | -51-      |
| $\mu$ 2.6.  | $\mu$    |              |  | $\mu$    |  | ..... | -52-      |
| $\mu$ 2.6.  | $\mu$    |              |  | $\mu$    |  | ..... | -52-      |
| $\mu$ 2.7   | $\mu$    |              |  |          | DEA-                                     | ..... | -54-      |
| $\mu$ 2.8.  | $\mu$    |              |  |          | DEA-                                     | ..... | -54-      |
| $\mu$ 2.8.  | $\mu$    |              |  |          | DEA-                                     | ..... | -55-      |
| $\mu$ 2.9   | $\mu$    | $\mu$        | $\mu$                                      |          | DEA -                                    | ..... | -55-      |
| $\mu$ 2.10  | $\mu$    |              |  |          | DEA-                                     | ..... | -56-      |
| $\mu$ 3.1   |          |              | –  | $\mu\mu$ |  | ..... | -60-      |
| $\mu$ 3.2   |          |              | –  | $\mu\mu$ |  | ..... | -60-      |
| $\mu$ 3.3.  |          |              |  | $\mu\mu$ |  | ..... | -61-      |
| $\mu$ 3.3.  |          |              |  | $\mu\mu$ |  | ..... | -61-      |
| $\mu$ 3.3.  |          |              |  | $\mu\mu$ |  | ..... | -62-      |
| $\mu$ 3.3.  |          |              |  | $\mu\mu$ |  | ..... | -62-      |
| $\mu$ 3.4   |          |              |  |          |  | ..... | -65-      |
| $\mu$ 3.5   |          |              |  |          |  | ..... | -65-      |
| $\mu$ 3.6   | $\mu$    |              |  |          |  | ..... | -71-      |
| $\mu$ 3.7   |          |              | $\mu$                                      |          |  | ..... | -72-      |
| $\mu$ 3.8   |          |              |  |          |  | ..... | -73-      |
| $\mu$ 3.9   | $\mu$    |              |  |          |  | ..... | -74-      |
| $\mu$ 3.10  | $\mu$    | $\mu$        |  |          | implication.....                         |       | -75-      |
| $\mu$ 3.11  |          |              |  | $\mu$    |  | ..... | -76-      |
| $\mu$ 3.12  |          |              |  |          |  | ..... | -77-      |
| $\mu$ 3.13  | $\mu$    | Sugeno.....  |  |          |  |       | -78-      |
| $\mu$ 3.14  |          | 15           |  |          |  | ..... | -79-      |
| $\mu$ 3.15  | $\mu$    |              |  |          |  | ..... | -81-      |
| $\mu$ 3.16  |          | PLI.....     |  |          |  |       | -87-      |
| $\mu$ 3.17  |          | VOLTAGE..... |  |          |  |       | -88-      |
| $\mu$ 3.18  |          | CSI.....     |  |          |  |       | -88-      |
| $\mu$ 3.19  | $\mu\mu$ |              | $\mu$                                      |          | CPP.....                                 |       | -98-      |
| $\mu$ 3.20. | $\mu\mu$ |              | (x 10 <sup>4</sup> \$)-ML-GA-switched..... |          |  |       | -102-     |
| $\mu$ 3.20. | $\mu\mu$ |              | (KW)-ML.....                               |          |  |       | -102-     |
| $\mu$ 3.21. | $\mu\mu$ |              | ( \$ )-LL.....                             |          |  |       | -103-     |
| $\mu$ 3.21. | $\mu\mu$ |              | (KW)-LL.....                               |          |  |       | -103-     |
| $\mu$ 3.22. | $\mu\mu$ |              | ( \$ )-HL.....                             |          |  |       | -104-     |
| $\mu$ 3.22. | $\mu\mu$ |              | (KW)-HL.....                               |          |  |       | -104-     |
| $\mu$ 3.23. | $\mu\mu$ |              | (x 10 <sup>4</sup> \$)-ML-GA-fixed.....    |          |  |       | -107-     |

|         |                          |   |             |       |       |
|---------|--------------------------|---|-------------|-------|-------|
| μ 3.23. | μμ                       | medium                                  | ( KW )      | ..... | -107- |
| μ 3.23. | μμ                       | low                                     | ( KW )      | ..... | -108- |
| μ 3.23. | μμ                       | peak                                    | ( KW )      | ..... | -108- |
| μ 3.24  | μμ PSO                   | μ                                       | CPP         | ..... | -115- |
| μ 3.25. |                          | ( x10 <sup>4</sup> \$ )-ML-PSO-switched |             | ..... | -118- |
| μ 3.25. | μμ                       | ( W )-ML                                |             | ..... | -119- |
| μ 3.26. |                          | ( \$ )-LL                               |             | ..... | -119- |
| μ 3.26. | μμ                       | ( W )-LL                                |             | ..... | -120- |
| μ 3.27. |                          | ( \$ )-HL                               |             | ..... | -120- |
| μ 3.27. | μμ                       | ( W )-HL                                |             | ..... | -121- |
| μ 3.28. |                          | ( x10 <sup>4</sup> \$ )-PSO-fixed       |             | ..... | -123- |
| μ 3.28. | μ                        | ( W )                                   |             | ..... | -123- |
| μ 3.28. | low                      | (KW)                                    |             | ..... | -124- |
| μ 3.28. | peak                     | (KW)                                    |             | ..... | -124- |
| μ 4.1   |                          |   |             | ..... | -127- |
| μ 4.2   | μ                        |   |             | ..... | -128- |
| μ 4.3   | Single-Layer Feedforward |   |             | ..... | -130- |
| μ 4.4.  | μ                        | μ                                       | feedforward | ..... | -131- |
| μ 4.4.  | μ                        | μ                                       | feedforward | ..... | -131- |
| μ 4.5   | μ                        | μ                                       |             | ..... | -132- |
| μ 4.6   |                          |   |             | ..... | -132- |
| μ 4.7   |                          |   | μ           | ..... | -133- |
| μ 4.8   | μ                        |   |             | ..... | -134- |
| μ 4.9   | μ                        |   |             | ..... | -134- |
| μ 4.10  | μμ                       |   |             | ..... | -134- |
| μ 4.11  |                          |   |             | ..... | -135- |
| μ 4.12  | μ                        | -                                       |             | ..... | -146- |
| μ 4.13  | μ                        | μ                                       | - μ         | ..... | -148- |
| μ 5.1   | μ                        | μ                                       |             | ..... | -154- |
| μ 6.1   | -                        | μ                                       |             | ..... | -179- |
| μ 6.2   | -                        | μ                                       |             | ..... | -180- |
| μ 6.3   |                          |   |             | ..... | -181- |
| μ 6.4   | μ                        | μ                                       | 1           | ..... | -183- |
| μ 6.5   |                          |   | μ           | ..... | -185- |
| μ 6.6.  | μ                        | μ                                       | - μ         | ..... | -186- |
| μ 6.6.  | μ                        | μ                                       | - μ         | ..... | -187- |
| μ 6.7.  | -                        | μ                                       | 1-6         | ..... | -188- |
| μ 6.7.  | -                        | μ                                       | 7-12        | ..... | -188- |
| μ 6.7.  | -                        | μ                                       | 13-14       | ..... | -189- |
| μ 6.8.  | -                        | μ                                       | 1-6         | ..... | -189- |
| μ 6.8.  | -                        | μ                                       | 7-12        | ..... | -190- |
| μ 6.8.  | -                        | μ                                       | 13-14       | ..... | -190- |
| μ 6.9   |                          | -                                       |             | ..... | -192- |
| μ 6.10  | μ                        | -                                       | μ           | ..... | -193- |
| μ 6.11. | -                        | μ                                       |             | ..... | -194- |
| μ 6.11. | -                        | μ                                       |             | ..... | -194- |
| μ 6.12  |                          |   |             | ..... | -196- |
| μ 6.13  | ANFIS                    |   |             | ..... | -198- |
| μ 6.14  | μμ                       |   |             | ..... | -201- |
| μ 6.15  | ANFIS                    | μ                                       |             | ..... | -202- |

|             |                       |                               |       |
|-------------|-----------------------|-------------------------------|-------|
| $\mu$ 6.16. | $\mu$ $\mu$ -         | $\mu$ $\mu$ ANFIS.....        | -203- |
| $\mu$ 6.16. | $\mu$ $\mu$ -         | $\mu$ $\mu$ ANFIS-testdata .. | -203- |
| $\mu$ 6.17. | - $\mu$ 1-6           | ANFIS .....                   | -204- |
| $\mu$ 6.17. | - $\mu$ 6-14          | ANFIS.....                    | -204- |
| $\mu$ 6.18  | - $\mu$ 1-14          | ANFIS ,testdata .....         | -205- |
| $\mu$ .1    | 5 .....               |                               | -213- |
| $\mu$ .2    | 5 .....               |                               | -213- |
| $\mu$ .3    | $\mu\mu$ 5 .....      |                               | -214- |
| $\mu$ .4    | .....                 |                               | -217- |
| $\mu$ .5    | $\mu$ - $\mu$ .....   |                               | -218- |
| $\mu$ .6    | $\mu$ - $\mu$ - ..... |                               | -220- |

---

|      |          |       |  |       |
|------|----------|-------|--|-------|
| 2.1  |          | $\mu$ | .....  | -23-  |
| 2.2  | $\mu$    |       | $\mu$ .....  | -24-  |
| 2.3  |          | $\mu$ | 6 .....  | -33-  |
| 2.4  | $\mu\mu$ | $\mu$ | 6 .....  | -33-  |
| 2.5  | $\mu$    |       | $\mu$ 6 -IP.....                                       | -35-  |
| 2.6  | $\mu$    |       | $\mu$ 6 - N-R.....                                     | -35-  |
| 2.7  |          | $\mu$ | 14 .....   | -36-  |
| 2.8  | $\mu\mu$ | $\mu$ | 14 .....   | -37-  |
| 2.9  | $\mu$    |       | 14 -interior point.....                                | -38-  |
| 2.10 | $\mu$    |       | 14 -N-R.....   | -39-  |
| 2.11 | $\mu$    |       | 14 -IP Qsh.....  | -40-  |
| 2.12 | $\mu$    |       | 14 - -R.....   | -50-  |
| 2.13 | $\mu$    |       | 14 - DEA.....  | -51-  |
| 2.14 | $\mu$    |       | 14 -DEA Qsh..  | -53-  |
| 3.1  | $\mu\mu$ |       | -15.....   | -80-  |
| 3.2  |          |       | -15.....   | -80-  |
| 3.3  |          |       | .....  | -81-  |
| 3.4  | $\mu$    |       | .....  | -85-  |
| 3.5  |          | $\mu$ | .....  | -88-  |
| 3.6  |          | $\mu$ | .....  | -88-  |
| 3.7  |          | $\mu$ | .....  | -89-  |
| 3.8. |          | $\mu$ | $\mu$ .....  | -89-  |
| 3.8. |          | $\mu$ | $\mu$ .....  | -90-  |
| 3.9  |          | $\mu$ | $\mu$ .....  | -90-  |
| 3.10 | $\mu$    |       | 15 - -R.....   | -99-  |
| 3.11 | $\mu$    |       | GA -switched.....                                      | -100- |
| 3.12 |          |       | 15 -GA-switched .....                                  | -101- |
| 3.13 | $\mu$    |       | GA -fixed.....   | -105- |
| 3.14 |          |       | 15 GA -fixed.....                                      | -106- |
| 3.15 | $\mu$    |       | PSO -switched.....                                     | -117- |
| 3.16 |          |       | 15 PSO-switched.....                                   | -117- |
| 3.17 | $\mu$    |       | PSO -fixed.....  | -121- |
| 3.18 |          |       | 15 PSO -fixed.....                                     | -122- |
| 5.1  | $\mu$    |       | 14 .....   | -168- |
| 5.2  | $\mu$    | $\mu$ | pro rata.....  | -169- |
| 5.3  | $\mu$    |       | proportional sharing.....                              | -170- |
| 5.4  |          |       | Downstream looking algorithm proportional sharing..... | -170- |
| 5.5  |          |       | Upstream looking algorithm proportional sharing.....   | -171- |
| 5.6  |          |       | ITL.....   | -172- |
| 5.7  |          | $\mu$ | ITL.....   | -173- |
| 5.8  | $\mu$    | $\mu$ | $\mu$ .....  | -174- |
| 6.1  | $\mu$    |       | .....  | -178- |
| 6.2  |          | $\mu$ | .....  | -184- |
| 6.3  |          |       | .....  | -191- |
| 6.4  |          |       | ANFIS.....   | -206- |
| .1   |          |       | .....  | -214- |





















- (PQ),
- (PV),
- (slack bus),

$$S = S_G - S_D = (P_G - P_D) + j(Q_G - Q_D) = P + jQ \quad (1.2)$$

- PG
- QG
- PD
- QD
- V

$$S = S_G - S_D = (P_G - P_D) + j(Q_G - Q_D) = P + jQ \quad (1.2)$$

μ :

$$J = \frac{P - jQ}{V} \quad (1.3)$$




$$\mu : \quad N \quad 2N$$

$$P_i = V_i \sum_{j=1}^N V_j [g_{ij} \cos(d_j - d_i) - b_{ij} \sin(d_j - d_i)] \quad (1.4)$$

$$Q_i = -V_i \sum_{j=1}^N V_j [g_{ij} \sin(d_j - d_i) + b_{ij} \cos(d_j - d_i)] \quad (1.5)$$

$$y_{ii} = g_{ii} + jb_{ii}$$



- ,  $V_{i,\min} < V_i < V_{i,\max}$
  - $\mu$  ,  $|dj - di| < |dj - di|_{\max}$
  - ,  $P_{G_{\min}} < P_{Gi} < P_{G_{\max}}$
- $$Q_{G_{\min}} < Q_{Gi} < Q_{G_{\max}}$$

Newton-Raphson. Gauss-Seidel.

### 1.8.3 Newton-Raphson

Newton-Raphson (PQ). (PV).  $n-m-1$

$$\begin{bmatrix} \Delta P^{(n)} \\ \Delta Q^{(n)} \end{bmatrix} = - \begin{bmatrix} J1^{(n)} & J2^{(n)} \\ J3^{(n)} & J4^{(n)} \end{bmatrix} \begin{bmatrix} \Delta \delta^{(n)} \\ \Delta V^{(n)} \end{bmatrix} \quad (1.6)$$

- $[\Delta P^{(n)}] = [\Delta P_i^{(n)}], i \in \{\text{Ζυγοι PV και PQ}\} - \text{διαστασεις } (n-1) \times 1$
- $[\Delta Q^{(n)}] = [\Delta Q_i^{(n)}], i \in \{\text{Ζυγοι PQ}\} - \text{διαστασεις } m \times 1$
- $[\Delta d^{(n+1)}] = [d_i^{(n+1)} - d_i^{(n)}], i \in \{\text{Ζυγοι PV και PQ}\} - \text{διαστασεις } (n-1) \times 1$
- $[\Delta V^{(n+1)}] = [V_i^{(n+1)} - V_i^{(n)}], i \in \{\text{Ζυγοι PQ}\} - \text{διαστασεις } m \times 1$

J μ

μ μ :

1) μ μ μ PV PQ, μ μ PV PQ.

2) μ Q<sub>i</sub> P<sub>i</sub> PV PQ, μ PQ

3) , [ P ] [ Q ] :

$$[\Delta P_i^{(n)}] = P_i - V_i^{(n)} \sum_{j=1}^N V_j^{(n)} [g_{ij} \cos(d_j^{(n)} - d_i^{(n)}) - b_{ij} \sin(d_j^{(n)} - d_i^{(n)})]$$

$$[\Delta Q_i^{(n)}] = Q_i - V_i^{(n)} \sum_{j=1}^N V_j^{(n)} [g_{ij} \sin(d_i^{(n)} - d_j^{(n)}) - b_{ij} \cos(d_j^{(n)} - d_i^{(n)})]$$

4) μ

5) μ [ΔP<sub>i</sub><sup>(n)</sup>], [ΔQ<sub>i</sub><sup>(n)</sup>] μ

(n+1) μ μ μ μ :

$$\begin{bmatrix} \Delta \delta^{(n+1)} \\ \Delta V^{(n+1)} \end{bmatrix} = - \begin{bmatrix} J1^{(n)} & J2^{(n)} \\ J3^{(n)} & J4^{(n)} \end{bmatrix}^{-1} \cdot \begin{bmatrix} \Delta P^{(n)} \\ \Delta Q^{(n)} \end{bmatrix} \Rightarrow$$

$$\begin{bmatrix} \delta^{(n+1)} \\ V^{(n+1)} \end{bmatrix} = \begin{bmatrix} \delta^{(n)} \\ V^{(n)} \end{bmatrix} - \begin{bmatrix} J1^{(n)} & J2^{(n)} \\ J3^{(n)} & J4^{(n)} \end{bmatrix}^{-1} \cdot \begin{bmatrix} \Delta P^{(n)} \\ \Delta Q^{(n)} \end{bmatrix} \quad (1.7)$$

μ 2 μ μ μ

6)

$\mu$

$\mu$

$\mu\mu$

$P_i, Q_i$

.





μ μ μ μ μ μ

$$\begin{aligned}
 S_{ij} &= V_i Y_{ij}^* \\
 S_{ji} &= V_j Y_{ij}^* \\
 S_{L_{ij}} &= S_{ij} + S_{ji} \quad (2.2) \\
 P_{L_{ij}} &= \text{real}(S_{L_{ij}})
 \end{aligned}$$

Sij i μμ μ i j  
 Sji j μμ μ i j  
 SLij μμ μ i j  
 PLij μμ .

μ μ μμ μ .  
 μ μ μμ .

2.2.1. μ μ

μ μμ μ μ

μ μ :

$$S_{ij} = V_i I_{ij}^* = V_i^2 (Y_{ij} + Y_i)^* - V_i V_j Y_{ij}^* \quad (2.3)$$

$$S_{ji} = V_j I_{ji}^* = V_j^2 (Y_{ij} + Y_j)^* - V_i V_j Y_{ij}^*$$

μ μ μμ μ μ :

$$P_{L_{ij}} = \text{Real}\{S_{ij} + S_{ji}\} \quad (2.4)$$

μ μ S<sub>ij</sub>, S<sub>ji</sub> μ :

$$\text{Real}\{V_j^2 (Y_{ij} + Y_j)^* + V_i^2 (Y_{ij} + Y_i)^*\} = G_{ij} (V_i^2 + V_j^2)$$

$$\text{Real}\{V_i V_j Y_{ij}^* + V_i V_j Y_{ij}^*\} = \text{Real}\{2(V_i V_j \cos\theta_1 \cos\theta_2 - V_i V_j \sin\theta_1 \sin\theta_2) Y_{ij}^*\} =$$

$$2V_i V_j \cos(\theta_1 - \theta_2) G_{ij}$$

μ :

$$P_{L_{ij}} = G_{ij} \{ (V_i^2 + V_j^2) - 2V_i V_j \cos(\theta_1 - \theta_2) \} \quad (2.5)$$

μ μ μ :

$$P_L = \sum_{k=1}^N G_{ij} \{ (V_i^2 + V_j^2) - 2V_i V_j \cos(\theta_i - \theta_j) \} \quad (2.6)$$

k μμ .

:

$$P_L = \sum_{k=1}^N G_{ij}^* \{ (tV_i)^2 + V_j^2 - 2tV_i V_j \cos(\theta_i - \theta_j) \} \quad (2.7)$$

μ t μ μ .

2.2.1. μ μ

μ μ μ μ μ μ μ μ  
μ .

$$V_i = e_i + jf_i \quad (2.8)$$

μ μ :

$$\text{Real}\{V_j^2(Y_{ij} + Y_j)^* + V_i^2(Y_{ij} + Y_i)^*\} = G_{ij}(e_i^2 + e_j^2 + f_i^2 + f_j^2)$$

$$\text{Real}\{V_i V_j Y_{ij}^* + V_i V_j Y_{ij}^*\} = \text{Real}\{2(e_i e_j + f_i f_j)G_{ij}\}$$



$\mu \quad \mu \mu \quad :$

$$P_{L_{ij}} = G_{ij} \{ (e_i - e_j)^2 + (f_i - f_j)^2 \}$$

$\mu \quad \mu \quad \mu \quad \mu \mu$

$$P_L = \sum_{k=1}^N G_{ij} \{ (e_i - e_j)^2 + (f_i - f_j)^2 \} \quad (2.9)$$

$k \quad \mu \mu \quad .$

$\mu \quad \mu \quad \mu \quad .$

2.2.1.  $\mu$

$\mu \quad :$

$$S_L = P_L + jQ_L = \sum_i S_i$$

$$S_L = [V_B]^T [I_B]^* + \dots \quad (2.10)$$

$\mu \quad [V_B] = [Z_B][I_B]$

$[Z_B] = [R] + [jX]$

$[I_B] = [I_p] + [jI_q]$

$[Z_B]: \quad .$

$[I_p]: \quad \mu \quad \mu \quad \mu \quad .$

$[I_q]: \quad \mu \quad \mu \quad .$

$\mu \quad :$

$$\begin{aligned} S_L &= [I_B]^T [Z_B][I_B]^* \\ &= ([I_p] + [jI_q])^T ([R] + [jX])([I_p] + [jI_q])^* \end{aligned} \quad (2.11)$$

$$\begin{aligned}
 & \mu \quad \mu \quad \mu \quad \mu : \\
 P_L &= [I_p]^T [R][I_p] + [I_q]^T [R][I_q] \quad (2.12)
 \end{aligned}$$

$$Q_L = [I_p]^T [X][I_p] + [I_q]^T [X][I_q]$$

$\mu :$

$$\begin{aligned}
 P_i + jQ_i &= V_i I_i^* \\
 V_i &= |V_i| (\cos \delta_i + j \sin \delta_i) \\
 I_i &= I_{pi} + jI_{qi}
 \end{aligned}$$

:

$$P_i + jQ_i = |V_i| (\cos \delta_i + j \sin \delta_i) (I_{pi} + jI_{qi}) \quad (2.13)$$

$\mu \mu :$

$$\begin{aligned}
 P_i &= |V_i| I_{pi} \cos \delta_i + |V_i| I_{qi} \sin \delta_i \quad (2.14) \\
 Q_i &= |V_i| I_{pi} \sin \delta_i - |V_i| I_{qi} \cos \delta_i
 \end{aligned}$$

$I_{pi}, I_{qi} :$

$$I_{pi} = \frac{P_i \cos \delta_i + Q_i \sin \delta_i}{|V_i|} \quad (2.15)$$

$$I_{qi} = \frac{P_i \sin \delta_i - Q_i \cos \delta_i}{|V_i|}$$

$\mu \mu$

$$[I_p] = [C][P] + [D][Q] \quad (2.16)$$

$$[I_q] = [D][P] - [C][Q]$$

:

$$\begin{aligned}
 [C]: & \quad \mu \quad (\cos d_i / |V_i|) \\
 [D]: & \quad \mu \quad (\sin d_i / |V_i|)
 \end{aligned}$$



$\mu \dots \mu$ ,  $\mu$ ,  $\mu$ .

$\mu$ ,  $\mu$  :

$$F(x,u)$$

$\mu$   $\mu$  :

$$g(x,u) = 0$$

$$h(x,u) < 0$$

$g(x,u)$  )  $\mu$   $\mu\mu$   $\mu$  (   
 $h(x,u)$   $\mu$   $\mu\mu$   $\mu$   $\mu$   $x$   $u$ .

$\mu$   $x$ ,  $\mu$   $\mu$ ,  $\mu$  :

-  $\mu$    
 - (MVA<sub>r</sub>) ,  $\mu$    
 - .

,  $\mu$   $x$   $\mu$   $\mu$ , :

-  $\mu$   $\mu$ , (MW) (MVA<sub>r</sub>)   
 -  $\mu$   $\mu\mu$ , . . . .

$\mu$   $u$   $\mu$   $\mu$  :

-  $\mu$    
 - (MW MVA<sub>r</sub>)   
 - DC  $\mu$   $\mu\mu$    
 -  $\mu$   $\mu$   $\mu$   $\mu$  tap

$\mu$  . . .  $\mu$   $\mu$   $\mu$   $\mu$   $\mu$   $\mu$  . . . .  $\mu$   $\mu$   $\mu$  .  
 $\mu$   $\mu$   $\mu$  ,  $\mu$   $\mu$   $\mu$  . . .  $\mu$   $\mu$   $\mu$   $\mu$   $\mu$   $\mu$   $\mu$  .  
 $\mu$   $\mu$  .  $\mu$   $\mu$   $\mu$   $\mu$   $\mu$   $\mu$  .


|  |
|--|
| $\mu$  |
| <p>1. _____</p> <ul style="list-style-type: none"> <li>• <math>\mu</math> <math>\mu</math> <math>\mu</math> ( MW)</li> <li>• <math>\mu</math> ,</li> <li>• <math>\mu</math></li> </ul> |
| <p>2. _____</p> <ul style="list-style-type: none"> <li>• ( _____ MW _____ MVAr )</li> </ul>  |
| <p>3. _____</p> <ul style="list-style-type: none"> <li>• <math>\mu\mu</math></li> <li>• <math>\mu</math></li> </ul>  |

2.1

$\mu$



$\mu$        $\mu\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$   
 $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$   
 $\mu\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$   
 $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$   
 $\mu$        $\mu$        $\mu\mu$        $\mu$        $\mu$        $\mu$        $\mu$   
 $\mu\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$



$\mu$  2.1

)

)

$\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu\mu$        $\mu$        $\mu$        $\mu$        $\mu$   
 $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$   
 $\mu\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$        $\mu$





2.  $\mu$   $\mu$   $\mu$   $\mu$  .
3.  $\mu$  /  $\mu$  tap  $\mu$   $\mu$  .
4.  $\mu$   $\mu$   $\mu$  ,  $\mu$   $\mu$   $\mu$   $\mu$   $\mu$  .
5.  $\mu$   $\mu$  .

2.3.2.  $\mu$   $\mu$

$$\mu \quad \mu \quad \mu$$

$$F(x) = \min \sum_{k=1}^N G_{ij} \{ (V_i^2 + V_j^2) - 2V_i V_j \cos(\theta_i - \theta_j) \} \quad (2.18)$$

$\mu$   $k$   $\mu$   $\mu$  .

$\mu$  :

$$P_{g_i} - P_{d_i} = |V_i| \left| \sum_{j=1}^N |V_j| [G_{ij} \cos(\theta_j - \theta_i) - B_{ij} \sin(\theta_j - \theta_i)] \right| \quad (2.19)$$

$$Q_{g_i} - Q_{d_i} = -|V_i| \left| \sum_{j=1}^N |V_j| [G_{ij} \sin(\theta_j - \theta_i) + B_{ij} \cos(\theta_j - \theta_i)] \right| \quad (2.20)$$

$\mu$   $\mu$  :

$$V_{i,\min} < V_i < V_{i,\max}$$

$$\theta_{i,\min} < \theta_i < \theta_{i,\max}$$

taps  $\mu$   $\mu$   $\mu$   $\mu$  :  $\mu$   $\mu$   $\mu$   $\mu$  .

$$\tau_{i,\min} < \tau_i < \tau_{i,\max}$$

$\mu$  :


$$Q_{g_i} + Q_{sh} - Q_{d_i} = -|V_i| \sum_{j=1}^N |V_j| [G_{ij} \sin(\theta_j - \theta_i) + B_{ij} \cos(\theta_j - \theta_i)] \quad (2.21)$$

$\mu$  :

$$Q_{sh,\min} < Q_{sh} < Q_{sh,\max}$$

:

$$P_{f,\min} < P_f < P_{f,\max}$$



$$X = [V_m, \dots, V_n, \theta_2, \dots, \theta_n, Q_{g_2}, \dots, Q_{g_{m-1}}, Q_{sh1}, \dots, Q_{shj}, t_i, \dots, t_j]$$

$\mu$  . :  $\mu$

$$F(x) = \min \sum_{k=1}^N G_{ij} \{(e_i - e_j)^2 + (f_i - f_j)^2\} \quad (2.22)$$

$\mu$  :

$$P_{g_i} - P_{d_i} = (e_i^2 + f_i^2) \sum_{j \in N} (G_{s_{ij}} + G_{ij}) - \sum_{j=1}^N (e_i e_j - f_i f_j) G_{ij} + (f_i e_j - e_i f_j) B_{ij} \quad (2.23)$$

$$Q_{g_i} - Q_{d_i} = -(e_i^2 + f_i^2) \sum_{j \in N} (B_{s_{ij}} + B_{ij}) + \sum_{j=1}^N (e_i e_j - f_i f_j) B_{ij} + (e_i f_j - f_i e_j) G_{ij} \quad (2.24)$$



$\frac{\mu}{\mu} :$ 
 $\mu \mu \dots \mu \mu$   
 $\mu \mu . \mu \mu \dots \mu \mu$   
 $\mu . \mu .$

**2.5 (INTERIOR POINT)**

1984, Karmarkar  $\mu \mu \mu$   
 $\mu \mu \mu , \mu \mu \mu$   
 $\mu \mu \mu$   
 $\mu$  Linear programming  $\mu$  .

1986, Gill et al.  $\mu \mu \mu$  Karmarkar  $\mu \mu \mu$   
 $\mu \mu \mu \mu \mu \mu \mu \mu \mu \mu \mu$   
 $\mu \mu \mu \mu$  .

$\mu \mu :$   
 $\mu \mu \mu$   
 $\mu \mu \mu$   
 $\mu \mu \mu$   
 $\mu \mu$  Lagrange  $\mu \mu \mu$   
 $\mu \mu \mu$

$\mu$  Newton  $\mu \mu \mu$  .

$\mu \mu \mu \mu \mu \mu \mu \mu \mu \mu \mu \mu \mu$   
 $\mu$  2-3.  $\mu \mu x \mu \mu \mu \mu \mu f(x) \mu$   
 $\mu \mu$  .

$$\mu \quad g(x) \quad \mu \quad :$$

$$h^- \leq h(x) \leq h^+$$

$$\mu \quad h \quad h^+ \\ \mu \quad , \quad .$$

$$, \quad \mu \quad \mu \quad \mu$$

$$x^- \leq x \leq x^+$$

$$\mu \quad \mu \quad \mu \quad \mu$$

:

$$\min f(x)$$

$$g(x) = 0$$

$$h(x) + s_h = h^+, \quad s_h + s_{sh} = h^+ - h^-$$

$$x + s_x = x^+$$

$$x - x^- \geq 0, \quad s_x, s_{sh}, s_h \geq 0$$

$$\mu \quad \mu \quad \mu \quad \mu \quad \mu \quad \mu \\ : \quad s_x, s_{sh}, s_h \quad x, x^- \quad \mu \quad \mu \quad \mu \quad 2 \quad \mu \quad \mu \\ \mu \quad \mu \quad \mu \quad \mu \quad \mu \quad \mu \quad \mu \quad \mu \quad \mu \quad \mu$$

:

$$f_\mu(x) = f(x) - \mu \sum_j \ln(x - x^-)_j - \mu \sum_j \ln(s_x)_j - \mu \sum_j \ln(s_{sh})_j - \mu \sum_j \ln(s_h)_j \quad (2.26)$$

$$\mu \quad \mu \quad \mu \quad \mu \quad \mu \quad \mu \quad \mu \quad \mu$$

Lagrange

$$L_\mu = f(x) - \lambda^T g(x) - \lambda^T (h^+ - s_h - h(x)) - \lambda_{sh}^T (s_h + s_{sh} - h^+ - h^-) - \lambda_x^T (x + s_x - x^+) - \mu \sum_j \ln(x - x^-)_j - \mu \sum_j \ln(s_x)_j - \mu \sum_j \ln(s_{sh})_j - \mu \sum_j \ln(s_h)_j \quad (2.27)$$

Newton.

$$\nabla_x L_\mu = \nabla f(x) - \nabla g(x)^T \lambda - \nabla h(x)^T \lambda - \lambda_x - \mu \frac{1}{x - x^-} = 0 \quad (2.28)$$

$$\nabla_{s_h} L_\mu = \lambda_h + \lambda_{sh} - \mu s_h^{-1} = 0$$

$$\nabla_{s_{sh}} L_\mu = \lambda_{sh} - \mu s_{sh}^{-1} = 0$$

$$\nabla_{s_x} L_\mu = \lambda_x + \lambda_{sh} - \mu s_x^{-1} = 0$$

$$\nabla_\lambda L_\mu = -g(x)$$

$$\nabla_{\lambda_s} L_\mu = -(h^+ - s_h - h(x))$$

$$\nabla_{\lambda_{sh}} L_\mu = -(s_h + s_{sh} - h^+ - h^-)$$

$$\nabla_{\lambda_x} L_\mu = -(x + s_x - x^+)$$

Newton.

### 2.5.1

interior point

fmincon (toolbox) Matlab

6

14-

2.5.2  $\mu$  1

$\mu$  3 6

| $\mu$ | (pu) | (degrees) | $P$  | $Q$    | $Q_{min}$ | $Q_{max}$ | $P$  | $Q$    |
|-------|------|-----------|------|--------|-----------|-----------|------|--------|
|       |      |           | (MW) | (MVar) | (MVar)    | (MVar)    | (MW) | (MVar) |
| 1     | 1    | 0         | -    | -      | -         | -         | -    | -      |
| 2     | 1,05 | -         | 100  | 0      | 0         | 500       | -    | -      |
| 3     | 1,05 | -         | 60   | 0      | 0         | 500       | -    | -      |
| 4     | -    | -         | -    | -      | -         | -         | 60   | 40     |
| 5     | -    | -         | -    | -      | -         | -         | 60   | 50     |
| 6     | -    | -         | -    | -      | -         | -         | 70   | 40     |

2.3  $\mu$  6

4 1 2 3 6

$\mu\mu$  :

|   |   | $\mu$ $\mu\mu$ |          |                |
|---|---|----------------|----------|----------------|
|   |   | $\mu\mu$       | $\mu\mu$ | $\mu$ $\mu\mu$ |
| 1 | 2 | 0,1            | 0,2      | 0,02           |
| 1 | 4 | 0,05           | 0,2      | 0,02           |
| 1 | 5 | 0,08           | 0,3      | 0,03           |
| 2 | 3 | 0,05           | 0,25     | 0,03           |
| 2 | 4 | 0,05           | 0,1      | 0,01           |
| 2 | 5 | 0,1            | 0,3      | 0,02           |
| 2 | 6 | 0,07           | 0,2      | 0,025          |
| 3 | 5 | 0,12           | 0,26     | 0,025          |
| 3 | 6 | 0,02           | 0,1      | 0,01           |
| 4 | 5 | 0,2            | 0,4      | 0,04           |
| 5 | 6 | 0,1            | 0,3      | 0,03           |

2.4  $\mu\mu$   $\mu$  6







μ μ μ μ μ μ

2.5.3 μ 2

μ μ μ μ μ -14 .

14 :

| μ  | (pu) | (degrees) | P    | Q      | Q <sub>min</sub> | Q <sub>max</sub> | P    | Q      |
|----|------|-----------|------|--------|------------------|------------------|------|--------|
|    |      |           | (MW) | (MVar) | (MVar)           | (MVar)           | (MW) | (MVar) |
| 1  | 1,06 | 0         | -    | -      | -100             | 100              | -    | -      |
| 2  | -    | -         | 40   | -      | -100             | 100              | 21,7 | 12,7   |
| 3  | -    | -         | 0    | -      | -100             | 100              | 94,2 | 19     |
| 4  | -    | -         | -    | -      | -                | -                | 47,8 | -3,9   |
| 5  | -    | -         | -    | -      | -                | -                | 7,6  | 1,6    |
| 6  | -    | -         | 0    | -      | -100             | 100              | 11,2 | 7,5    |
| 7  | -    | -         | -    | -      | -                | 0                | 0    | 0      |
| 8  | -    | -         | 0    | -      | -100             | 100              | 0    | 0      |
| 9  | -    | -         | -    | -      | -                | -                | 29,5 | 16,6   |
| 10 | -    | -         | -    | -      | -                | -                | 9    | 5,8    |
| 11 | -    | -         | -    | -      | -                | -                | 3,5  | 1,8    |
| 12 | -    | -         | -    | -      | -                | -                | 6,1  | 1,6    |
| 13 | -    | -         | -    | -      | -                | -                | 13,5 | 5,8    |
| 14 | -    | -         | -    | -      | -                | -                | 14,9 | 5      |

2.7 μ 14 .

(3, 6, 8) μ Pg=0. 1  
 μ 11 μ  
 μ 9 14 .  
 μ



$\mu \qquad \qquad \qquad \mu \qquad \qquad \qquad 34. \qquad \mu \qquad \qquad \mu$   
 $\qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \qquad \mu$

$$x = [P_{g1}, Q_{g1}, Q_{g2}, Q_{g3}, Q_{g6}, Q_{g8}, Q_{sh,9}, Q_{sh,14}, V_2, V_3, V_4, V_5, V_6, V_7, V_8, V_9, V_{10},$$

$$V_{11}, V_{12}, V_{13}, V_{14}, d_2, d_3, d_4, d_5, d_6, d_7, d_8, d_9, d_{10}, d_{11}, d_{12}, d_{13}, d_{14}]$$

$\mu \qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \mu \qquad \mu$   
 $\qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \mu$   
 $\mu \qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \mu$   
 $\qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \mu$   
 $\mu \qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \mu$   
 $\qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \qquad \mu \qquad \qquad \mu$

Ploss=13,246MW.

$\mu \qquad \mu \qquad \qquad \qquad \mu$   
:

|          |          |          |          |          |          |            |             |
|----------|----------|----------|----------|----------|----------|------------|-------------|
| $P_{g1}$ | $Q_{g1}$ | $Q_{g2}$ | $Q_{g3}$ | $Q_{g6}$ | $Q_{g8}$ | $Q_{sh,9}$ | $Q_{sh,14}$ |
| 232,4    | -20,5    | 34,9     | 26,9     | 16,9     | -27,6    | 44,5       | 6,7         |

|       |       |       |       |       |       |       |       |
|-------|-------|-------|-------|-------|-------|-------|-------|
| $V_2$ | $V_3$ | $V_4$ | $V_5$ | $V_6$ | $V_7$ | $V_8$ | $V_9$ |
| 1,045 | 1,015 | 1,023 | 1,027 | 1,1   | 1,057 | 1,008 | 1,093 |

|          |          |          |          |          |        |         |         |
|----------|----------|----------|----------|----------|--------|---------|---------|
| $V_{10}$ | $V_{11}$ | $V_{12}$ | $V_{13}$ | $V_{14}$ | $d_2$  | $d_3$   | $d_4$   |
| 1,087    | 1,09     | 1,087    | 1,084    | 1,082    | -4,975 | -12,727 | -10,351 |

|        |         |         |         |         |          |          |          |
|--------|---------|---------|---------|---------|----------|----------|----------|
| $d_5$  | $d_6$   | $d_7$   | $d_8$   | $d_9$   | $d_{10}$ | $d_{11}$ | $d_{12}$ |
| -8,842 | -14,074 | -13,374 | -13,374 | -14,896 | -15,022  | -14,678  | -14,905  |

|          |          |
|----------|----------|
| $d_{13}$ | $d_{14}$ |
| -15,046  | -16,134  |

2.9  $\mu$  14 -interior point.



μ μ μ μ μ .  
 μ μ :

Ploss= 147 KW

2.5.4 μ 2-

μ μ μ μ , μ μ μ μ  
 μ μ 9 14.  
 , μ μ μ μ μ  
 μ 0.

μ μ :

|          |          |          |          |          |          |            |             |
|----------|----------|----------|----------|----------|----------|------------|-------------|
| $P_{g1}$ | $Q_{g1}$ | $Q_{g2}$ | $Q_{g3}$ | $Q_{g6}$ | $Q_{g8}$ | $Q_{sh,9}$ | $Q_{sh,14}$ |
| 232,4    | -21,1    | 36,9     | 20,6     | 20,3     | -17,7    | 0          | 0           |

|       |       |       |       |       |       |       |       |
|-------|-------|-------|-------|-------|-------|-------|-------|
| $V_2$ | $V_3$ | $V_4$ | $V_5$ | $V_6$ | $V_7$ | $V_8$ | $V_9$ |
| 1,046 | 1,016 | 1,024 | 1,026 | 1,089 | 1,072 | 1,1   | 1,068 |

|          |          |          |          |          |        |         |         |
|----------|----------|----------|----------|----------|--------|---------|---------|
| $V_{10}$ | $V_{11}$ | $V_{12}$ | $V_{13}$ | $V_{14}$ | $d_2$  | $d_3$   | $d_4$   |
| 1,064    | 1,073    | 1,074    | 1,069    | 1,051    | -4,986 | -12,736 | -10,351 |

|        |         |         |         |         |          |          |          |
|--------|---------|---------|---------|---------|----------|----------|----------|
| $d_5$  | $d_6$   | $d_7$   | $d_8$   | $d_9$   | $d_{10}$ | $d_{11}$ | $d_{12}$ |
| -8,836 | -14,226 | -13,313 | -13,313 | -14,839 | -15,005  | -14,738  | -15,051  |

|          |          |
|----------|----------|
| $d_{13}$ | $d_{14}$ |
| -15,117  | -15,932  |

2.11 μ 14 -interior point Qsh.







Wu (EP)

Lai, EP

Lee

(SGA)

Yoshida

Particle Swarm Optimization (PSO)

(Artificial Intelligence)

(differential evolutionary algorithm)

(EA),

taps

DE

Evolutionary algorithms

(ES),

DE

(GA)

### 2.6.2 Differential evolutionary algorithm

(DEA)

DEA

D

NP.

$$X_{i,k}^G = X_{k_{\min}} + rand[0,1]*(X_{k_{\max}} - X_{k_{\min}})$$

$$i \in [1, N_D] \quad k \in [1, D]$$





,  $\mu$ ,  $\mu$   $\mu$   $\mu$  ,

2.6.3.  $\mu$

$\mu$   $\mu$  ,  $\mu$   $\mu$   
 $\mu$  taps  $\mu$   $\mu$  ,  $\mu$   $\mu$   $\mu$   $\mu$   
 $\mu$   $\mu$  ,  $\mu$   $\mu$   $\mu$   $\mu$   
 $\mu$   $\mu$   $\mu$  .  $\mu$   $\mu$   $\mu$   $\mu$  .

$$x_i = x_i \quad \mu$$

$$x_i = [x_i] \quad \mu$$

$\mu$   $\mu$  [x]  $\mu$   $\mu$  OPF  $\mu$   $\mu$   
 $\mu$   $\mu$  x. :  $\mu$   $\mu$   $\mu$   $\mu$  .  
 $\mu$   $\mu$  taps  $\mu$   $\mu$  ,  $\mu$   $\mu$  .  
 $\mu$   $\mu$   $\mu$  taps .  $\mu$   
 $\mu$   $\mu$   $\mu$  . taps ,

$$t_k = t_{k \min} + n_k * \Delta_{t_k}$$

$n_k$   $\mu$   $\mu$  taps  $\Delta_{t_k}$   $\mu$   $\mu$   
taps.  $\mu$   $\mu$  ,  $\mu$   $\mu$   $\mu$   
 $\mu$   $\mu$  .  $\mu$   $\mu$   $\mu$   
 $\mu$   $\mu$   $\mu$   $\mu$   
.  $\mu$   $\mu$   $\mu$

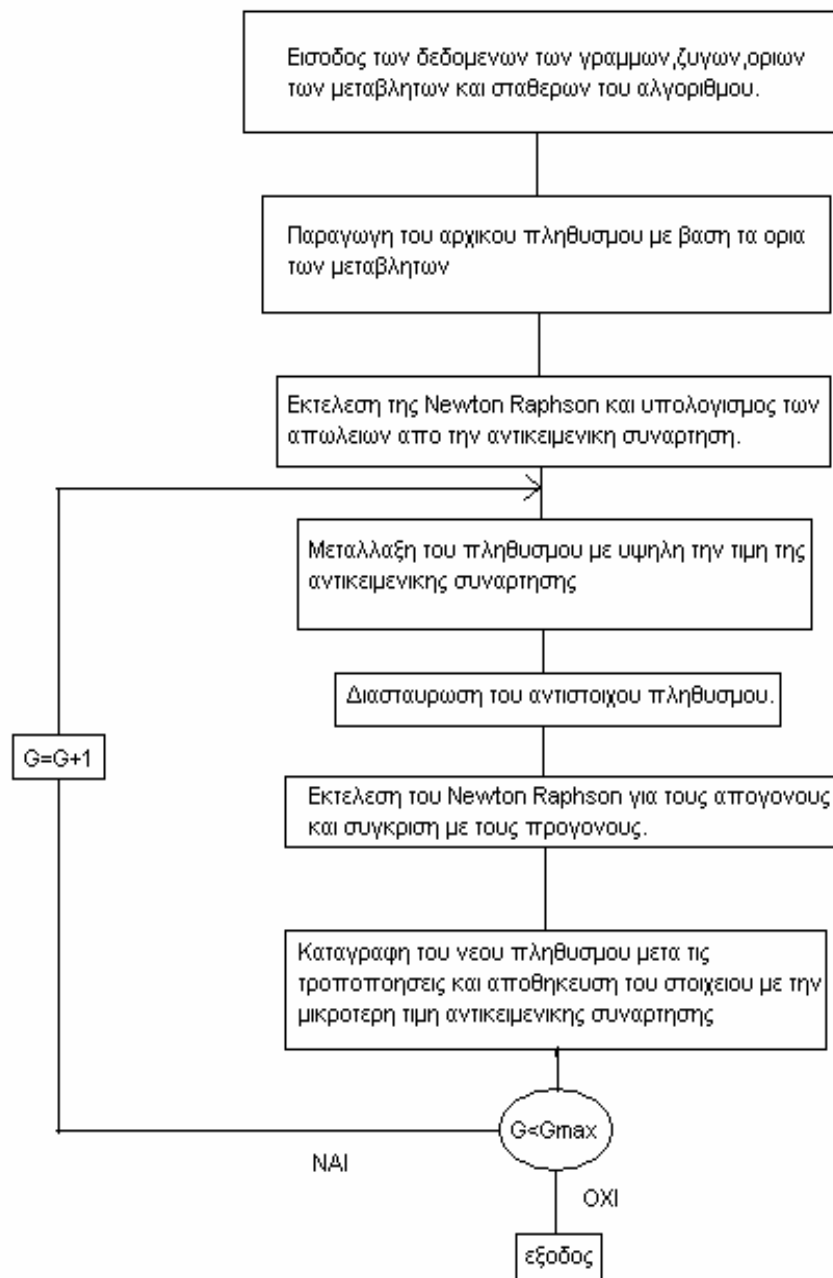
2.6.3.  $\mu$   $\mu$

- $\mu$ 
  - DE  $\mu$
  - :
- $\mu$  1:  $\mu$   $\mu$   $\mu$
- $\mu$  2:  $\mu$   $\mu$  Newton Raphson  $\mu$   $\mu$
- $\mu$  3:  $\mu$   $\mu$   $\mu$
- $\mu$  4:  $\mu$  ( $\mu$  )
- $\mu$  5:  $\mu$  , $\mu$  ,
- $\mu$  6:  $\mu$   $\mu$   $\mu$
- $\mu$  7: ( $\mu$   $\mu$   $^2$   $\mu$   $^6$   $\mu$  ).

μ μ μ  
μ μ :

μ


μ



μ 2.4 μμ differential evolutionary algorithm

2.6.4  $\mu$   $\mu$

2.6.4. .



- $T_{4-7} = 0,9467.$
- $T_{4-9} = 0,9524.$
- $T_{5-6} = 0,9091.$

taps :  $0,9 < T_{i-j} < 1,1$

$\mu$  9 14  $\mu$  .  
 $\mu$  :

Qsh,i = 0 , 6, 12, 18 Mvar.

$\mu$   $\mu$   $\mu$  .  
 $\mu$   $\mu$   $\mu$   $\mu$   $\mu$   $\mu$  .  
 ratio ,  $\mu$   $\mu$  ,  $\mu$   $\mu$   $\mu$  : crossover  $\mu$

- Max no. of generations = 100
- Population size = 30
- Step size (s) = 0.8
- Crossover ratio (CR) = 0.8

2.6.4. I

μ μ μ μ μ μ μ μ  
 μ μ DEA μ μ μ μ μ μ μ  
 taps μ μ μ μ μ μ μ μ  
 μ μ μ μ μ μ μ μ  
 :  
 $Q_{sh,9} = 18 \text{ Mvar}$      $Q_{sh,14} = 18 \text{ Mvar}$ .  
 μ μ μ μ μ μ μ μ    Newton-Raphson μ  
 μ μ μ μ μ μ μ μ :

|       |         |
|-------|---------|
|       | μ       |
|       | V(p.u.) |
| V1    | 1.060   |
| V2    | 1.045   |
| V3    | 1.010   |
| V6    | 1.070   |
| V8    | 1.090   |
|       |         |
|       | P(MW)   |
| Ploss | 13.430  |

**2.12** μ 14 - -R.

μ μ μ μ μ μ μ μ  
 μ μ Newton Raphson μ μ μ μ  
 μ μ μ μ μ μ μ μ  
 μ μ μ μ μ μ μ μ  
 μ μ μ μ μ μ μ μ  
 :

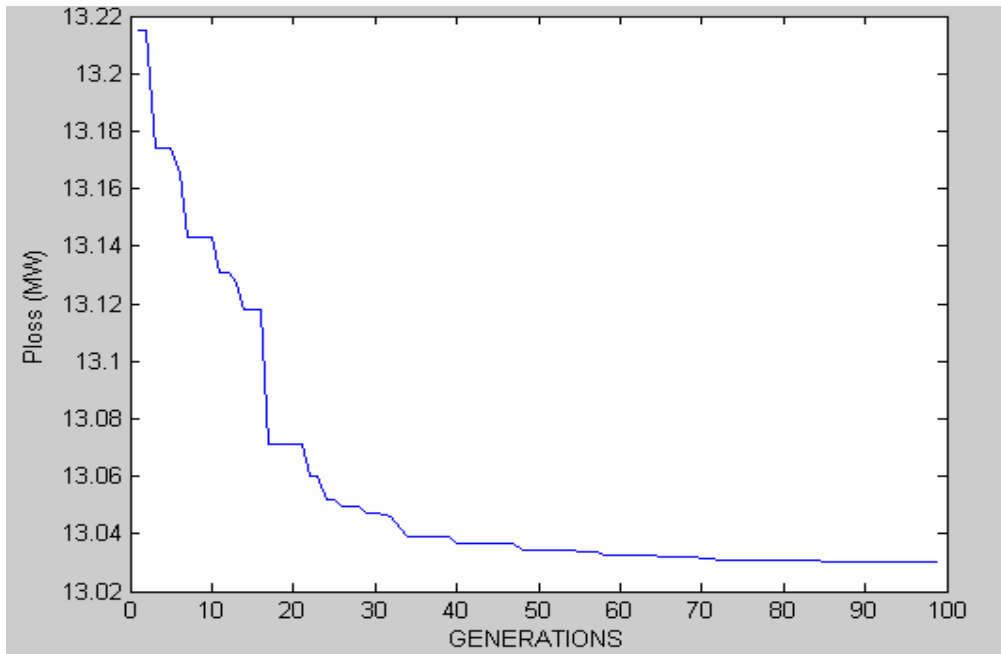









μ μμ μ μ  
 :




μ 2.7 μ DEA-

μ 1 μ Ploss μ μ  
 μ μ μ .



μ 2.8. μ DEA-



$\mu$  2.8.  $\mu$  DEA-

$\mu$  1


$\mu$   $\mu$

$\mu$

$\mu$

.

taps  $\mu$   $\mu$  :  $\mu\mu$   $\mu$  .



$\mu$  2.9  $\mu$   $\mu$   $\mu$  DEA -

$\mu$   $\mu$   $\mu$

$\mu\mu$

$\mu$   $\mu$  .


$\mu$  0,1  $\mu$

$\mu$  [0,9-1,1].

.  $\mu$   $\mu$

μ μ μ

μ :



μ 2.10 μ DEA-

μ μ μ μ μ μ μ . :

$Q_{sh, 9} = 3 \cdot 6 = 18 \text{ Mvar}$  ,  $Q_{sh, 14} = 1 \cdot 6 = 6 \text{ Mvar}$







$\mu_A(x)$  is a function from the universe of discourse  $X$  to the interval  $[0,1]$ .  
 $\mu_A(x) \in [0,1]$  for all  $x \in X$ .

### 3.2.2 Fuzzy Sets

Let  $A$  be a fuzzy set in the universe of discourse  $X$ . The membership function  $\mu_A(x)$  is defined as follows:

- $\mu_A(x)$  is a real number in the interval  $[0,1]$ .
- $\mu_A(x)$  (ad hoc) is the degree of membership of  $x$  in  $A$ .
- $\mu_A(x)$  is the degree of truth of the statement " $x$  is  $A$ ".
- $\mu_A(x)$  is the degree of membership of  $x$  in  $A$ .
- $\mu_A(x)$  is the degree of membership of  $x$  in  $A$ .


$\mu_A(x) \in [0,1]$ ,  
 $(\mu_A(x) = 1)$        $(\mu_A(x) = 0)$ .

Example: Let  $X$  be the universe of discourse "height in meters".  
 Let  $A$  be the fuzzy set "tall".  
 Then  $\mu_A(2.50) = 1$  and  $\mu_A(1.80) = 0$ .  
 If  $x = 1.79$ , then  $\mu_A(x)$  is a real number in the interval  $[0,1]$ .







sigmoidal ,  
 , psigmf:  
 dsigmf,  $\mu$  sigmoidal



sigmf



dsigmf




psigmf


$\mu$  3.3.

$\mu\mu$  .


$\mu$  .  
 $\mu$  .  
 $\mu$  , smf ,  $\mu\mu$  Z  
 $\mu$  , pimf  $\mu$   $\mu$   $\mu$  :



zmf



pimf



smf

$\mu$  3.3.

$\mu\mu$  .

### 3.2.3

$\mu$   $\mu\mu$   $\mu$   $\mu$  :

$$A = \{(x, \mu_A(x)), x \in X\}. \quad (3.1)$$

$\mu$   $\mu$   $\mu$  -  $\mu$  .

(support set) , :

$$\text{supp}(A) = \{x \in X \mid \mu(x) > 0\}. \quad (3.2)$$

$\mu$  (supremum)  $\mu$  (height),  $\mu$

$$\text{htg}(A) = \sup_{x \in X} \mu_A(x).$$

$$\frac{\mu_A(x)}{\max \mu_A(x)}.$$

$[0,1]$ ,  $\mu$  -level  $\mu$  -cut (crisp)

$$A = \{x \in X \mid \mu(x) \geq \mu\}, \quad \mu \in [0,1]. \quad (3.3)$$

$\mu = 1$ ,  $1$   $\mu$  (kernel) (core),

$$A = \{x \in X \mid \mu(x) = 1\}. \quad (3.4)$$

$\mu$  ,  $\mu$

$$A = \emptyset \Leftrightarrow \mu(x) = 0 \quad \forall x \in X. \quad (3.5)$$

$$\mu_A(x) < \mu_B(x). \quad (3.6)$$

$\mu_{x \in U}$  ,  $\mu = \mu$

$$\mu_A(x) = \mu_B(x). \quad (3.7)$$

### 3.2.4

$\mu$

$\mu \mu$

#### 3.2.4.

CON(A)

$\mu$

$\mu$

$\mu\mu$

:

$$\mu_{CON(A)}(x) = (\mu_A(x))^2 \quad (3.8)$$

$\mu$

$\mu$

#### 3.2.4.

:

$$\mu_{DIL(A)}(x) = \sqrt{\mu_A(x)} \quad (3.9)$$

$\mu$

$\mu$

#### 3.2.4.

$\mu$

$\mu$

Boolean

$\mu$

$\mu\mu$

0 (

)

1 (

$\mu$

$\mu$

)

$\mu$

$\mu$

$\mu$

0  $\mu$

$\mu$

1.

$\mu$

$\mu$

$\mu$

$\mu$

$\mu$

$\mu$

$\mu$

$\mu\mu$

$\mu$

$\mu$



3.2.4.

AND, OR, NOT.  $\mu(A \cup B) = \max(\mu_A, \mu_B)$ ,  $\mu(A \cap B) = \min(\mu_A, \mu_B)$ .

(aggregates)  $\mu_{A \cup B} = \max(\mu_A, \mu_B)$  :  $\mu_{A \cap B} = \min(\mu_A, \mu_B)$

$$\mu_{A \cap B} = T(\mu_A(x), \mu_B(x)) \quad (3.10)$$

$\mu_A(x), \mu_B(x)$ .  $T$  (triangular norm)

- $T(0, 0) = 0, T(a, 1) = T(1, a) = a$ .
- $T(a, b) \leq T(c, d) \quad a \leq c \quad b \leq d$ .
- $T(a, b) = T(b, a)$ .
- $T(a, T(b, c)) = T(T(a, b), c)$ .

sets).  $\mu$  (crisp)

$\mu_{A * B}(x) = \mu_A(x) * \mu_B(x)$

$\mu_{A * B}(x) = \mu_A(x) * \mu_B(x)$  :

$$\mu_{A * B}(x) = \mu_A(x) * \mu_B(x), \quad x \in U \quad (3.11)$$



$\mu_{A \cup B} = S(\mu_A(x), \mu_B(x)) \quad (3.12)$

- $S(1, 1) = 1, S(a, 0) = S(0, a) = a.$
- $M : S(a, b) \leq S(c, d) \quad a \leq c \quad b \leq d.$
- $\mu : S(a, b) = S(b, a).$
- $: S(a, S(b, c)) = S(S(a, b), c).$

$\mu_{A \hat{+} B} : \mu_{\hat{+}}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x)\mu_B(x), \quad x \in U \quad (3.13)$

$\mu_{\bar{A}}(x) = C(\mu_A(x)) \quad (3.14)$

- $c(0)=1 \quad c(1)=0.$
- $: \forall a \in [0,1], \alpha \forall a \leq b \Rightarrow c(a) \geq c(b).$
- $: c \quad [0,1].$
- $\cdot \forall a \in [0,1] \quad c(c(a))=a.$

**3.2.5 ( fuzzy relations )**

(fuzzy relations)  
 $( \dots x \in X, X \times Y \times Z )$ .  $\mu$   
 $R = \langle x \quad y \rangle \mu \quad x \in X, y \in Y \quad R \in X \times Y.$

$$\mu_{R(x,y)} = \mu_{R_1(x,y)} \cdot \mu_{R_2(x,y)}$$

$$R = \begin{bmatrix} \mu_R(x_1, y_1) & \mu_R(x_1, y_2) & \cdots & \mu_R(x_1, y_n) \\ \mu_R(x_2, y_1) & \mu_R(x_2, y_2) & \cdots & \mu_R(x_2, y_n) \\ \vdots & \vdots & \ddots & \vdots \\ \mu_R(x_m, y_1) & \mu_R(x_m, y_2) & \cdots & \mu_R(x_m, y_n) \end{bmatrix}$$

(composition)

$$\mu_{R(x,z)} = \mu_{R_1(x,y)} \cdot \mu_{R_2(y,z)}$$

$R = R_1 \circ R_2$

---


$$R(x,y) = R^{-1}(y,x)$$

---

H

$$\mu_{R_1(x,y)} \cdot \mu_{R_2(y,z)} = \mu_{R_1 \circ R_2(x,z)}$$

$R_1 \circ R_2$



$\mu$  (antecedent premise)  $\mu$  ' y B'  
 $\mu$   $\mu$   $\mu$  (consequent conclusion).  $\mu$   
 $\mu$  :

**if service is good then tip is average**

good  $\mu$   $\mu$   $\mu$  0  
 1.  $\mu$   $\mu$  average 0  
 $\mu$  y. if-then 'is'  $\mu$   
 $\mu$   $\mu$   $\mu$  .  $\mu$   
 (  $\mu$   $\mu$   $\mu$  ==).  $\mu$   
 $\mu$   $\mu$   $\mu$  =). (  $\mu$   
 $\mu$   $\mu$   $\mu$  :  $\mu$

**If service == good then tip = average**

if-then  $\mu$   $\mu$   
 $\mu$   $\mu$   $\mu$   $\mu$   $\mu$   $\mu$   
 $\mu$  (defuzzification).  
 $\mu$  .  
 :  $\mu$   $\mu$  If-then  $\mu$   
 - 'fuzzifying' - (  $\mu$   
 )  $\mu$   
 - )  $\mu$   $\mu$   $\mu$   $\mu$  (  $\mu$   
 $\mu$   $\mu$   $\mu$   $\mu$  , if-then  
 $\mu$   $\mu$   $\mu$   $\mu$   $\mu$  ,  
 $\mu$   $\mu$   $\mu$   $\mu$   $\mu$   $\mu$   
 $\mu$   $\mu$  :  $\mu$   
 • ) :  $p \rightarrow q$  (  $p$   $q$  )

- $\mu_{(p \rightarrow q)} = 0.5 p \rightarrow 0.5 q$

$\mu_{(p \rightarrow q)} = 0.5 \mu_p \rightarrow 0.5 \mu_q$

**if sky is gray and wind is strong and barometer is falling, then ...**

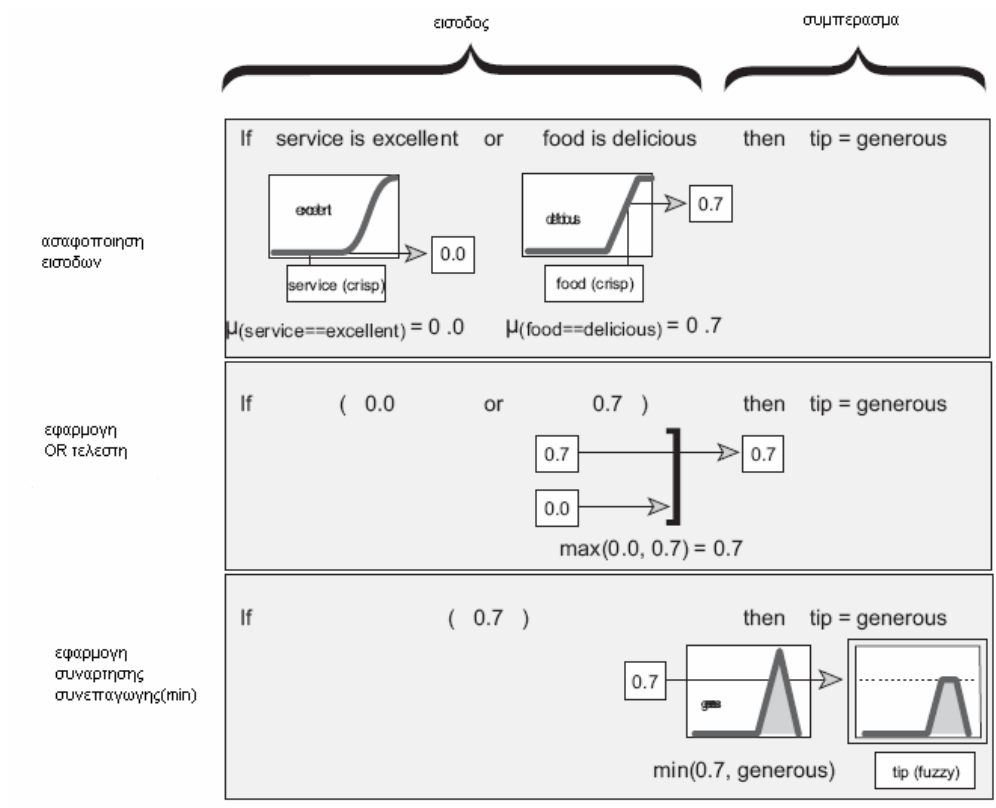
$\mu_{(p \wedge q \wedge r)} = \mu_p \wedge \mu_q \wedge \mu_r$

**if temperature is cold then hot water valve is open and cold water valve is shut**

$\mu_{(p \rightarrow q)} = \mu_p \rightarrow \mu_q$  (implication function)


$\mu_{(p \rightarrow q)} = \min(\mu_p, \mu_q)$

if-then.



$\mu_{(p \rightarrow q)}$

### 3.2.7 μ (fuzzy inference systems)

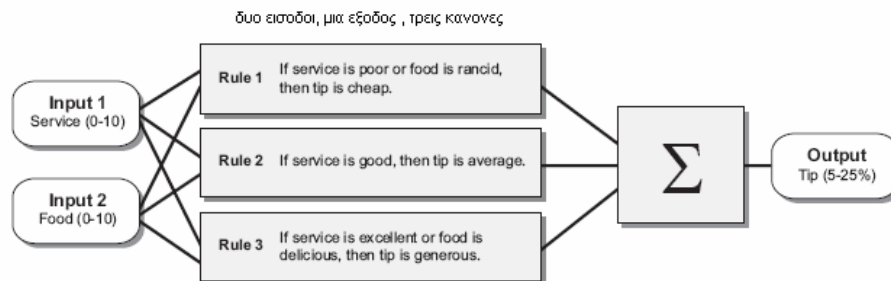


#### 3.2.7. μ Mamdani

Η διαδικασία της ασαφούς συλλογιστικής περιλαμβάνει όλα εκείνα τα κομμάτια στα οποία αναφερθήκαμε αναλυτικά προηγουμένως. Δηλαδή τις συναρτήσεις συμμετοχής, τους ασαφείς λογικούς τελεστές και τους κανόνες if-then. Υπάρχουν δύο είδη ασαφών συστημάτων παρεμβολής τα τύπου-Mamdani και τα τύπου Sugeno. Οι διαφορές ανάμεσα στα δύο αυτά συστήματα έγκεινται κυρίως στον τρόπο με τον οποίο σχηματίζεται η έξοδος του συστήματος. Τα συστήματα Mamdani είναι αυτά που συναντώνται συχνότερα. Η μεθοδολογία των συστημάτων Mamdani εισήχθηκε το 1975 από τον Ebrahim Mamdani.

Η κατανόηση των FIS αλλά και η διάφορα των δυο συστημάτων παρεμβολής φαίνεται πιο κατανοητά με το παράδειγμα του φιλοδώρηματος. Αρχικά εφαρμόζουμε το FIS τύπου Mamdani.

Το σύστημα έχει δύο εισόδους και τρεις κανόνες. Οι εισόδοι του συστήματος είναι η ποιότητα του φαγητού και η εξυπηρέτηση. Θεωρούμε ότι ο πελάτης βαθμολογεί την ποιότητα του φαγητού και την εξυπηρέτηση με  $\mu$  ια κλίμακα από το 0 έως το 10. Η έξοδος του συστήματος είναι το φιλοδώρημα που θα δώσει ο πελάτης και το οποίο κυμαίνεται από 5% έως 25% της τιμής του λογαριασμού. Η δομή του συστήματος φαίνεται στο διάγραμμα:



μ 3.7 Μορφές συστημάτων ασαφούς λογικής.

Η πληροφορία οδεύει από τα αριστερά προς τα δεξιά και καταλήγει από τις δυο εισόδους σε μία μοναδική έξοδο. Ένα σημαντικό χαρακτηριστικό των συστημάτων ασαφούς λογικής είναι η παράλληλη εφαρμογή των κανόνων. Στα κλασικά συστήματα δυαδικής λογικής έχουμε χρήση διακοπών που ανοίγουν και κλείνουν ανάλογα με τις τιμές των εισόδων. Στα ασαφή συστήματα μεταβαίνουμε ομαλά από περιοχή σε περιοχή ανάλογα με τις συνέπειες των κανόνων.

Η διαδικασία της απεικόνισης των εισόδων στις εξόδους μέσα από ένα σύστημα ασαφούς λογικής ακολουθεί πέντε βήματα:


- Ασαφοποίηση των εισόδων.
- Εφαρμογή των ασαφών λογικών τελεστών στις εισόδους.
- Καθορισμός των συνεπαγωγών των κανόνων.
- Συγκέντρωση όλων των συνεπαγωγών όλων των κανόνων.
- Αποσαφήνιση.

Ακολουθεί μια αναλυτική περιγραφή των βημάτων.

#### 1<sup>ο</sup> : Ασαφοποίηση εισόδων.

Το πρώτο βήμα έχει να κάνει με την ασαφοποίηση των εισόδων δηλαδή αυτό που έχουμε να κάνουμε είναι να πάρουμε τις εισόδους και να καθορίσουμε σε ποιο βαθμό κάθε είσοδος ανήκει σε ένα ασαφές σύνολο μέσω των συναρτήσεων συμμετοχής. Οι εισοδοί είναι αριθμητικές τιμές μέσα στα όρια του χώρου αναφοράς (στην περίπτωση του προβλήματος μας από 0 μέχρι 10) και οι έξοδοι είναι βαθμοί συμμετοχής στο προσδιορισμένο ασαφές σύνολο. Η ασαφοποίηση των εισόδων μπορεί να γίνει είτε με χρήση πίνακα τιμών είτε μέσα από μια αποτίμηση μιας συνάρτησης.

Το παράδειγμα μας είναι βασισμένο σε τρεις κανόνες και κάθε ένας από αυτούς προϋποθέτει την κατάταξη των εισόδων σε διαφορετικές λεκτικές μεταβλητές: service is poor, service is good, food is rancid, food is delicious κ.ο.κ. Πριν να εφαρμοσθούν οι κανόνες θα πρέπει να ασαφοποιηθούν οι εισοδοί σύμφωνα με τις λεκτικές μεταβλητές. Για παράδειγμα σε ποιο βαθμό το φαγητό είναι νόστιμο. Αν υποθέσουμε ότι το φαγητό έχει αξιολογηθεί με μια συγκεκριμένη βαθμολογία από το 0 έως το 10 (π.χ. 8) τότε πως μπορούμε να συμπεράνουμε σε ποιο βαθμό είναι νόστιμο χρησιμοποιώντας μια συνάρτηση συμμετοχής με βάση το παρακάτω σχήμα :



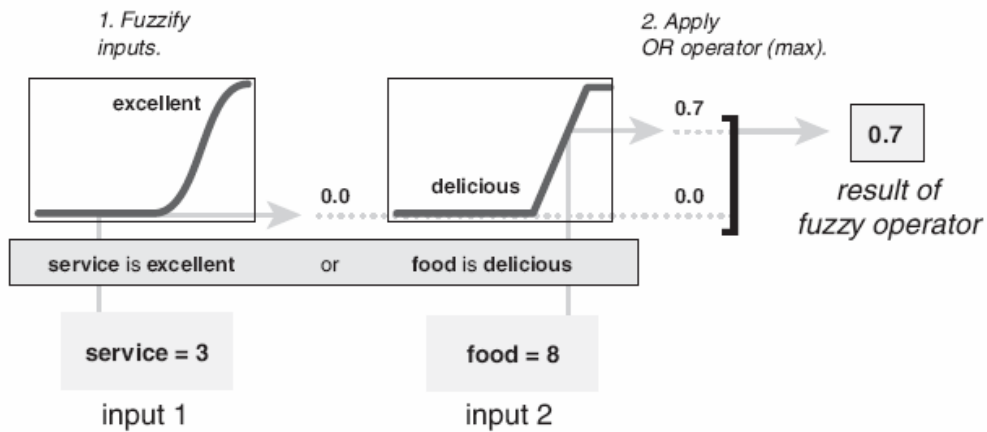
**μ 3.8** Ασαφοποίηση εισόδων

Κατά αυτόν τον τρόπο, κάθε είσοδος ασαφοποιείται μέσω των συναρτήσεων συμμετοχής που διαμορφώνονται από κανόνες .

2<sup>ο</sup> : Εφαρμογή των ασαφών τελεστών.

Μετά την ασαφοποίηση των εισόδων μπορούμε να γνωρίζουμε σε ποιο βαθμό ικανοποιείται κάθε μέρος των προϋποθέσεων των if-then κανόνων. Αν ένας κανόνας if-then έχει στο σκέλος if περισσότερα του ενός μέρη τότε πρέπει να εφαρμοσθούν οι ασαφείς τελεστές ώστε να καθορισθεί ένα νούμερο που αντιπροσωπεύει το αποτέλεσμα της προϋπόθεσης του κανόνα. Το νούμερο αυτό θα εφαρμοσθεί έπειτα στη συνάρτηση εξόδου. Οι εισοδοί ενός λογικού τελεστή είναι δύο ή περισσότεροι βαθμοί συμμετοχής που έχουν προκύψει μετά από το πρώτο βήμα που αναφέραμε παραπάνω . Η έξοδος του τελεστή είναι απλά ένας βαθμός αλήθειας.

Όπως είδαμε κατά την αναφορά στους ασαφείς τελεστές υπάρχει ένας μεγάλος αριθμός συναρτήσεων που μπορούν να χρησιμοποιηθούν για να ορίσουν τους τελεστές AND και OR. Συνήθως χρησιμοποιούνται ο τελεστής max για το OR και min για το AND. Στο παρακάτω διάγραμμα βλέπουμε πως εφαρμόζεται ο τελεστής OR και η ίδια αντιστοιχία ισχύει και για τον AND.




**μ 3.9** Εφαρμογή ασαφών τελεστών.



### 3<sup>ο</sup> : Εφαρμογή της μεθόδου implication.

Πριν εφαρμόσουμε την συνάρτηση συνεπαγωγής πρέπει να καθορίζουμε το βάρος του κάθε κανόνα. Κάθε κανόνας if-then έχει βάρος που μπορεί να κυμαίνεται από 0 έως 1 και το οποίο εφαρμόζεται στο νούμερο που δίνει το κομμάτι της υπόθεσης. Συνήθως τα βάρη αυτά είναι ίσα με 1, ωστόσο μπορούμε να δώσουμε σ' αυτά μια οποιαδήποτε τιμή από 0 έως 1. Για παράδειγμα αν θέλουμε να δώσουμε μικρότερη έμφαση σε έναν κανόνα σε σχέση με κάποιον άλλο, αυτό μπορούμε να το κάνουμε μέσω των τιμών των βαρών τους.

Αφού έχουμε αναθέσει στους κανόνες τα βάρη μπορούμε να εφαρμόσουμε την συνάρτηση συνεπαγωγής. Το αποτέλεσμα ενός κανόνα if-then είναι ένα ασαφές σύνολο που αντιπροσωπεύεται από μια συνάρτηση συμμετοχής που σταθμίζει κατάλληλα τα λεκτικά χαρακτηριστικά που έχουν ανατεθεί σ' αυτόν. Το αποτέλεσμα αυτό αναδιαμορφώνεται με τη χρήση μιας συνάρτησης που είναι συνδεδεμένη με το μέρος της υπόθεσης. Η είσοδος για τη διαδικασία συνεπαγωγής είναι ένας αριθμός που δίδεται από την υπόθεση και η έξοδος είναι ένα ασαφές σύνολο. Αυτή η διαδικασία εφαρμόζεται για κάθε κανόνα και η συνηθέστερη συνάρτηση είναι αυτή του min:



**μ 3.10** Εφαρμογή της μεθόδου implication.

### 4<sup>ο</sup> : Συγκέντρωση των αποτελεσμάτων κάθε εξόδου.

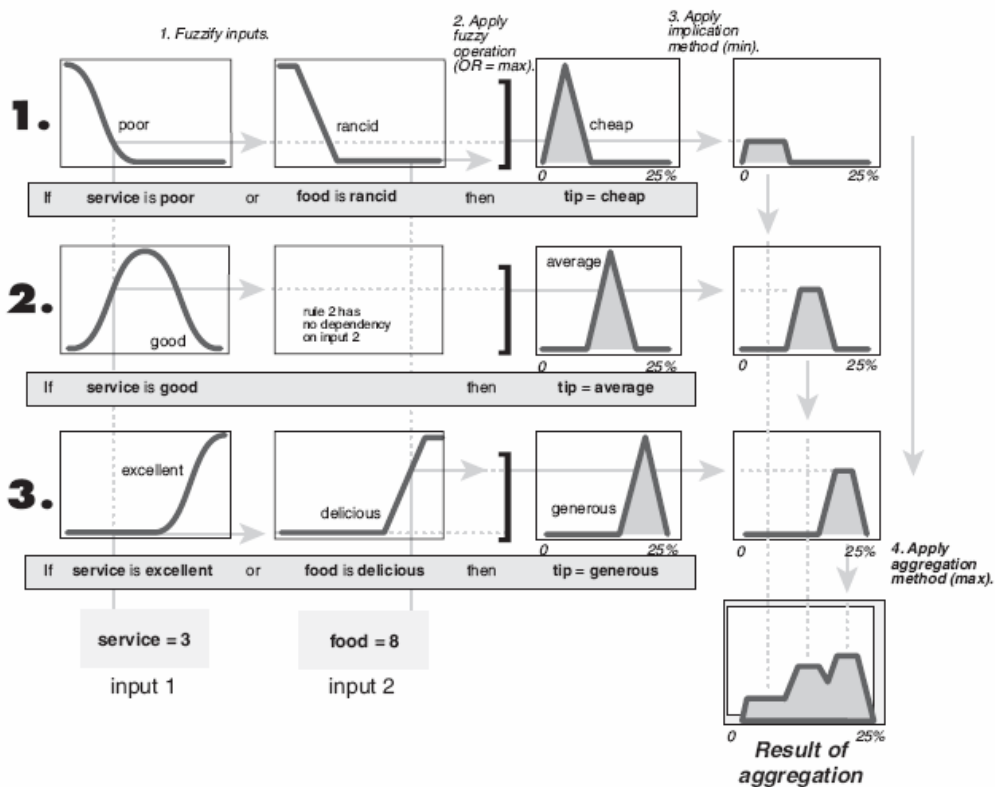
Επειδή οι αποφάσεις βασίζονται στον έλεγχο όλων των κανόνων σε ένα FIS πρέπει αυτοί να συνδυαστούν κατάλληλα προκειμένου να καταλήξουμε σε μια απόφαση. Η συγκέντρωση των κανόνων είναι μια διαδικασία κατά την οποία όλα τα ασαφή σύνολα που προκύπτουν ως εξόδοι των κανόνων συνδυάζονται ώστε να σχηματίσουν ένα μοναδικό ασαφές σύνολο. Η συγκέντρωση είναι η διαδικασία που

προηγείται μόνο του τελευταίου βήματος και δέχεται ως είσοδο τις αποκομμένες συναρτήσεις εξόδου των προηγούμενων σταδίων.

Η διαδικασία της συγκέντρωσης των εξόδων είναι αντιμεταθετική και έτσι η σειρά με την οποία εκτελούνται οι κανόνες δεν έχει σημασία. Οι πιο γνωστές συναρτήσεις που χρησιμοποιούνται για την συγκέντρωση των εξόδων είναι :

- Max (maximum).
- probor (probabilistic OR).
- sum (άθροισμα της κάθε εξόδου)

Στο παρακάτω διάγραμμα βλέπουμε τους τρεις κανόνες του προβλήματος και τον τρόπο που συνδυάζονται τα αποτελέσματά τους σε ένα ασαφές σύνολο:



μ 3.11 Συγκέντρωση των αποτελεσμάτων κάθε εξόδου.

### 5<sup>0</sup> : Αποσαφήνιση

Η είσοδος για τη διαδικασία της αποσαφήνισης είναι το ασαφές σύνολο που προέκυψε από το προηγούμενο βήμα ενώ η έξοδος της αποσαφήνισης είναι ένας μόνο αριθμός. Η αποσαφήνιση είναι αναγκαία γιατί επιθυμούμε να έχο υμε ως αποτέλεσμα

έναν αριθμό που θα μας επιτρέψει να πάρουμε συγκεκριμένες αποφάσεις και είναι τόσο χρήσιμη όσο η ασαφοποίηση που είδαμε στα ενδιάμεσα σταδία.


Υπάρχουν πολλοί τρόποι για να γίνει η αποσαφήνιση. Ένας ιδιαίτερα δημοφιλής είναι ο υπολογισμός του κέντρου βάρους της περιοχής που περικλείεται από την καμπύλη της συνάρτησης συμμετοχής του ασαφούς συνόλου. Άλλες επίσης δημοφιλείς μέθοδοι είναι η μέση τιμή, η μέγιστη ή η μέγιστη θέση του μεγίστου και η ελάχιστη θέση του μεγίστου. Αναφερόμαστε αναλυτικά στην πρώτη μέθοδο :

- *Centroid*

Σύμφωνα με αυτή τη μέθοδο αποσαφήνισης, η μοναδική τιμή είναι αυτή που προκύπτει από το κέντρο βάρους της τελικής συνάρτησης συμμετοχής για την ασαφή παράμετρο εξόδου. Το κέντρο βάρους μιας επιφάνειας που ορίζεται από μια συνάρτηση  $f(t)$  και τους καρτεσιανούς άξονες, βρίσκεται στη θέση  $t$  που ορίζεται από τη σχέση:

$$t_{κβ} = \frac{\int t * f(t) dt}{\int f(t) dt} \quad (3.15)$$

Στο παρακάτω σχήμα βλέπουμε πως εφαρμόζεται η μέθοδος της αποσαφήνισης για το παράδειγμά μας:



### μ 3.12 Αποσαφήνιση .

Στην περίπτωση διακριτού συνόλου αναφοράς, τα ολοκληρώματα στην παραπάνω σχέση αντικαθίστανται με διακριτό άθροισμα και γίνεται δειγματοληψία  $N$  σημείων στο σύνολο αναφοράς.

### 3.2.7. . μ Sugeno

Παραπάνω ασχοληθήκαμε με τα συστήματα Mamdani που είναι και τα πιο ευρέως χρησιμοποιούμενα. Ωστόσο υπάρχει και η μέθοδος Sugeno που εισήχθη το 1985 η μέθοδος αυτή έχει ομοιότητες με τη μέθοδο των συστημάτων Mamdani. Για παράδειγμα τα 2 πρώτα βήματά της (ασαφοποίηση των εισόδων και εφαρμογή των τελεστών) είναι ακριβώς τα ίδια. Η κύρια διαφορά ανάμεσα στα δύο συστήματα έγκειται στο ότι από τις συναρτήσεις συμμετοχής η έξοδος των συστημάτων Sugeno είναι μόνο γραμμική ή σταθερά.

Ένας τυπικός ασαφής κανόνας σε συστήματα sugeno έχει την μορφή :


**If Input 1 = x and Input 2 = y, then Output is z = ax + by + c .**

Για ένα μηδενικού τύπου σύστημα sugeno ισχύει ότι η τιμή εξόδου είναι μια σταθερά δηλαδή a=b=0.

Η τιμή της εξόδου  $z_i$  κάθε κανόνα σταθμίζεται από τα βάρη  $w_i$  του κάθε κανόνα. Η τελική παραγωγή του συστήματος είναι ο σταθμισμένος μέσος όρος όλων των αποτελεσμάτων κάθε κανόνα, που υπολογίζεται όπως :

$$final \ output = \frac{\sum_{i=1}^N w_i z_i}{\sum_{i=1}^N w_i} \quad (3.16)$$

όπου το N είναι ο αριθμός των κανόνων. Στο παρακάτω σχήμα απεικονίζεται το παράδειγμα μας με την μέθοδο Sugeno.



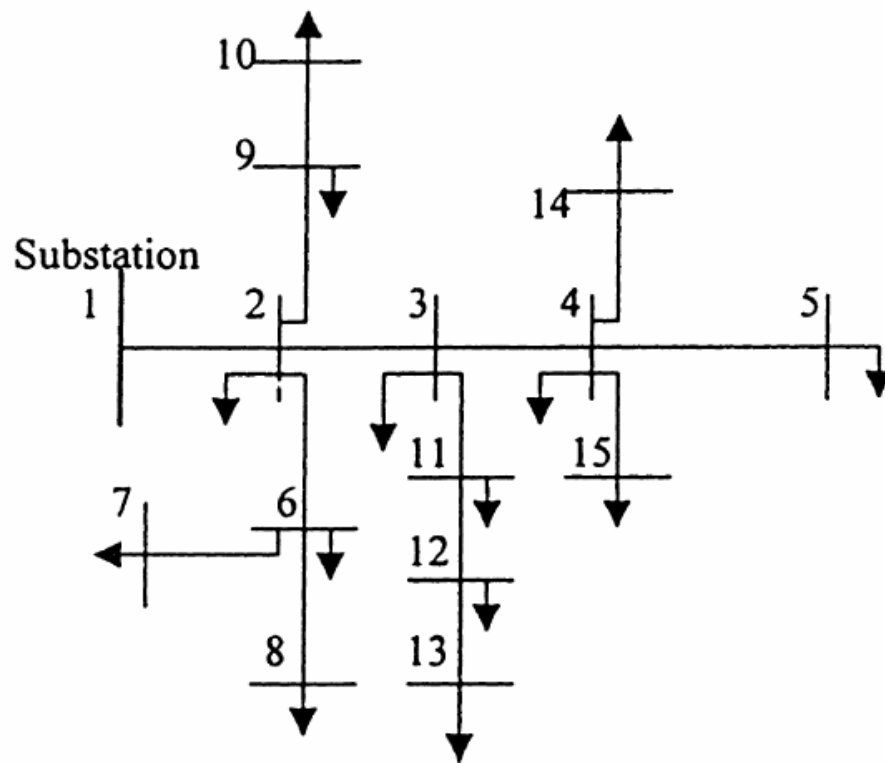
μ 3.13 Σύστημα Sugeno.

### 3.3

Επειδή έχουμε ένα πολυσύνθετο πρόβλημα με πολλές παραμέτρους παρουσιάζονται όλα τα δεδομένα και οι μεταβλητές πριν προχωρήσουμε στην βήμα προς βήμα επίλυση του προβλήματος .

Η ανάλυση του προβλήματος της τοποθέτησης πυκνωτών σε ένα δίκτυο γίνεται στο IEEE-15 Bus system .Πρόκειται για ένα δίκτυο 15 ζυγών όπου εκτελούνται οι αλγόριθμοι βελτιστοποίησης .

Στο διάγραμμα παρουσιάζεται το δίκτυο των 15 ζυγών. Πρόκειται για ένα διανεμημένο δίκτυο με ένα ζυγό παραγωγής και 14 ζυγούς καταναλώσεως :



μ 3.14 Δίκτυο IEEE 15 ζυγών

Στον πίνακα που ακολουθεί παρουσιάζονται τα στοιχεία των γραμμών του δικτύου, δηλαδή το πραγματικό και φανταστικό μέρος των αντιστάσεων.

| from | to | R ( p . u. ) | X ( p . u. ) | B ( p . u. ) |
|------|----|--------------|--------------|--------------|
| 1    | 1  | 1,1182       | 10,937       | 0            |
| 2    | 3  | 0,9671       | 0,9459       | 0            |
| 3    | 4  | 0,6951       | 0,6799       | 0            |
| 4    | 5  | 1,2591       | 0,8492       | 0            |
| 2    | 9  | 1,6637       | 1,1222       | 0            |
| 9    | 10 | 1,3939       | 0,9402       | 0            |
| 2    | 6  | 2,1134       | 1,4255       | 0            |
| 6    | 7  | 0,7289       | 0,6066       | 0            |
| 6    | 8  | 1,0342       | 0,6976       | 0            |
| 3    | 11 | 1,4839       | 1,0001       | 0            |
| 11   | 12 | 2,0235       | 1,3648       | 0            |
| 12   | 13 | 1,6637       | 1,1222       | 0            |
| 4    | 14 | 1,84364      | 1,2435       | 0            |
| 4    | 15 | 0,98927      | 0,6672       | 0            |

### 3.1 Στοιχεία γραμμών IEEE-15

Τα φορτία αναπαριστώνται ως εγχύσεις ισχύος όπου οι ποσότητες P και Q θεωρούνται σταθερές σε κάθε εκτέλεση. Οι ποσότητες P και Q σε κάθε ζυγό είναι:

| bus | No. | Pd(MW) | Qd(Mvar) |
|-----|-----|--------|----------|
| 1   | 1   | 0      | 0        |
| 2   | 0   | 0,0441 | 0,045    |
| 3   | 0   | 0,07   | 0,0714   |
| 4   | 0   | 0,14   | 0,1428   |
| 5   | 0   | 0,0441 | 0,045    |
| 6   | 0   | 0,14   | 0,1428   |
| 7   | 0   | 0,14   | 0,1428   |
| 8   | 0   | 0,007  | 0,0714   |
| 9   | 0   | 0,007  | 0,0714   |
| 10  | 0   | 0,0441 | 0,045    |
| 11  | 0   | 0,14   | 0,1428   |
| 12  | 0   | 0,07   | 0,0714   |
| 13  | 0   | 0,0441 | 0,045    |
| 14  | 0   | 0,07   | 0,0714   |
| 15  | 0   | 0,14   | 0,1428   |

### 3.2 Στοιχεία ζυγών IEEE-15

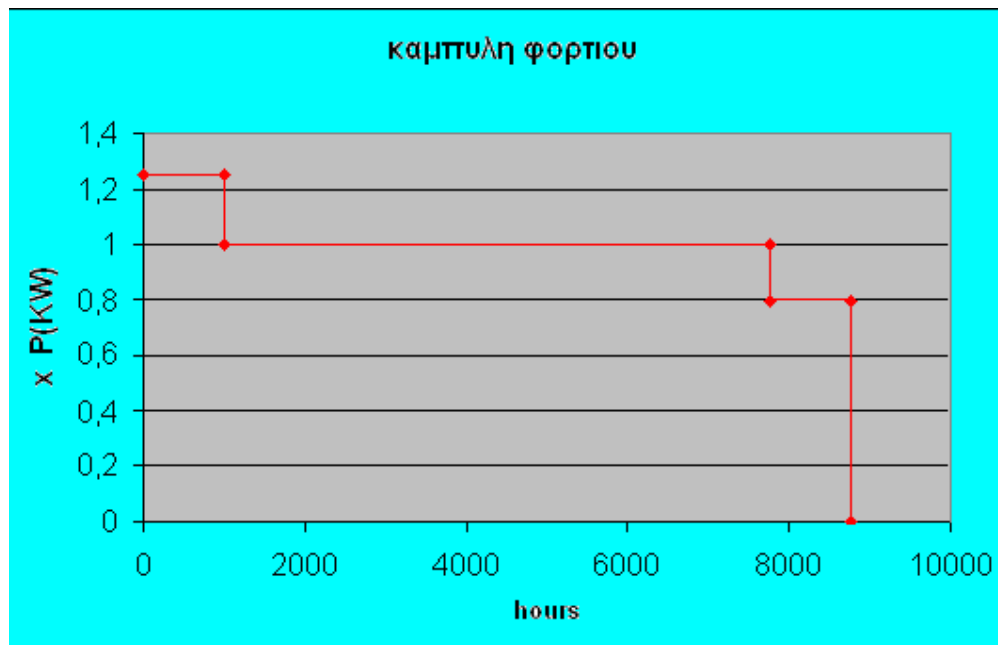
Η στήλη No υποδηλώνει το είδος του ζυγού . Έτσι ο ζυγός 1 είναι slack bus ζυγός (ζυγός αναφοράς ) ενώ οι ζυγοί 2-15 είναι ζυγοί φορτίου.

Επειδή μελετάμε την εξοικονόμηση απωλειών σε διάστημα ενός χρόνου δεν μπορούμε να υποθέσουμε ότι η ζήτηση είναι σταθερή ανά πάσα χρονική στιγμή. Με βάση πειραματικές μετρήσεις που έχουν γίνει σχετικά με τη ζήτηση ανά πάσα στιγμή τη διαχωρίζουμε σε υψηλή μέση και χαμηλή ζήτηση ,περίοδοι οι οποίες διαρκούν τα αντίστοιχα χρονικά διαστήματα :

|                  | peak | medium | light |
|------------------|------|--------|-------|
| S                | 1,25 | 1      | 0,8   |
| duration (hours) | 1000 | 6760   | 1000  |

### 3.3 Στοιχεία ζήτησης φορτίου.

Η καμπύλη φορτίου παίρνει την μορφή :



μ 3.15 Ετήσια καμπύλη φορτίου.

Οι ποσότητες του πυκνωτή που μπορούν να τοποθετηθούν σε κάθε ζυγό επιλέγονται πολλαπλάσια των 100 KVar. Τα 100 KVar θεωρούνται η μικρότερη δομή μονάδα στο δίκτυο μελέτης .

Για την ολοκλήρωση της προσέγγισης πρέπει να ορίσουμε την συνάρτηση της εξοικονόμησης χρημάτων παρουσία πυκνωτών. Η αντικειμενική συνάρτηση εξόδων είναι:

$$\text{Min. } S = KE + KC$$

Όπου  $S$  : είναι το κόστος χρημάτων (\$)  
 $KE$ : Το κόστος εξαιτίας των απωλειών ενέργειας (KWh).  
 $KC$ : Τα κόστη από την εγκατάσταση πυκνωτών (\$).

Πιο αναλυτικά ισχύει:

$$KE = \Delta KE \times r$$

όπου  $\Delta KE$ : Η ποσότητα της ενέργειας που καταναλώνεται στις γραμμές σε κάθε ροή φορτίου.  
 $r$  : χρέωση της ενέργειας (ληφθείσα \$0,06/ KWh).

Τέλος

$$KC = Q_c \times ICKC \times IKC$$

με  $Q_c$ : Τα συνολικά εγκατεστημένα KVar.  
 $ICKC$ : Κόστος του πυκνωτή (ίσο με \$4/K Var).  
 $IKC$ : Ετήσια χρέωση του κόστους του πυκνωτή (ίση με 0,2).

Η ετήσια χρέωση του κόστους του πυκνωτή δηλώνει ότι το κόστος του πυκνωτή επιμερίζεται στα χρόνια λειτουργίας του και δεν θεωρείται πάγιο έξοδο όποτε να προσμετράτε στον πρώτο χρόνο. Για την θεώρηση του προβλήματος λαμβάνεται σαν χρόνος λειτουργίας τα 5 έτη.



### 3.4

Αρχικά μελετάμε το πρόβλημα της εύρεσης της τοποθεσίας των πυκνωτών με την ντετερμινιστική μέθοδο της ανάλυσης ευαισθησίας . Η ανάλυση ευαισθησίας είναι μια συστηματική διαδικασία για να επιλέξουμε τις θέσεις στο δίκτυο που έχουν την μεγαλύτερη επίδραση στην πραγματική τιμή των απωλειών ενέργειας σε συνδυασμό με την έγχυση της άεργου ισχύος .Οι τοποθεσίες με την μεγαλύτερη ευαισθησία επιλέγονται ως υποψήφιοι ζυγοί για την τοποθέτηση πυκνωτών σε ένα διανεμημένο δίκτυο. Ο στόχος της ανάλυσης ευαισθησίας είναι να μας βοηθήσει να μειώσουμε τον χρόνο της διαδικασίας τοποθέτησης των πυκνωτών αφού μας δείχνει την θέση της τοποθεσίας πυκνωτών.

Θεωρούμε την ανάλυση της ευαισθησίας το πρώτο βήμα της διαδικασίας για την τοποθέτηση του πυκνωτή. Η τελική απόφαση όμως λαμβάνεται σε συνδυασμό με διάφορους πρακτικούς κανόνες και ευριστικές τεχνικές αφού η τοποθέτηση στον ζυγό δεν είναι πάντα δυνατή για τεχνικούς λόγους.

Οι απώλειες ισχύος είναι :

$$P_L + jQ_L = VI^* = VY^*Y \quad (3.17)$$

$$P_L = \sum_{i=1}^N \sum_{j=1}^N V_i V_j Y_{ij} \cos(\theta_i - \theta_j - \delta_{ij})$$

Η ευαισθησία των πραγματικών απωλειών ισχύος του συστήματος ως προς τις εγχεόμενες άεργες ισχύς δίνεται από τον τύπο :

$$\frac{\partial P_L}{\partial Q} = \left(\frac{\partial P_L}{\partial V}\right) \left(\frac{\partial V}{\partial Q}\right) \quad (3.18)$$

με:

$$\frac{\partial P_L}{\partial V_i} = 2 \sum_{j=1}^N V_j Y_{ij} \cos \delta_{ij} \cos(\theta_i - \theta_j) \quad (3.19)$$

$$\frac{\partial P_L}{\partial \theta_i} = -2V_i \sum_{j=1}^N V_j Y_{ij} \cos \delta_{ij} \sin(\theta_i - \theta_j) \quad (3.20)$$

Για να υπολογίσουμε την ευαισθησία των ζυγών ,όπως απαιτείται για την κατανομή των πυκνωτών ,λύνουμε ως προς  $\frac{\partial P_L}{\partial Q}$  την ακόλουθη σχέση:

$$\begin{bmatrix} \frac{\partial P_L}{\partial \theta} \\ \frac{\partial P_L}{\partial V} \end{bmatrix} = \begin{bmatrix} \frac{\partial P}{\partial \theta} & \frac{\partial Q}{\partial \theta} \\ \frac{\partial P}{\partial V} & \frac{\partial Q}{\partial V} \end{bmatrix} \begin{bmatrix} \frac{\partial P_L}{\partial P} \\ \frac{\partial P_L}{\partial Q} \end{bmatrix}$$

όπου  $\frac{\partial P_L}{\partial Q}$  είναι ένα (nx1) διάνυσμα στήλης ,n ο αριθμός των ζυγών. Ο παράγοντας ευαισθησίας ενός ζυγού καθορίζεται από το αντίστοιχο στοιχείο του διανύσματος αυτού. Ο μεσαίος πίνακας είναι ο Ιακωβιανός (Jacobian) που προκύπτει με τις πράξεις από την μέθοδο Newton-Raphson. Μετά την επίλυση ως προς το διάνυσμα ευαισθησίας οι ζυγοί κατανέμονται από αυτόν με την μεγαλύτερη τιμή ή σε αυτόν με τη μικρότερη. Όσο μεγαλύτερη είναι η τιμή τόσο περισσότερες πιθανότητες έχει να επιλεγεί.

Σε συνδυασμό με τον παράγοντα ευαισθησίας ενός ζυγού, το μέγεθος του φορτίου που είναι συνδεδεμένο σε αυτόν επηρεάζει την διαδικασία επιλογής ενός ζυγού ως υποψήφιο για την τοποθέτηση πυκνωτή . Οι ζυγοί με μεγαλύτερα φορτία έχουν περισσότερες πιθανότητες να επιλεγούν. Ακόμη και το μέγεθος της τάσης στους ζυγούς επηρεάζει την τοποθέτηση .Όσο πιο μικρό είναι το μέγεθος αυτό τόσο πιο ικανή είναι η εγκατάσταση συσκευής . Όποτε ο τύπος για την επιλογή της καταλληλότητας είναι:

$$BS_i = SS_i * \frac{Q_{L_i}}{V_i} \quad (3.21)$$

Επίσης πρέπει να επισημανθεί ότι από τεχνικής σκοπιάς επιλέγεται η υποψήφια ομάδα πυκνωτών να είναι διασκορπισμένη στο δίκτυο και όχι συγκεντρωμένη σε μια περιοχή.

### 3.4.1 Case study

Στην περίπτωση του συστήματος 15 ζυγών εφαρμόζουμε την ανάλυση ευαισθησίας. Εκτελούμε μια ροή φορτίου ώστε να υπολογίσουμε τα μέτρα και τις γωνίες τάσης σε όλους τους ζυγούς . Υπολογίζουμε κατόπιν την εκτεταμένη Ιακωβιανή που είναι ένας πίνακας 30x30 και στη συνέχεια των πίνακα των απωλειών  $[\frac{\partial P_L}{\partial \theta_i} ; \frac{\partial P_L}{\partial V_i}]$  . Οποτε έχουμε με αντίστροφη του Ιακωβιανου και πολλαπλασιασμό με τον πίνακα απωλειών το  $SS_i$  και το  $BS_i$  , όπου  $Q_{L_i}$  από τα δεδομένα του συστήματος και  $V_i$  όπως προκύπτει από τη ροή ισχύος .

|    | SS(i)  | BS(i)  |
|----|--------|--------|
| 1  | 0.8613 | 0      |
| 2  | 0.8748 | 0.0405 |
| 3  | 0.8766 | 0.0654 |
| 4  | 0.8778 | 0.1318 |
| 5  | 0.8675 | 0.0411 |
| 6  | 0.8712 | 0.1298 |
| 7  | 0.8645 | 0.1291 |
| 8  | 0.8651 | 0.0645 |
| 9  | 0.8779 | 0.0648 |
| 10 | 0.8677 | 0.0404 |
| 11 | 0.8757 | 0.1316 |
| 12 | 0.8638 | 0.0652 |
| 13 | 0.8610 | 0.0410 |
| 14 | 0.8664 | 0.0652 |
| 15 | 0.8551 | 0.1287 |

### 3.4 Αποτελέσματα ανάλυσης ευαισθησίας .

Από τις τιμές του παραπάνω πίνακα 5 ζυγοί επιλέγονται για τη ν τοποθέτηση των πυκνωτών στο δίκτυο. Αυτοί είναι οι:

**4-6-7-11-15**

## 3.5 FUZZY

### 3.5.1

Μετά την εισαγωγική παρουσίαση της fuzzy λογικής αναφερόμαστε στην ευρύτερη εφαρμογή που έχει στη επιλογή της τοποθεσίας όπου θα εγκαταστήσουμε ένα πυκνωτή ώστε να μειωθούν οι πραγματικές απώλειες ισχύος . Είναι μια διαφορετική μεθοδολογία από την ανάλυση ευαισθησίας η οποία προτιμάται γιατί δεν χρειάζεται να υπολογίσουμε έτσι την Ιακωβιανή και τους πίν ακες των απωλειών ως προς την άεργο ισχύ που είναι αναγκαίες αλλά συνάμα απαιτούν πολύ υπολογιστικό κόπο και χρόνο.

Αρχικά σε ένα fuzzy σύστημα πρέπει να επιλέξουμε τα δεδομένα εισόδου δηλαδή τα δεδομένα εκείνα των οποίων οι συναρτήσεις συμμετοχής θα καθορίσουν το πρόβλημα. Είναι γνωστό ότι η τοποθέτηση πυκνωτών προτιμάται σε ζυγούς όπου έχουν μεγάλες απώλειες ισχύος και μικρή τάση. Όποτε στη διαμόρφωση του fuzzy επιλέγουμε αυτές τις δυο μεταβλητές . Σε μια παραλλαγή της μεθόδου αντί των απωλειών ισχύος επιλέγεται σαν μεταβλητή εισόδου η οικονομικότερη λειτουργία του κάθε ζυγού.

Πρέπει να βρούμε πως θα υπολογιστούν οι τιμές των μεταβλητών που επιλέξαμε. Σε πρώτη φάση, η λύση της ροής φορτίων για το αρχικό σύστημα απαιτείται για να λάβουμε τις πραγματικές και άεργες απώλειες ισχύος. Πάλι, οι λύσεις ροής φορτίων απαιτούνται για να ληφθούν οι μειώσεις απώλειας ισχύος με την αντιστάθμιση του συνολικού φορτίου σε κάθε κόμβο του συστήματος διανομής. Οι ροές φορτίων εκτελούνται με την μέθοδο Newton Raphson. Οι μειώσεις των απωλειών έπειτα, γραμμικά ομαλοποιούνται στο διάστημα [0, 1] όπου η μεγαλύτερη μείωση απώλειας έχει μια αξία 1 και η μικρότερη έχει μια αξία 0. Η αξία των δεικτών που λαμβάνονται μετά την γραμμικοποίηση των δεδομένων δίνονται από τον τύπο:

$$PLI(n) = \frac{loss\_reduction(n) - loss\_reduction(min)}{loss\_reduction(max) - loss\_reduction(min)} \quad (3.22)$$

Τα δεδομένα της δεύτερης εισόδου ,δηλαδή το μέτρο της τάσης ανά μονάδα (p.u.) , λαμβάνονται από την εκτέλεση της ροής ισχύος χωρίς καμία επιπλέον έγχυση άεργου στο δίκτυο(αρχική κατάσταση) και γραμμικοποιοντας τα μεγέθη στο διάστημα [0.9 , 1.1].

Ομοίως πρέπει να ορίσουμε και την συνάρτηση εξόδου που επιλέγουμε να είναι ο συντελεστής καταλληλότητας πυκνωτή CSI (capacitor suitability index) και η εκτίμηση των τιμών γίνεται εμπειρικά.

### 3.5.2

### Fuzzy $\mu$


Μετά την επιλογή των εισόδων προχωράμε στη κατασκευή του fuzzy συστήματος με βάση τα βήματα που αναπτύχθηκαν στην θεωρητική μελέτη που παρουσιάστηκε. Αρχικά από τις δυο κατηγορίες συστημάτων επιλέγουμε τύπου Mamdani. Κατόπιν επιλέγουμε ποιες λογικές πράξεις (max,min) διέπουν κάθε βήμα του συστήματος .

Έτσι κατά την εκτέλεση των λογικών πράξεων που υπάρχουν στους κανόνες λειτουργίας του fuzzy έχουμε:

- Για την **and method** επιλέγουμε την πράξη **min**.
- Για την **or method** επιλέγουμε την πράξη **max**.

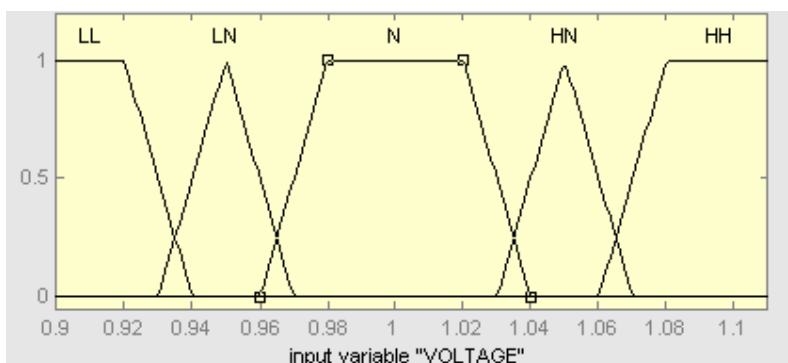
Για το τρίτο βήμα του αλγόριθμου (implication) επιλέγουμε την λογική πράξη min. Στο τέταρτο βήμα (aggregation) που είναι οι σύνθεση των αποτελεσμάτων της εξόδου επιλέγουμε την max τιμή. Στο τελευταίο βήμα που είναι η αποσαφηνοποίηση χρησιμοποιούμε την centroid μέθοδο που παρουσιάσαμε παραπάνω ώστε να πάρουμε τα τελικά αποτελέσματα στην έξοδο.

Αφού ορίσαμε τις λογικές πράξεις σε κάθε βήμα της fuzzy λογικής(που αποτελούν και τη δομή του συστήματος ) πρέπει να ορίσουμε σε πρώτο στάδιο τις συναρτήσεις συμμετοχής των στοιχείων εισόδου και εξόδου. Χωρίσουμε σε 5 κατηγορίες τις τιμές των στοιχείων εισόδου-εξόδου. Οι κατηγορίες αυτές είναι: low, medium low, medium, medium high, high. Μετά το διαχωρισμό αυτό ορίζουμε τις συναρτήσεις συμμετοχής . Για την είσοδο PLI έχουμε την συνάρτηση του σχήματος :



**$\mu$  3.16** Είσοδος PLI.

Αντίστοιχα για την μεταβλητή volts έχουμε την membership function:




**μ 3.17** Είσοδος VOLTAGE.

Ο διαχωρισμός των τιμών των μεταβλητών εισόδου όπως φαίνεται και στα πάνω σχήματα των συναρτήσεων είναι:

| Description of the variables | Low    | Low - Medium | Medium    | High - Medium | High     |
|------------------------------|--------|--------------|-----------|---------------|----------|
| Power loss indices           | < 0.25 | 0-0.5        | 0.25-0.75 | 0.5-1         | > 0.75   |
| Voltage                      | < 0.94 | 0.92-0.98    | 0.96-1.04 | 1.02-1.08     | 1.06-1.1 |

**3.5** Όρια εισόδων ασαφούς συστήματος .

Η αντίστοιχη διαδικασία ακολουθείται για την μεταβλητή εξόδου CSI .Η συνάρτηση συμμετοχής είναι:



**μ 3.18** Έξοδος CSI.

και ο αντίστοιχος πίνακας τιμών :

| Description of the variables | Low    | Low - Medium | Medium    | High - Medium | High   |
|------------------------------|--------|--------------|-----------|---------------|--------|
| CSI                          | < 0.25 | 0-0.5        | 0.25-0.75 | 0.5-1         | ≥ 0.75 |

**3.6** Όρια εξόδου ασαφούς συστήματος .

Για την ολοκλήρωση του ορίσματος του fuzzy system απαιτείται η περιγραφή των κανόνων που συνδέουν τις εισόδους με τις εξόδους στη μορφή που ορίστηκαν στην θεωρητική ανάλυση. Απαιτούνται συνολικά 25 κανόνες οι οποίοι έχουν προέλθει μετά από πειραματική διαδικασία και οι οποίοι συνοψίζονται στον παρακάτω πίνακα:

| AND         |    | Voltage |    |    |    |    |
|-------------|----|---------|----|----|----|----|
|             |    | LL      | LN | NN | HN | HH |
| P<br>L<br>I | L  | LM      | LM | L  | L  | L  |
|             | LM | M       | LM | LM | L  | L  |
|             | M  | HM      | M  | LM | L  | L  |
|             | HM | HM      | HM | M  | LM | L  |
|             | H  | H       | HM | M  | LM | LM |

3.7 Κανόνες ασαφούς συστήματος .

Η μορφή των κανόνων αυτών είναι για παράδειγμα:

- If **PLI** is **H** and **Voltage** is **L** then **CSI** is **H**.
- If **PLI** is **M** and **Voltage** is **NN** then **CSI** is **LM**.

Πλέον μετά τον ορισμό των κανόνων έχουμε κατασκευάσει το fuzzy system και απαιτείται μόνο η αποσαφήνιση των στοιχείων εξόδου ώστε να έχουμε το επιθυμητό αποτέλεσμα. Στην μελέτη των απωλειών μετά τον υπολογισμό των CSI για κάθε ζυγό τα τοποθετούμε σε αύξουσα σειρά και όσο πιο μεγάλη είναι η τιμή του τελεστή τόσο η θέση του ζυγού είναι καλύτερη για την εγκατάσταση του πυκνωτή.

### 3.5.3 Case Study

Στο σύστημα των 15 ζυγών που μελετάμε σαν εφαρμογή εκτελούμε αρχικά την ροή φορτίου Newton Raphson και λαμβάνουμε τις τιμές της μεταβλητής Voltage για κάθε ζυγό:

|         |   |       |       |       |      |       |       |
|---------|---|-------|-------|-------|------|-------|-------|
|         | 1 | 2     | 3     | 4     | 5    | 6     | 7     |
| Voltage | 1 | 0,971 | 0,957 | 0,951 | 0,95 | 0,958 | 0,956 |

|       |       |       |      |       |       |       |       |
|-------|-------|-------|------|-------|-------|-------|-------|
| 8     | 9     | 10    | 11   | 12    | 13    | 14    | 15    |
| 0,957 | 0,968 | 0,967 | 0,95 | 0,946 | 0,945 | 0,949 | 0,948 |

3.8. Είσοδοι ασαφούς συστήματος εφαρμογής.

Επίσης υπολογίζουμε και τις αρχικές τιμές απωλειών σε όλο το σύστημα που είναι

$$P_{\text{loss}} = 61.6885 \text{ KW.}$$

Κατόπιν τοποθετούμε σε κάθε θέση του ζυγού , έγχυση αεργου ισχύος 500 KW και υπολογίζουμε διαδοχικά για κάθε μια από τις 15 περιπτώσεις την μείωση των πραγματικών απωλειών στο δίκτυο ώστε κατόπιν με βάση τον τύπο που αναφέρθηκε παραπάνω να υπολογιστεί το PLI. Οι τιμές για την δεύτερη είσοδο του fuzzy (PLI) είναι:

|     |   |        |        |   |        |       |       |
|-----|---|--------|--------|---|--------|-------|-------|
|     | 1 | 2      | 3      | 4 | 5      | 6     | 7     |
| PLI | 0 | 0,6547 | 0,9361 | 1 | 0,8488 | 0,788 | 0,744 |

|       |        |        |        |       |        |        |        |
|-------|--------|--------|--------|-------|--------|--------|--------|
| 8     | 9      | 10     | 11     | 12    | 13     | 14     | 15     |
| 0,683 | 0,5305 | 0,3724 | 0,9462 | 0,788 | 0,5922 | 0,8076 | 0,9378 |

### 3.8. Είσοδοι ασαφούς συστήματος εφαρμογής.

Μετά τον υπολογισμό των στοιχείων εισόδου-εξόδου εκτελούμε το fuzzy σύστημα που αναπτύχθηκε με βάση το fuzzy toolbox του Matlab . Οι συναρτήσεις συμμετοχής και οι κανόνες είναι αυτοί που χρησιμοποιήθηκαν παραπάνω. Από την εκτέλεση του κώδικα παίρνουμε τις τιμές για το CSI:

|     |      |       |      |      |      |      |      |
|-----|------|-------|------|------|------|------|------|
|     | 1    | 2     | 3    | 4    | 5    | 6    | 7    |
| CSI | 0,08 | 0,394 | 0,75 | 0,75 | 0,75 | 0,75 | 0,75 |

|      |       |       |      |      |       |      |      |
|------|-------|-------|------|------|-------|------|------|
| 8    | 9     | 10    | 11   | 12   | 13    | 14   | 15   |
| 0,67 | 0,372 | 0,323 | 0,75 | 0,75 | 0,598 | 0,75 | 0,75 |

### 3.9 Έξοδοι ασαφούς συστήματος εφαρμογής.

Από τις τιμές του συντελεστή καταλληλότητας βλέπουμε ότι οι καλύτεροι ζυγοί για τοποθέτηση πυκνωτών είναι οι 3,4,5,6,7,11,12,14,15. Όμως πρέπει να μην έχουμε συγκεντρωμένους πυκνωτές στο δίκτυο αλλά να είναι διασκορπισμένοι. Η ομαδοποίηση των ζυγών είναι: (3,4,5) (6,7) (11,12) (14,15) και γίνεται με βάση τον κοινό κλάδο στον οποίον ανήκουν. Η επιλογή του πυκνωτή από κάθε ομάδα γίνεται με το μέγεθος της άεργου ισχύος σε κάθε ζυγό όπως είδαμε και στην ανάλυση ευαισθησίας. Έτσι επιλέγουμε τους ζυγούς

### 4-6-7-11-15

για την τοποθέτηση πυκνωτών.



Παρατηρούμε ότι τα αποτελέσματα συμπίπτουν με αυτά που υπολογίστηκαν από την ανάλυση ευαισθησίας . Όποτε φαίνεται η ικανότητα της fuzzy μεθόδου στο δεδομένο πρόβλημα της τοποθεσίας πυκνωτών αποφεύγοντας τις δύσκολες υπολογιστικές διαδικασίες της πρώτης μεθόδου. Η fuzzy λογική είναι μια μέθοδος τεχνητής νοημοσύνης που στην εποχή μας έχει πολλές εφαρμογές στην επίλυση προβλημάτων βελτιστοποίησης και μια από τις χρήσεις τις στην επίλυση ενεργειακών προβλημάτων παρουσιάστηκε εδώ.

Μετά την επιλογή της θέσης των πυκνωτών σειρά παίρνει η μελέτη του μεγέθους αυτών. Εισάγονται δυο μέθοδοι της τεχνητής νοημοσύνης : οι γενετικοί αλγόριθμοι και η particle swarm optimization. Ταυτόχρονα με την περιγραφή του αλγόριθμου γίνεται και μια σύντομη παρουσίαση αυτών ξεκινώντας με το υς γενετικούς αλγόριθμους .

### 3.6

Σε αυτό το κομμάτι εισάγονται οι γενετικοί αλγόριθμοι ( genetic algorithm) σαν μια ευρεστική μέθοδο βελτιστοποίησης . Περιγράφεται η μορφή του αλγόριθμου , τα χαρακτηριστικά του και τα βήματα για την σωστή διαμόρφωση του. Ακόμη αναφερόμαστε στην εφαρμογή του αλγόριθμου αυτού στο άμεσο πρόβλημα που μελετάμε, την κατανομή πυκνωτών σε ένα διανεμημένο δίκτυο.

#### 3.6.1

Οι γενετικοί αλγόριθμοι αρχικά αναπτύχθηκαν από τον Holland και τους συνεργάτες του το 1960-1970. Από τα πρώτα στάδια ανατήξεις των, έχουν χρησιμοποιηθεί αποτελεσματικά σε πολλά προβλήματα συμπεριλαμβανόμενου σύνθετα προβλήματα βελτιστοποίησης . Το όνομα γενετικοί αλγόριθμοι παρέρχεται από την αναλογία με την αναπαράσταση μιας σύνθετης δομής με ένα διάνυσμα από στοιχεία του γενετικού κώδικα που είναι τα χρωμοσώματα. Στην εξελικτική αναπαραγωγή των φυτών και των ζώων για παράδειγμα , οι απόγονοι έχουν ορισμένα ξεχωριστά χαρακτηριστικά. Τα χαρακτηριστικά αυτά των απόγονων κα θορίζονται σε γενετικό επίπεδο από τον τρόπο που τα χρωμοσώματα των προγονών συνδυάζονται. Με παρόμοιο τρόπο , συχνά συνδυάζουμε τμήματα από ήδη υπάρχουσες λύσεις για να αναζητήσουμε καλύτερες λύσεις σε σύνθετα προβλήματα. Αν και η αντιστοιχία που αναφέρθηκε δεν ήταν ακριβής ,ήταν επαρκής για να περιγράψει την πρόταση του Holland για μεθοδολογία επίλυσης προβλημάτων.

Η κεντρική ιδέα των γενετικών αλγόριθμων μπορεί να περιγράψει σαν μια έξυπνη εκμετάλλευση τυχαίων ή πιθανοτικών ερευνών που είναι βασισμένοι σε μηχανισμούς φυσικής επιλογής και παραγωγής νέων γενεών. Η λογική της επιλεκτικής υιοθέτησης και επιβίωσης της βέλτιστης λύσης εφαρμόζεται στην ερευνά του διαστήματος παραμέτρων οστά να καθοριστεί αυτή .

Υπάρχουν τέσσερα βήματα στο σχεδιασμό του γενετικού αλγόριθμου . Αυτά ινία η αρχικοποίηση της εφαρμογής , η αποτίμηση της συνάρτησης βελτιστοποίησης , η επιλογή και η παραγωγή νέων γενεών.

Η αρχικοποίηση είναι μια διαδικασία τυχαίας παραγωγής εν ός συνόλου λύσεων μέσα στα όρια του προβλήματος , το σύνολο αυτό ονομάζεται ‘ αρχικός πληθυσμός ’. Το μέγεθος των στοιχείων του συνόλου αυτού αναφέρεται ως ‘ μέγεθος πληθυσμού ’. Κάθε επανάληψη του γενετικού αλγόριθμου , γνωστή ως ‘ generation ’ παράγει ένα σύνολο νέων εφικτών λύσεων.

Όπως ισχύει και σε όλες τις μεθόδους βελτιστοποίησης , οι γενετικοί αλγόριθμοι απαιτούν την ύπαρξη ενός μέτρου που θα καθορίζει πως μια λύση είναι καλύτερη από μια άλλη. Αυτό μπορεί να γίνει είτε με την άμεση αποτίμηση της αντικειμενικής συνάρτησης είτε με κάποιο άλλο έμμεσο τρόπο. Η αποτίμηση της συνάρτησης είναι το κριτήριο που οδηγεί την διαδικασία αναζήτησης καλύτερων λύσεων.

Στους γενετικού αλγόριθμους οι γονείς επιλέγονται ώστε να παράγουν απόγον ουσ. Η διαδικασία της επιλογής μπορεί να γίνει με διάφορους τρόπους .Ένας τρόπος είναι να επιλέγει ο ένας γονέας ως ο βέλτιστος ( με την καλύτερη τιμή στην συνάρτηση αποτίμησης ) και ο άλλος τυχαία. Ένας δεύτερος τρόπος είναι η τυχαία επιλογή και των δυο γονέων.

Οι διαδικασίες παραγωγής νέων γενεών είναι οι πιθανοτικοι κανόνες που χρησιμοποιούνται στον αλγόριθμο. Ένας νέος και βελτιωμένος πληθυσμός παράγεται από μια παλιά μορφή εφαρμόζοντας γενετικές διαδικασίες . Οι διαδικασίες αυτές που χρησιμοποιούνται είναι η αναπαραγωγή η διασταύρωση και η μετάλλαξη.

Η αναπαραγωγή αναφέρεται ως το τυχαίο ταίριασμα λύσεων του πληθυσμού για την παραγωγή ενός απόγονου. Οι κανόνες αναπαραγωγής εφαρμόζονται σε κάθε ξεχωριστό στοιχείο του πληθυσμού . Πολλές μέθοδοι χρησιμοποιούνται για να ολοκληρώσουν αυτή τη διαδικασία. Η αναλογική επιλογή είναι μια από αυτές τις μεθόδους όπου οι πιθανότητες να επιλέγουν κάποια συγκεκριμένα στοιχεία από τον πληθυσμό υπολογίζονται ανάλογα με την εκτίμηση της συνάρτησης .

Η διασταύρωση είναι η διαδικασία επιλογής μιας τυχαίας θέσης της λύσης και αντιμετάθεσης των χαρακτήρων ( swapping ) γύρω από αυτή τη θέση με αυτά κάποιας άλλης λύσης .Το τυχαίο αυτό σημείο αναφέρεται ως ‘σημείο διασταύρωσης’ . Με αλλά λόγια , η διασταύρωση καθορίζει την έξοδο μια ανταλλαγής γενεών. Είναι μια διαδικασία πανίσχυρη στους γενετικούς αλγόριθμους .

Η μετάλλαξη είναι η διαδικασία της τυχαίας διαμόρφωσης μιας τυχαίας τιμής μιας λύσης με μια μικρή πιθανότητα. Χρησιμοποιείται για να αλλάζει ο ριζμένα γονίδια στις λύσεις . Όταν η ανταλλαγή γονιδίων στην διαδικασία της διασταύρωσης δεν ικανοποιεί τους περιορισμούς , η μετάλλαξη μπορεί να είναι πολύ χρήσιμη στην προώθηση της λύσης . Είναι γενικά μια βοηθητική διαδικασία που παρέχει ένα μικρό ποσοστό στην τυχαία ερευνά .

Επιπλέον με όσα αναφέραμε , τα κριτήρια τερματισμού του γενετικού αλγόριθμου έχουν μεγάλη σημασία. Καθορίζουν ποτέ πρέπει να σταματήσει η διαδικασία και στο σημείο αυτό η καλύτερη λύση επιλέγεται ως η βέλτιστη λύση.

### **3.6.3            μ            μ            GA μ**

Στο σχεδιασμό της GA μεθόδου , διάφορες αποφάσεις που αφορούν τις παραμέτρους του αλγόριθμου πρέπει να παρθούν ώστε να επιτύχουμε υψηλής ποιότητας λύσεις . Πρόωρος τερματισμός σε ένα τοπικό ελάχιστο είναι εφικτός αν οι παράμετροι δεν επιλέγουν με κατάλληλο τρόπο.

Το μέγεθος του πληθυσμού και ο τρόπος που αυτός επιλέγεται έχουν σημαντική επίπτωση στα αποτελέσματα. Ο αρχικός πληθυσμός μπορεί να αναζητηθεί με ένα ευριστικό αλγόριθμο ή κατά τύχη. Σε κάθε περίπτωση ο αρχικός πληθυσμός πρέπει να περιέχει μεγάλη ποικιλία στο περιεχόμενο. Το σταθερό μέγεθος του πληθυσμού του αλγόριθμου θα πρέπει να εκτιμάται από τον σχεδιαστή. Αν ο πληθυσμός είναι πολύ μικρός , η περιοχή λύσεων δεν εξερευνάται επαρκώς και έτσι η αποτελεσματικότητα είναι μικρή. Με μεγάλο το μέγεθος του πληθυσμού αποφεύγουμε τον τερματισμό σε τοπικό ελάχιστο αλλά μειώνεται πολύ ο ρυθμός σύγκλισης .

Η απόδοση του γενετικού αλγόριθμου είναι πολύ ευαίσθητη στην τιμή εκτίμησης . Αυτή μπορεί να επιλέγει σαν την βελτιστοποίηση της αντικειμενικής συνάρτησης. Πολλοί επιστήμονες όμως πιστεύουν ότι η αντικειμενική συνάρτηση είναι ένα πολύ απλοϊκό μέτρο εκτίμησης τιμής. Όταν εφαρμόζεται η διαδικασία της διασταύρωσης , ο προερχόμενος απόγονος μπορεί να ανήκει μέσα στα όρια λύσεων μπορεί και όχι. Για την διαχείριση αυτής της περίπτωσης υπάρχουν δυο εναλλακτικές . Η πρώτη είναι η επανάληψη της διαδικασία μέχρι την εύρεση εφικτής λύσης. Η δεύτερη είναι η επιβολή μιας 'ποινής ' στην τιμή της αντικειμενικής συνάρτησης ώστε να μην επιλέγει αυτή η λύση σαν βέλτιστη. Σε αυτή την περίπτωση πρέπει να καθοριστεί από τον δημιουργό και το είδος της ποινής .

Όταν εφαρμόζεται η διαδικασία της διασταύρωσης πρέπει να γίνει επιλογή ανάμεσα σε απλή διασταύρωση η πολλαπλή διασταύρωση. Η διάφορα είναι ότι στην πολλαπλή διασταύρωση η διαδικασία αυτή γίνεται σε διαφορετικό κάθε φορά σημείο των γονιδίων. Συνήθως επιλέγεται αυτή η διαδικασία.

Οι ρυθμοί διασταύρωσης και μετάλλαξης παίζουν σημαντικό ρόλο στην απόδοση του γενετικού αλγόριθμου. Ένας υψηλότερος ρυθμός διασταύρωσης εισάγει νέες λύσεις πιο γρήγορα στον πληθυσμό. Αν ο ρυθμός αυτός είναι πολύ υψηλός τότε προσπερνώνται οι υψηλές απόδοσης τιμές. Αν όμως είναι χαμηλός τότε παρουσιάζεται μια στασιμότητα στην εξεύρεση λύσεων. Ο ρυθμός μετάλλαξης πρέπει να είναι μικρός οστά να μην εμποδίζει την διασταύρωση να λειτουργήσει σωστά. Πολλοί επιστήμονες θεωρούν ότι ένας μεταβλητός δείκτης μετάλλαξης είναι καλύτερος από ένα σταθερό. Σε αρχικό στάδιο του αλγόριθμου θα πρέπει να εφαρμόζεται υψηλός crossover ratio και χαμηλός mutation ratio ενώ όσο η διαδικασία προχωρά τα μεγέθη των δεικτών αντιστρέφονται.

Οι απλοί γενετικοί αλγόριθμοι που περιλαμβάνουν μόνο τις διαδικασίες διασταύρωσης και μετάλλαξης έχουν αποδειχτεί αρκετά ισχυροί. Μερικοί επιστήμονες έχουν εισάγει και άλλες διαδικασίες όπως την αντίστροφη όπου ένα μέρος της λύσης αποκόπτεται και εισάγεται αντίστροφα. Όμως δεν έχει επισημανθεί κάποια αξιοσημείωτη βελτίωση. Μπορεί να χρησιμοποιηθεί αντί τη διαδικασία της μετάλλαξης για την εξερεύνηση νέων πεδίων λύσεων.

Όπως επισημάνθηκε και νωρίτερα οι νέες λύσεις αντικαθιστούν τις παλιές. Υπάρχουν δυο διαφορετικές προσεγγίσεις στην αντικατάσταση. Αυτές είναι η αυξητική ή 'steady state' προσέγγιση και η γενετική προσέγγιση. Στην πρώτη, μόλις μια εφικτή λύση παραχθεί, θα αντικαταστήσει μια λύση με τιμή μεγαλύτερη από την μέση τιμή των τιμών του πληθυσμού. Τα μέλη του πληθυσμού με τιμή καλύτερη από τη μέση τιμή προωθούνται στο επόμενο στάδιο χωρίς αντικατάσταση. Στην γενετική αντικατάσταση ένας νέος πληθυσμός από απόγονους καλείται να αντικαταστήσει όλο το σύνολο των προγόνων. Η επαυξητική αντικατάσταση έχει τα εξής πλεονεκτήματα:

- Αν δεν εφαρμόζεται ο 'steady state' αλγόριθμος, δεν υπάρχει εγγύηση ότι η βέλτιστη λύση του υπάρχοντος πληθυσμού θα επιβιώσει στην επόμενη γενιά. Με την προσέγγιση αυτή οι βέλτιστες λύσεις διατηρούνται στον πληθυσμό και οι πρόσφατα παραγόμενες λύσεις είναι άμεσα διαθέσιμες για επιλογή και αναπαραγωγή.
- Είναι πιο αποδοτική, συγκρινόμενη με την γενετική μέθοδο. Γρηγορότερη σύγκλιση αναμένεται με αυτή τη μέθοδο.
- Εμποδίζει την ύπαρξη αντιγράφων. Η ύπαρξη όμοιων λύσεων δεν είναι χρήσιμη αφού σπαταλά χρόνο στον υπολογισμό της ίδιας τιμής και καθυστερεί την διαδικασία επιλογής δίνοντας επιπλέον ευκαιρίες σε όμοιες λύσεις να αναπαραχθούν.

Ο γενετικός αλγόριθμος μπορεί να σχεδιαστεί να σταματάει μόλις ένας προκαθορισμένος αριθμός επαναλήψεων ξεπεραστεί ή αν δεν παρατηρείται καμία βελτίωση στην βέλτιστη λύση για ένα συγκεκριμένο αριθμό επαναλήψεων. Το κριτήριο τερματισμού θα πρέπει να επιλέγεται κατάλληλα σε συνδυασμό με τις άλλες

παραμέτρους όπως είναι το μέγεθος του πληθυσμού, ο ρυθμός διασταύρωσης και ο ρυθμός μετάλλαξης ώστε να κατέχουμε καλύτερη ποιότητας λύσεις.

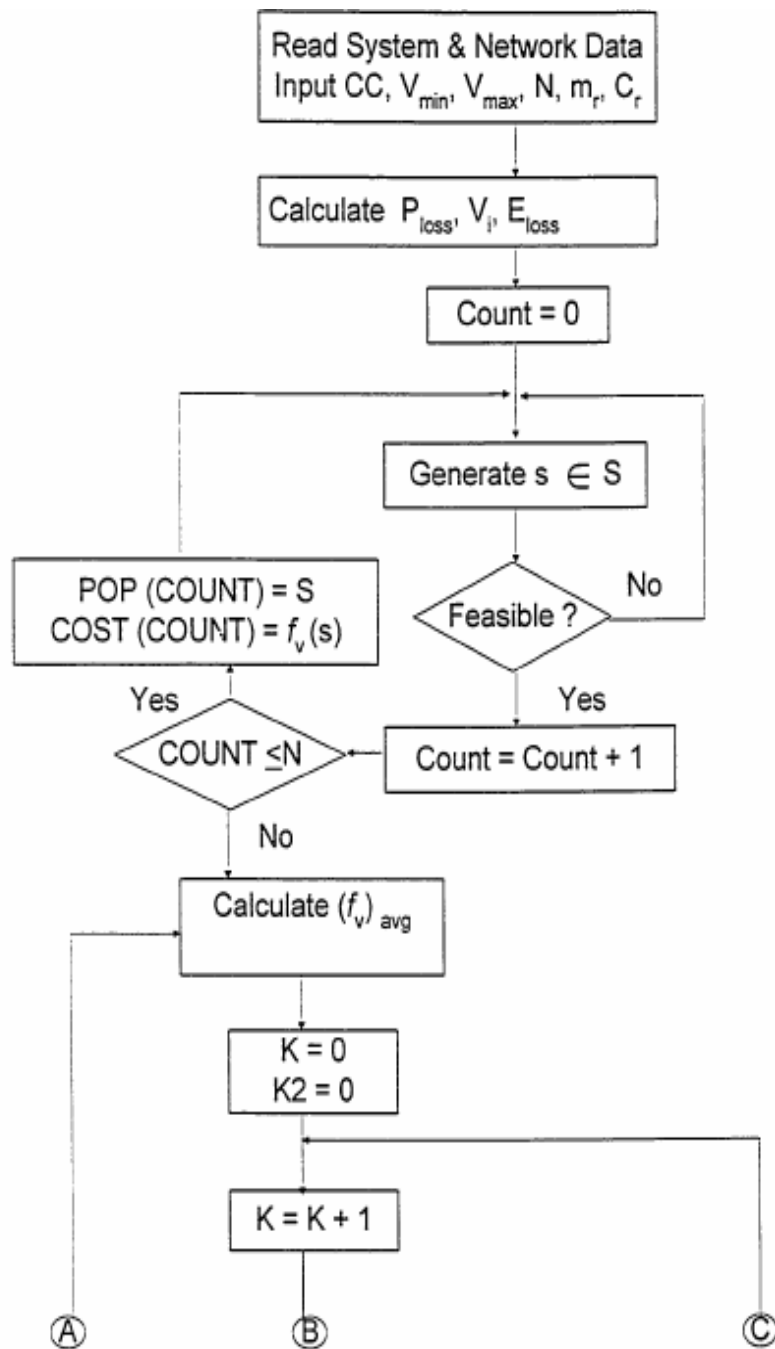
### 3.6.4 μ GA CPP μ μ μ

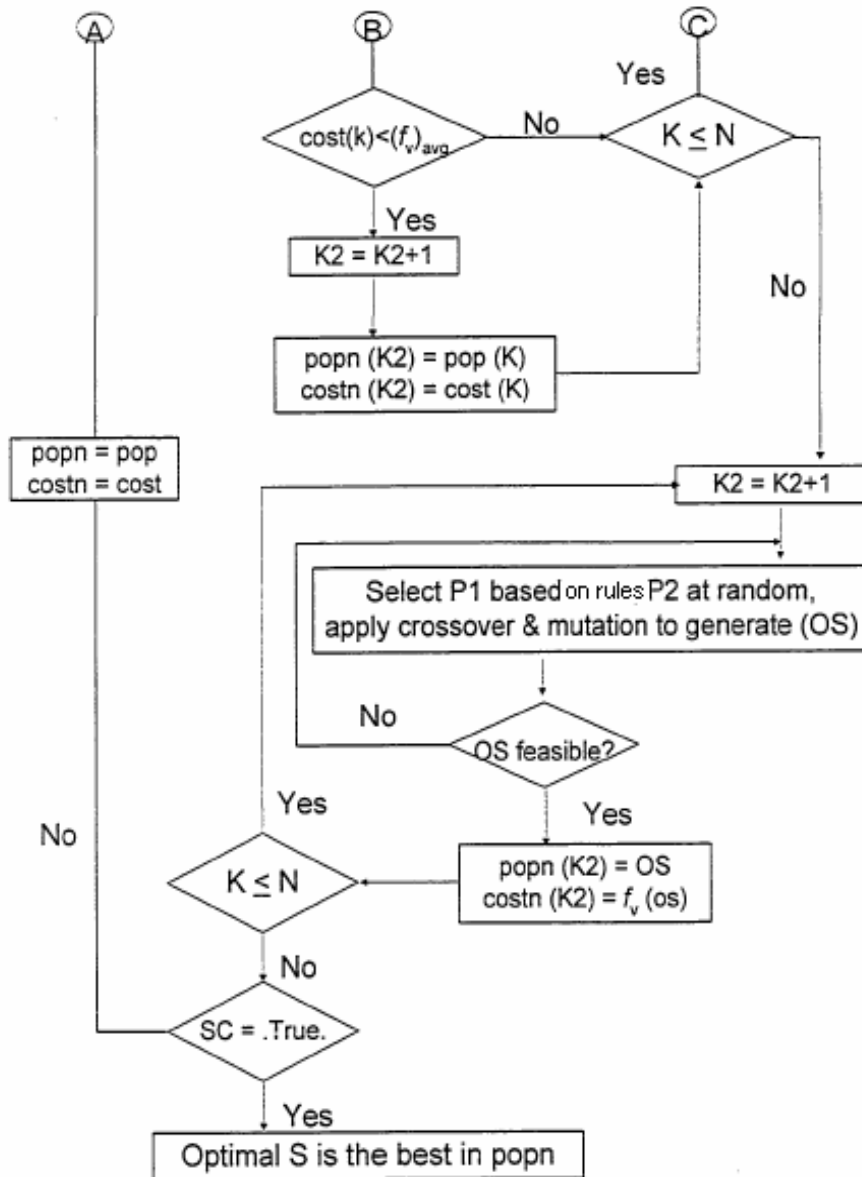
Εξαιτίας της απλότητας της γενικότητας και της ικανότητας να διαχειρίζεται τους πρακτικούς περιορισμούς, ένας γενετικός αλγόριθμος έχει σχεδιαστεί για να λύνει γενικά προβλήματα τοποθέτησης πυκνωτών σε διανεμημένα δίκτυα. Οι επόμενες επισημάνσεις ξεκαθαρίζουν τις σχεδιαστικές πλευρές του αλγόριθμου που εφαρμόζεται στο CPP:

1. Ο αλγόριθμος ακολουθείται από την ανάλυση ευαισθησίας που μελετήσαμε προηγουμένως για την επιλογή της τοποθεσίας του πυκνωτή. Στους ζυγούς θεωρούμε ότι μπορούν να θεωρηθούν fixed και switched πυκνωτές.
2. Για την επιλογή του αρχικού πληθυσμού επιλέγουμε ένα σταθερό αριθμό εφικτών λύσεων.
3. Η αντικειμενική συνάρτηση επιλέγεται να παρέχει την τιμή μιας νέας παραγόμενης λύσης. Όταν μια νέα λύση παράγεται ελέγχεται κατά πόσον ικανοποιεί τους περιορισμούς. Αν είναι εφικτή, τότε τη δεχόμαστε. Αλλιώς απορρίπτεται. Δεν τοποθετούμε παράγοντες ποινής.
4. Η διασταύρωση και η μετάλλαξη επιλέγονται σαν διαδικασίες στον αλγόριθμο. Όχι επιπλέον διαδικασίες όπως είναι η αντιστροφή.
5. Επιλέγουμε την multi-point διασταύρωση, δηλαδή σε κάθε στοιχείο του πληθυσμού, η διασταύρωση γίνεται σε ξεχωριστό σημείο του γονιδίου.
6. Ο ρυθμός μετάλλαξης επιλέγεται να είναι σταθερός για όλη τη διάρκεια της διαδικασίας.
7. Η μετάλλαξη και η διασταύρωση επιλέγονται εμπειρικά μετά από διαδοχικές επαναλήψεις.
8. Η steady-state αντικατάσταση προτιμάται. Σε κάθε επανάληψη υπολογίζεται η μέση τιμή των εκτιμημένων τιμών. Οι λύσεις που έχουν την τιμή αποτίμησης μικρότερη από το μέσο όρο δεν μεταβάλλονται. Όλες οι υπόλοιπες διασταυρώνονται και μεταλλάσσονται.
9. Για τον τερματισμό επιλέγουμε ένα δεδομένο πλήθος επαναλήψεων.

Με βάση τις παραπάνω αναφορές , η μεθοδολογία που εφαρμόζεται στο CPP πρόβλημα περιγράφεται . Ένα διάγραμμα ακολουθεί τα βήματα που αναφέρονται :

1. Διάβασε τα στοιχεία του συστήματος και των γραμμών. Εισαγωγή του κόστους πυκνωτών, minimum και maximum Volts , μέγεθος πληθυσμού (N), crossover ratio (CR) και mutation ratio ( $m_r$ ).
2. Υπολογισμός των απωλειών σε κάθε επίπεδο φορτίου ,πριν την τοποθέτηση των πυκνωτών.
3. Παραγωγή ενός συνόλου από εφικτές λύσεις ,σχεδιάζοντας τον αρχικό πληθυσμό (pop) τυχαία.
4. Υπολογισμός των τιμών αποτίμησης  $f_v(s)$  για κάθε λύση.
5. Καθορισμός της μέσης τιμής  $(f_v)_{avg}$  του πληθυσμού.
6. Μεταφορά όλων των στοιχείων που είναι μικρότερα της μέσης τιμής στο επόμενο στάδιο.
7. Επιλογή ενός γονέα από αυτές του βήματος (6) τυχαία. Ο άλλος γονέας επιλέγεται τυχαία από όλο το σύνολο. Εφαρμογή crossover και mutation και παραγωγή ενός απόγονου (os).
8. Αν η λύση δεν είναι εφικτή τότε πήγαινε στο (7), αλλιώς στο βήμα (9).
9. Υπολογισμός της τιμής του απόγονου  $f_v(os)$ .
10. Ο παραγόμενος απόγονος είναι ένα στοιχείο του νέου πληθυσμού και αντικαθιστεί ένα άλλο με τιμή μεγαλύτερη από τη μέση τιμή.
11. Επανάληψη των βημάτων (7) ως (10) για τον εύρεση των υπόλοιπων στοιχείων του πληθυσμού.
12. Επανάληψη των βημάτων (5) έως (11) μέχρι να ικανοποιηθούν τα κριτήρια τερματισμού. Αλλιώς πηγαίνουμε στο βήμα (13).
13. Η βέλτιστη λύση του νέου πληθυσμού είναι η βέλτιστη του προβλήματος .





μ 3.19 Διάγραμμα γενετικού αλγόριθμου στο CPP.



### 3.7

#### 3.7.1

Πριν την εγκατάσταση των πυκνωτών μια επανάληψη της μεθόδου Newton Raphson εκτελέστηκε με σκοπό την καταγραφή των συνθηκών του συστήματος . Στον πίνακα που ακολουθεί παρουσιάζονται τα μεγέθη της max και min τάσης ανά μονάδα στους ζυγούς καθώς και τις απώλειες στις γραμμές και το συνολικό κόστος εξαιτίας των απωλειών αυτών.

| <b>LOAD CASE</b>                    |          |          |         |
|-------------------------------------|----------|----------|---------|
|                                     | low      | medium   | peak    |
| <b>min Bus Voltage ( V )</b>        | 0,9561   | 0,9445   | 0,9297  |
| <b>max Bus Voltage ( V )</b>        | 1,0000   | 1,0000   | 1,0000  |
| <b>Real Power Losses ( KW )</b>     | 38,6901  | 61,6885  | 98,94   |
| <b>Cost of Energy Losses ( \$ )</b> | 2321,41  | 25020,85 | 5936,45 |
|                                     |          |          |         |
| <b>total cost ( \$ )</b>            | 33278,71 |          |         |

#### 3.10 Αποτελέσματα απωλειών IEEE15 – N-R

### 3.7.2 μ μ μ

Η προτεινόμενη μεθοδολογία αναπτύχθηκε στην Matlab R2008b και εκτελέστηκε σε ένα επεξεργαστή 2,0 GHz. Μελετώνται δυο περιπτώσεις :

- Παρουσία μόνο switched πυκνωτών και
- Παρουσία μόνο fixed πυκνωτών.

Στόχος είναι να φανεί ποιοι πυκνωτές έχουν καλύτερα οικονομικά αποτελέσματα και ποια η διάφορα των χρημάτων.

#### 3.7.2. . μ switched

Αρχικά θέτουμε τις παραμέτρους του γενετικού αλγόριθμου. Μετά από πειραματικές διαδικασίες επιλέγουμε:

Population Size = 20

Crossover ratio = 0.25

Mutation ratio = 0.01

No of iterations = 500

Με βάση τα παραπάνω δεδομένα και με την εκτέλεση του αλγόριθμου έχουμε την τοποθέτηση πυκνωτών στους ζυγούς :

|    | LOAD CASE |        |      |
|----|-----------|--------|------|
|    | low       | medium | peak |
| 4  | 1         | 4      | 4    |
| 6  | 1         | 3      | 3    |
| 7  | 1         | 1      | 1    |
| 11 | 2         | 3      | 3    |
| 15 | 1         | 1      | 1    |

### 3.11 Αριθμός πυκνωτών GA -switched

Από τον πίνακα φαίνεται ότι η συνολική χωρητικότητα των πυκνωτών που τοποθετούνται στο δίκτυο στη βέλτιστη λύση είναι:

- 600 KVAR στην low load case.
- 1200 KVAR στην medium load case.
- 1200 KVAR στην peak load case.

Μετά την τοποθέτηση των πυκνωτών στο δίκτυο υπολογίζουμε την τιμή της αντικειμενικής συνάρτησης καθώς και τα μέτρα των τάσεων. Τα αποτελέσματα παρουσιάζονται συνοπτικά στον πίνακα :

|                                     | LOAD CASE |         |         |
|-------------------------------------|-----------|---------|---------|
|                                     | low       | medium  | peak    |
| <b>min Bus Voltage ( V )</b>        | 0,9692    | 0,9699  | 0,9558  |
| <b>max Bus Voltage ( V )</b>        | 1,0000    | 1,0000  | 1,0000  |
| <b>Real Power Losses ( KW )</b>     | 21,5415   | 29,9068 | 49,3704 |
| <b>Cost of Energy Losses ( \$ )</b> | 1292,47   | 12130,2 | 2962,22 |
|                                     |           |         |         |
| <b>Cost of capacitors ( \$ )</b>    | 480       | 960     | 960     |
|                                     |           |         |         |
| <b>sum of costs ( \$ )</b>          | 1772,47   | 13090,2 | 3922,2  |
|                                     |           |         |         |
| <b>total cost ( \$ )</b>            | 18784,89  |         |         |


### 3.12 Απωλειες IEEE 15 –GA-switched

Παρατηρούμε ότι η εξοικονόμηση χρημάτων παρουσία πυκνωτών ανέρχεται στα


$$33278,21 - 18784,89 = 14493,32 \$$$

Εξοικονόμηση υπάρχει και στα τρία μεγέθη φορτίου. Αξιοσημείωτη είναι και η ευστάθεια στην τάση (το όριο στο οποίο κινείται το μέγεθος της τάσης είναι πιο μικρό ) που ενισχύει την ευστάθεια του δικτύου.

Για την κατανόηση της λειτουργίας του αλγόριθμου παρουσιάζουμε πως ο αλγόριθμος οδηγείται στη βέλτιστη λύση μετά από τις επαναλήψεις. Για κάθε ένα από τα τρία μεγέθη φορτίου (low, medium, peak) παρουσιάζουμε την αντικειμενική συνάρτηση του κόστους αλλά και την πολύ χρήσιμη συνάρτηση των απωλειών στο δίκτυο. Αρχικά στην **medium** περίπτωση φορτίου που διαρκεί το μεγαλύτερο χρονικό διάστημα έχουμε:




μ 3.20. Διάγραμμα κόστους ( $\times 10^4$  \$)-ML-GA-switched.




μ 3.20. Διάγραμμα απωλειών ενέργειας (KW)-ML.

Για το low έχουμε :




μ 3.21. Διάγραμμα κόστους ( \$ )-LL.




μ 3.21. Διάγραμμα απολειών ενέργειας (KW)-LL.

Τέλος για την μέγιστη

( **peak** ) παίρνουμε:



**μ 3.22.** Διάγραμμα κόστους ( \$ )-HL.



**μ 3.22.** Διάγραμμα απωλειών ενέργειας (KW)-HL.

### 3.7.2.B. μ fixed

Σε δεύτερο στάδιο εξετάζουμε την κατανομή των πυκνωτών στο δίκτυο όταν έχουμε στην διάθεση μας μόνο fixed πυκνωτές. Πολλές φορές ο συνεχής χειρισμός της θέσης των ρυθμιζόμενων πυκνωτών είναι δύσκολος και επίπονος για την ίδια τη συσκευή. Επιπλέον σε περιόδους διαρκών εναλλαγών του φορτίου από τη low ζήτηση σε medium και από medium σε peak και αντίστροφα είναι αδύνατη η συνεχής εναλλαγή των θέσεων του πυκνωτή.

Γι' αυτό και πολλές φορές προτιμάται η εγκατάσταση fixed πυκνωτών δηλαδή πυκνωτών με σταθερή ποσότητα που δεν μεταβάλλεται, σε αντίθεση με τους switched πυκνωτές. Οι αλλαγές σε σχέση με την προηγούμενη μελέτη έγκειται στο γεγονός ότι το πρόβλημα πλέον μελετάται συνολικά. Η αντικειμενική συνάρτηση είναι το άθροισμα του κόστους των τριών περιόδων πολλαπλασιασμένα με τα αντίστοιχα χρονικά διαστήματα.

Επιλέγουμε πάλι τις ίδιες παραμέτρους για τον γενετικό αλγόριθμο. Έτσι έχουμε τα εξής μεγέθη:

Population Size = 20

Crossover ratio = 0.25

Mutation ratio = 0.01

No of iterations = 500

Από την εκτέλεση του διαμορφωμένου να καλύπτει την γενική περίπτωση προγράμματος έχουμε για τις θέσεις των πυκνωτών τις αντίστοιχες ποσότητες άεργου ισχύος :

|    | μ |
|----|---|
| 4  | 3 |
| 6  | 3 |
| 7  | 1 |
| 11 | 3 |
| 15 | 1 |

### 3.13 Αριθμός πυκνωτών GA -fixed

Η βασική μονάδα των πυκνωτών που χρησιμοποιείται σε κάθε ζυγό είναι τα 100 KVAR. Άρα η συνολική έγχυση σε κάθε μέγεθος φορτίου είναι 1100 KVAR.

Κατά αντιστοιχία με τη πρώτη μελέτη , υπολογίζουμε με βάση τους εγκατεστημένους πυκνωτές τα μεγέθη της τάσης καθώς και την τιμή της αντικειμενικής συνάρτησης για τις τρεις χωριστές κατηγορίες φορτίου . Παίρνουμε τον πίνακα:

|                                     | LOAD CASE |         |         |
|-------------------------------------|-----------|---------|---------|
|                                     | low       | medium  | peak    |
| <b>min Bus Voltage ( V )</b>        | 0,9788    | 0,9678  | 0,9536  |
| <b>max Bus Voltage ( V )</b>        | 1,0000    | 1,0000  | 1,0000  |
| <b>Real Power Losses ( KW )</b>     | 19,4079   | 30,1489 | 50,9859 |
| <b>Cost of Energy Losses ( \$ )</b> | 1164,47   | 12228,4 | 3059,15 |
|                                     |           |         |         |
| <b>Cost of capacitors ( \$ )</b>    | 880       | 880     | 880     |
|                                     |           |         |         |
| <b>sum of costs ( \$ )</b>          | 2044,47   | 13108,4 | 3939,15 |
|                                     |           |         |         |
| <b>total cost ( \$ )</b>            | 19092,02  |         |         |

### 3.14 Απωλειες IEEE 15 GA -fixed


Συγκρίνοντας τις δυο μεθόδους που περιγράφηκαν παρατηρούμε ότι με τους fixed capacitors το συνολικό κόστος των απωλειών ενέργειας είναι μεγαλύτερο από ότι αυτό με τους switched capacitors .Η διάφορα είναι βέβαια :

$$19092,02 - 18784,89 = 307,13 \$$$


όποτε πρέπει να γίνεται συμψηφισμός με το κόστος από τη βλάβη των switched πυκνωτών (δηλαδή πόσο συχνά μεταβάλλεται το φορτίο) ώστε να αποφασίσουμε ποιο είδος συμφέρει στο δίκτυο μελέτης .




Τα παρακάτω διαγράμματα παρουσιάζουν τα μεγέθη των απωλειών και του κόστους κατά την διαδικασία εκτέλεσης του αλγόριθμου.




**μ 3.23.** Διάγραμμα κόστους ( $\times 10^4$  \$)-ML-GA-fixed.



**μ 3.23.** Διάγραμμα απωλειών ενέργειας medium φορτίου( KW ).



**μ 3.23.** Διάγραμμα απωλειών ενέργειας low φορτίου ( KW ).



**μ 3.23.** Διάγραμμα απωλειών ενέργειας peak φορτίου ( KW ).

## 3.8 PARTICLE SWARM OPTIMIZATION

### 3.8.1

Η βελτιστοποίηση σμηνών (particle swarm) είναι ένας πιθανολογικός, βασισμένος στον πληθυσμό αλγόριθμος υπολογιστών για την επίλυση προβλημάτων. Είναι ένα είδος νοημοσύνης σμηνών που είναι βασισμένο στις κοινωνικό-ψυχολογικές αρχές και παρέχει την μελέτη στην κοινωνική συμπεριφορά, καθώς επίσης συμβάλλει στις εφαρμογές εφαρμοσμένης μηχανικής. Ο αλγόριθμος βελτιστοποίησης σμηνών περιγράφηκε αρχικά το 1995 από James Kennedy και Russell C. Eberhart. Οι τεχνικές έχουν εξελιχθεί πολύ από τότε, και η αρχική έκδοση του αλγορίθμου είναι μόλις αναγνωρίσιμη στους τρέχοντες.

Το σμήνος διαμορφώνεται χαρακτηριστικά από τα μόρια στο πολυδιάστατο διάστημα και κάθε μόριο έχει μια θέση και μια ταχύτητα. Αυτά τα μόρια κινούνται μέσω του υπερδιαστήματος και έχουν δύο ουσιαστικές ικανότητες συλλογισμού: τη μνήμη της καλύτερης θέσης τους και τη γνώση του σφαιρικού ή γειτονικού τους βέλτιστου. Σε ένα πρόβλημα ελαχιστοποίησης, τα προβλήματα διατυπώνονται έτσι ώστε "βέλτιστο" απλά να σημαίνει τη θέση με τη μικρότερη αντικειμενική αξία. Τα μέλη ενός σμήνους διαβιβάζουν τις καλές θέσεις το ένα στο άλλο και ρυθμίζουν τη θέση και την ταχύτητά τους βασισμένες σε αυτές τις καλές θέσεις. Έτσι ένα μόριο έχει τις ακόλουθες πληροφορίες για να κάνει μια κατάλληλη αλλαγή στη θέση και την ταχύτητά του:

- Το σφαιρικό καλύτερο που είναι γνωστό σε όλα τα μόρια και ενημερώνεται αμέσως μόλις βρεθεί μια καλύτερη θέση από οποιοδήποτε σμήνος.
- Το τοπικό βέλτιστο που είναι η καλύτερη λύση που είχε στο παρελθόν κάθε μόριο.

Όσο ο αλγόριθμος επαναλαμβάνει, η απόδοση της γενικής καλύτερης λύσης βελτιώνεται (μειώσεις για το πρόβλημα ελαχιστοποίησης). Όμως πρέπει να σημειωθεί ότι θα μπορούσε να συμβεί να πλησιάζουν τελικά όλα τα μόρια που επηρεάζονται από το σφαιρικό καλύτερο στο σφαιρικό καλύτερο, και η τιμή δεν βελτιώνεται περισσότερο από το ολικό βέλτιστο παρά τις πολλές επαναλήψεις του PSO. Τα μόρια τριγυρνούν στο διάστημα αναζήτησης γύρω από το σφαιρικό βέλτιστο και δεν ανακαλύπτουν άλλες περιοχές αναζήτησης. Αυτό το φαινόμενο καλείται 'convergence'. Για την αποφυγή αυτής της περίπτωσης που δεν οδηγεί σε βέλτιστη λύση πρέπει να γίνει κατάλληλη επιλογή των σταθερών του αλγορίθμου που παρουσιάζονται παρακάτω.

Πρέπει να σημειωθεί ότι ο PSO λειτουργεί παρόμοια με την differential evolutionary approach που είδαμε στο πρόβλημα βελτιστοποίησης των απωλειών. Εξάλλου και αυτή αποτελεί τεχνική τεχνητής νοημοσύνης οπότε η δομή παραμένει κοινή.

### 3.8.2

### PSO μ

Για την κατανόηση της particle swarm optimization μεθόδου που αναφέραμε απαιτείται μια αναλυτική περιγραφή των βημάτων του αλγόριθμου ώστε να επιτύχουμε την βελτιστοποίηση της αντικειμενικής συνάρτησης .

Αρχικά θεωρούμε ότι το διάστημα αναζήτησης είναι d-διαστάσεων. Ο ορισμός της μεθόδου περιλαμβάνει:

1. Κάθε μέλος ονομάζεται ‘ μόριο ’ και κάθε τέτοιο μόριο (το  $i_{th}$  μόριο ) αναπαριστάται με ένα d-διαστάσεων διάνυσμα και περιγράφεται ως :

$$X_i = [x_{i_1}, x_{i_2}, \dots, x_{i_d}]$$

2. Το σύνολο των n μορίων στο σμήνος ονομάζεται πληθυσμός και περιγράφεται σαν :

$$pop = [X_1, X_2, \dots, X_n]$$

3. Η βέλτιστη λύση στην θέση κάθε μορίου ονομάζεται ‘ βέλτιστο μορίου ’ και περιγράφεται ως :

$$PB_i = [pb_{i_1}, pb_{i_2}, \dots, pb_{i_d}]$$

4. Η βέλτιστη λύση από όλα τα μόρια που έχουμε δημιουργήσει ονομάζεται ‘ γενικό βέλτιστο ’ και συμβολίζεται με :

$$GB = [gb_1, gb_2, \dots, gb_d]$$

5. Ο ρυθμός αλλαγής της θέσης κάθε μορίου ονομάζεται ‘ ταχύτητα μορίου ’ και γράφεται :

$$V_i = [v_{i_1}, v_{i_2}, \dots, v_{i_d}]$$

6. Στην επανάληψη k η ταχύτητα για τη d-διάσταση του  $i_{th}$  μορίου παίρνει την νέα μορφή:

$$v_{id}^{k+1} = wv_{id}^k + c_1r_1(pb_{id}^k - x_{id}^k) + c_2r_2(gb_d^k - x_{id}^k) \quad (3.23)$$

όπου το w είναι το βάρος αδρανείας τα  $c_1, c_2$  είναι οι ρυθμοί ταχύτητας και τα  $r_1, r_2$  δυο τυχαίες τιμές στο διάστημα [0,1].

7. Η θέση του  $i_{th}$  μορίου ανανεώνεται με την σχέση :

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (3.24)$$

Αν το διάστημα αναζήτησης είναι διακριτό και μπορεί να λάβει μόν ο δυαδικές τιμές εφαρμόζεται για τον υπολογισμό της ταχύτητας μια σιγμοειδή απεικόνιση ώστε η ταχύτητα να υπολογίζεται στο διάστημα  $[0,1]$  και κατόπιν να ωθεί τα στοιχεία να παίρνουν τις δυαδικές τιμές 0 ή 1. Για τον λόγο αυτό η σχέση που περιγράφηκε στο βήμα 7 αντικαθίσταται από τις παρακάτω σχέσεις :

$$sigmoid(v_{id}^k) = \frac{1}{1 + e^{-v_{id}^k}} \quad (3.25)$$

$$x_{id}^k = 1, \text{ if } rand < sigmoid(v_{id}^k) \\ x_{id}^k = 0, \text{ otherwise.}$$

### 3.8.3 μ PSO μ CPP

Το πρόβλημα της τοποθέτησης των πυκνωτών σε ένα δίκτυο , όταν επιλύεται με την μεθοδολογία του particle swarm optimization , λαμβάνεται ως δυαδικό. Για να επιλέξουμε τον αριθμό των πυκνωτών που θα τοποθετηθούν στον  $j_{th}$  ζυγό του συστήματος ,χρησιμοποιούμε μια μορφή πολλαπλασιασμού ακέραιων όπου υπολογίζουμε :

$$Nc_j^l = 2^0 b_1 + 2^1 b_2 + \dots + 2^{r-1} b_r + \dots + 2^{R-1} b_R, \quad (3.26)$$

$$\text{όπου } 2^0 + 2^1 + 2^2 + \dots + 2^{r-1} + \dots + 2^{R-1} \geq u, \text{ and } b_r = \{0,1\}$$

Τα αναλυτικά βήματα της διαδικασίας είναι για το  $l_{th}$  επίπεδο φορτίου.

1. Ένας πληθυσμός από  $n$  μόρια στην επανάληψη  $k$  περιγράφεται από τη σχέση:

$$pop^{lk} = [X^{lk}_1, X^{lk}_2, \dots, X^{lk}_n]$$

2. Κάθε μόριο  $i$  αναπαριστάται στις  $J$ -διαστάσεις ( όπου  $J$  ο αριθμός των πιθανών θέσεων του πυκνωτή):

$$X^{lk}_i = [x^{lk}_{i_1}, x^{lk}_{i_2}, \dots, x^{lk}_{i_J}]$$

3. Κάθε στοιχείο του μορίου αναπαριστάται στις  $R$ -διαστάσεις (όπου  $R$  ο μέγιστος ακέραιος που μπορεί να λάβει η σχέση υπολογισμού  $N$  c.):

$$X^{lk}_{ij} = [x^{lk}_{ij_1}, x^{lk}_{ij_2}, \dots, x^{lk}_{ij_R}]$$

4. Έτσι κάθε μόριο αναπαριστάται στις  $(J,R)$  διαστάσεις .
5. Ο αριθμός των πυκνωτών που τοποθετούνται στο  $l_{th}$  επίπεδο φορτίου στο ζυγό  $j_{th}$  στην επανάληψη  $k$  στο μόριο  $i$  υπολογίζεται από την σχέση:

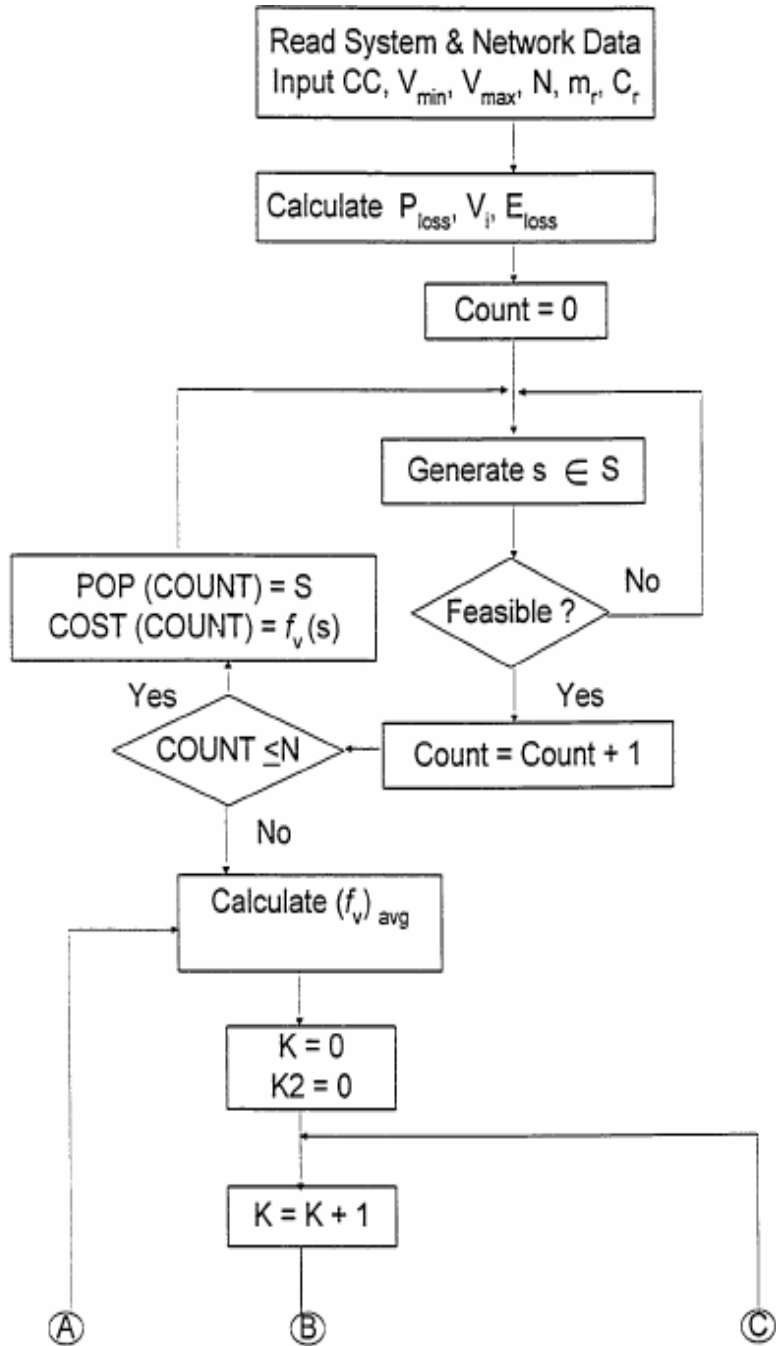
$$Nc_{ij}^{lk} = 2^0 x^{lk}_{ij1} + 2^1 x^{lk}_{ij2} + \dots + 2^{r-1} x^{lk}_{ijr} + \dots + 2^{R-1} x^{lk}_{ijR}$$

5. Το στοιχείο  $x^{lk}_{ijr}$  δείχνει αν η τιμή  $2^{r-1}$  χρησιμοποιείται στο  $l_{th}$  επίπεδο φορτίου στο ζυγό  $j_{th}$  στην επανάληψη  $k$  στο μόριο  $i$  και παίρνει την τιμή 1 αν χρησιμοποιείται και την τιμή 0 αν δεν χρησιμοποιείται.
6. Το βέλτιστο μόριο ,το ολικό βέλτιστο και η ταχύτητα μορίου αναπαριστώνται στις διαστάσεις  $(J,R)$ .

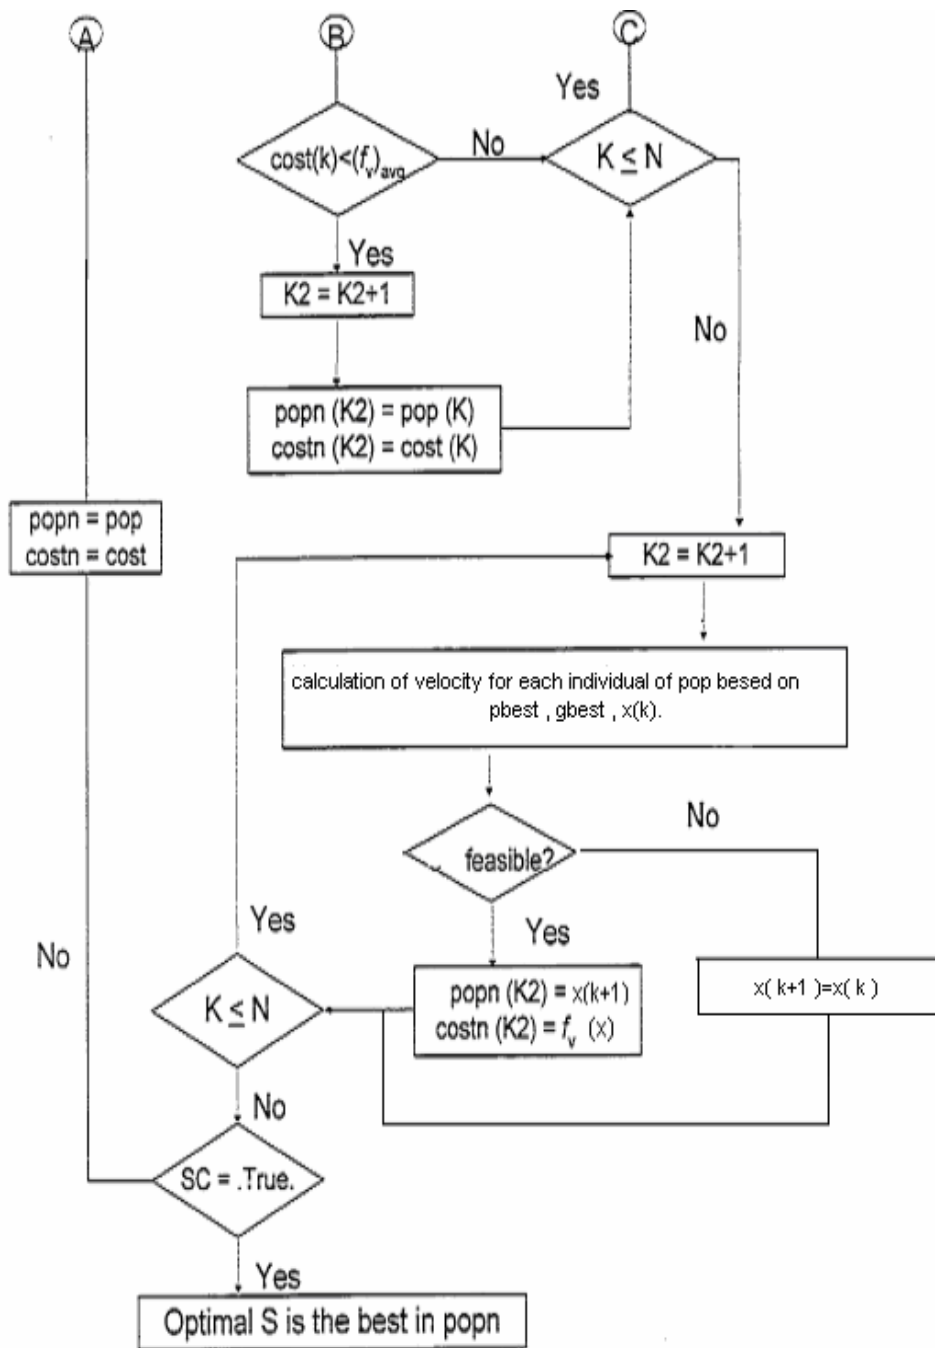
Αφού αναφέραμε την διαδικασία επίλυσης του CPP προβλήματος, παρουσιάζουμε τον αλγόριθμο κατά αναλογία με τα βήματα που παρουσιάστηκαν στη GA based μέθοδο. Η ομοιότητα σε κάποια βήματα είναι εμφανής κάτι που δείχνει ότι στην επίλυση προβλημάτων με τεχνητή νοημοσύνη ο βασικός άξονας επίλυσης παραμένει σταθερός.

1. Διάβασμα των στοιχείων του συστήματος και των γραμμών. Εισαγωγή του κόστους πυκνωτών, minimum και maximum Volts, τελεστών ταχύτητας  $c_1, c_2$ , τελεστών συντελεστή αδρανεϊας  $w_{max}, w_{min}$  και 'θερμοκρασία'  $T$ .
2. Υπολογισμός των απωλειών σε κάθε επίπεδο φορτίου, πριν την τοποθέτηση των πυκνωτών.
3. Παραγωγή ενός συνόλου από εφικτές λύσεις, σχεδιάζοντας τον αρχικό πληθυσμό (pop) τυχαία.
4. Υπολογισμός των τιμών αποτίμησης  $f_v(s)$  για κάθε λύση του αρχικού πληθυσμού.
5. Καθορισμός της μέσης τιμής  $(f_v)_{avg}$  του πληθυσμού.
6. Μεταφορά όλων των στοιχείων που είναι μικρότερα της μέσης τιμής στο επόμενο στάδιο.
7. Υπολογισμός για τα στοιχεία με μεγαλύτερης της μέσης τιμής της ταχύτητας  $v$  και της νέας κατάστασης  $x$ .
8. Αν η λύση δεν είναι εφικτή τότε πήγαινε στο (7), αλλιώς στο βήμα (9).
9. Υπολογισμός της τιμής του νέου διανύσματος  $f_v(x)$ .
10. Το παραγόμενο διάνυσμα είναι ένα στοιχείο του νέου πληθυσμού και αντικαθιστεί ένα άλλο με τιμή μεγαλύτερη από τη μέση τιμή.
11. Επανάληψη των βημάτων (7) ως (10) για τον εύρεση των υπόλοιπων στοιχείων του πληθυσμού.
12. Επανάληψη των βημάτων (5) έως (11) μέχρι να ικανοποιηθούν τα κριτήρια τερματισμού. Αλλιώς πηγαίνουμε στο βήμα (13).
13. Η βέλτιστη λύση του νέου πληθυσμού είναι η βέλτιστη του προβλήματος.

Ένα διάγραμμα της μεθόδου παρουσιάζεται στο σχήμα :







μ 3.24 Διάγραμμα PSO αλγόριθμου στο CPP.

### 3.9

### PSO

#### 3.9.1

Σε αντιστοιχία με ότι κάναμε με τους γενετικούς αλγόριθμους εφαρμόζουμε τον αλγόριθμο του σμήνους για την τοποθέτηση πυκνωτών στο δίκτυο IEEE-15 ζυγών . Επιλέγουμε το ίδιο δίκτυο ώστε να έχουμε την κοινή μονάδα σύγκρισης του αλγόριθμου τόσο με την αρχική κατάσταση όσο και με την λύση που προήλθε από τον GA αλγόριθμο .

Το πρόγραμμα εκτελέστηκε με την βοήθεια του Matlab. Αρχικά θέτουμε τις σταθερές παραμέτρους του αλγόριθμου. Η καλύτερη δυνατή επιλογή ήταν η :

Θερμοκρασία  $T = 150$ .

Σταθερά  $c_1 = 0,05$

Σταθερά  $c_2 = 0,05$

Τελεστής αδρανείας  $w_{\max} = 0,8$

Τελεστής αδρανείας  $w_{\min} = 0,4$

Η σχέση που δίνει τον συντελεστή αδρανείας  $w$  σε κάθε επανάληψη είναι :

$$w = w_{\max} - (w_{\max} - w_{\min}) \frac{t}{T}$$

όπου  $t$  είναι ο αριθμός της επανάληψης που στην περίπτωση μας φτάνει μέχρι την τιμή του  $T$ .

Αφού έχουν οριστεί όλες οι παράμετροι του αλγόριθμου και του προβλήματος των 15 ζυγών εκτελούμε την μεθοδολογία πρώτα με την παρουσία switched πυκνωτών.

### 3.9.2. μ μ

#### 3.9.2.A. switched

Ο πίνακας που προκύπτει μετά την εφαρμογή της μεθόδου αυτής της τεχνητής νοημοσύνης είναι ο ακόλουθος για την τοποθέτηση των πυκνωτών :

|    | load flow |        |      |
|----|-----------|--------|------|
|    | low       | medium | peak |
| 4  | 2         | 3      | 3    |
| 6  | 2         | 1      | 1    |
| 7  | 1         | 3      | 3    |
| 11 | 1         | 1      | 3    |
| 15 | 1         | 1      | 1    |

### 3.15 Αριθμός πυκνωτών PSO -switched

Βλέπουμε ότι ο αριθμός των πυκνωτών μεταβάλλεται ανάλογα με το είδος του φορτίου. Έτσι στο χαμηλό φορτίο ο συνολικός αριθμός είναι 7 ,στο μεσαίο φορτίο είναι 12 ενώ στο υψηλό 11.

Ο συγκεντρωτικός πίνακας των τάσεων και των απωλειών -κόστους που προκύπτει για τις τρεις κατηγορίες φορτίων είναι :

|                                     | load case |         |         |
|-------------------------------------|-----------|---------|---------|
|                                     | low       | medium  | peak    |
| <b>min Bus Voltage ( V )</b>        | 0,9694    | 0,9689  | 0,9536  |
| <b>max Bus Voltage ( V )</b>        | 1,0000    | 1,0000  | 1,0000  |
| <b>Real Power Losses ( KW )</b>     | 20,5783   | 30,3314 | 51,0569 |
| <b>Cost of Energy Losses ( \$ )</b> | 1234,69   | 12302,4 | 3063,41 |
|                                     |           |         |         |
| <b>Cost of capacitors ( \$ )</b>    | 560       | 880     | 880     |
|                                     |           |         |         |
| <b>sum of costs ( \$ )</b>          | 1797,69   | 13182,4 | 3943,4  |
|                                     |           |         |         |
| <b>total cost ( \$ )</b>            | 18923,49  |         |         |

### 3.16 Απωλειες IEEE 15 PSO-switched

Σε σχέση με την κατάσταση πριν την τοποθέτηση των πυκνωτών η εξοικονόμηση χρημάτων είναι μεγάλη :

$$33278,21 - 18923,49 = 14354,72 \$.$$


Ακόμη παρατηρείται ξανά βελτίωση στην ευστάθεια της τάσης παρουσία των πυκνωτών. Όμως σε σχέση με τον αλγόριθμο GA το αποτέλεσμα είναι κατά ελάχιστα χειρότερο. Η διάφορα στην εξοικονόμηση χρημάτων είναι:

$$18923,49 - 18784,89 = 138,6 \$$$


που αντιστοιχεί σε διάφορα μικρότερη του 1% .

Παρουσιάζεται στα επόμενα διαγράμματα η ακολουθία του αλγόριθμου μέχρι την εξεύρεση της επιθυμητής λύσης . Αρχικά παρουσιάζεται η πορεία της αντικειμενικής συνάρτησης κόστους και στη συνέχεια η απώλειες των γραμμών σε όλο το δίκτυο.

### Medium load case




**μ 3.25.** Κόστος απωλειών ( $\times 10^4$  \$)-ML-PSO-switched.




**μ 3.25.** Απώλειες γραμμών ( KW )-ML

**Low load case**




**μ 3.26.** Κόστος απωλειών ( \$ )-LL.




μ 3.26. Απώλειες γραμμών ( KW )-LL.

**Peak load case**



μ 3.27. Κόστος απωλειών ( \$ )-HL



**μ 3.27.** Απώλειες γραμμών ( KW ) -HL

3.9.2. . fixed capacitors.

Για το πλήρες του προβλήματος εξετάζεται και η περίπτωση όπου πρέπει να εγκατασταθούν πυκνωτές σταθερής τιμής ( fixed) που δεν μεταβάλλονται ανάλογα με το φορτίο. Στην περίπτωση αυτή εκτελείται ο αλγόριθμος για ενιαίο πόσο απωλειών στη διάρκεια του χρόνου και το αποτ έλεσμα για την εγκατάσταση πυκνωτών είναι :

|    | μ |
|----|---|
| 4  | 3 |
| 6  | 1 |
| 7  | 3 |
| 11 | 3 |
| 15 | 1 |

**3.17** Αριθμός πυκνωτών PSO -fixed

Ο συγκεντρωτικός πίνακας όλων των ενδιαφερόμενων στοιχείων από την μελέτη της PSO μεθόδου παρουσιάζονται στον πίνακα.

|                                     | load case |          |         |
|-------------------------------------|-----------|----------|---------|
|                                     | low       | medium   | peak    |
| <b>min Bus Voltage ( V )</b>        | 0,9788    | 0,9678   | 0,9536  |
| <b>max Bus Voltage ( V )</b>        | 1,0000    | 1,0000   | 1,0000  |
| <b>Real Power Losses ( KW )</b>     | 19,6727   | 30,4314  | 51,0569 |
| <b>Cost of Energy Losses ( \$ )</b> | 1180,36   | 12352,9  | 3063,41 |
|                                     |           |          |         |
| <b>Cost of capacitors ( \$ )</b>    | 880       | 880      | 880     |
|                                     |           |          |         |
| <b>sum of costs ( \$ )</b>          | 2060,36   | 13232,9  | 3943,4  |
|                                     |           |          |         |
| <b>total cost ( \$ )</b>            |           | 19236,66 |         |

### 3.18 Απολλειες IEEE 15 PSO -fixed

Το αποτέλεσμα της αντικειμενικής συνάρτησης ,όπως αναμέναμε, είναι χειρότερο από αυτό της A περίπτωσης με τους switched πυκνωτές . Η διάφορα είναι :

$$19236,66-18970,69=265,97 \$$$


Επίσης λιγότερο επωφελές είναι το αποτέλεσμα και σε σύγκριση με την αντίστοιχη διάταξη του GA αλγόριθμου. Η διάφορα αυτή είναι :

$$19236,66-19092,02=144,64$$


που και πάλι είναι αμελητέα ( <0,75 % ).




Τα αντίστοιχα διαγράμματα είναι :




**μ 3.28.** Συνολικού Κόστους ( $\times 10^4$  \$ )-PSO-fixed.



**μ 3.28.** Απωλειών μέσου φορτίου (KW)



**μ 3.28.** Απωλειών low φορτίου (KW)



**μ 3.28.** Απωλειών peak φορτίου (KW)

## ΕΦΑΡΜΟΓΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΣΤΟ ΠΡΟΒΛΗΜΑ ΕΓΚΑΤΑΣΤΑΣΗΣ ΠΥΚΝΩΤΩΝ

### 4.3

Μέχρι στιγμής μελετήθηκε το πρόβλημα της εγκατάστασης πυκνωτών σε ένα δίκτυο με στόχο την μείωση των απωλειών στις γραμμές μεταφοράς και την εξοικονόμηση χρημάτων από την μείωση αυτή. Αναπτύχθηκαν διάφορες τεχνικές τεχνητής νοημοσύνης ( γενετικοί αλγόριθμοι, particle swarm optimization ) που στόχο έχουν την καλύτερη κατανομή του μεγέθους των πυκνωτών που σε συνδυασμό με χρήση της ανάλυσης ευαισθησίας (για την επιλογή της τοποθεσίας του πυκνωτή) λαμβάνουμε το επιθυμητό αποτέλεσμα.

Όμως το πρόβλημα της τοποθέτησης των πυκνωτών είναι ένα δυναμικό πρόβλημα. Μέχρι τώρα η εφαρμογή των αλγόριθμων έγινε για δεδομένα και σταθερά φορτία στους ζυγούς του δικτύου. Όμως στην καθημερινή εφαρμογή το φορτίο δεν μένει σταθερό. Αντιθέτως μεταβάλλεται συνεχώς όποτε για την ελαχιστοποίηση των απωλειών πρέπει να γίνεται μετά από κάθε αλλαγή του φορτίου , ο υπολογισμός της βέλτιστης λύσης . Αυτό απαιτεί πολύ υπολογιστικό χρόνο γιατί όπως είδαμε στους αλγόριθμους που αναπτύχθηκαν ,ο αριθμός των επαναλήψεων μέχρι την εύρεση του τελικού αποτελέσματος είναι πολύ μεγάλος . όποτε πρέπει να βρεθεί ένας τρόπος να μειωθεί ο χρόνος υπολογισμού για πολλά απλά φορτία .Μια αντιμετώπιση του προβλήματος αυτού είναι η εφαρμογή νευρωνικών δικτύων για την εύρεση ανάλογα με το φορτίο , της διάταξης των πυκνωτών. Όμως πριν την αναφορά στον αλγόριθμο κρίνεται σκόπιμη η αναλυτική περιγραφή των νευρωνικών δικτύων τα οποία θα χρησιμοποιηθούν και σε ακόλουθες εφαρμογές .

### 4.2


#### 4.2.1

Τα τεχνητά νευρικά δίκτυα, συνήθως αποκαλούμενα «νευρικά δίκτυα» είναι μια διαφορετική μεθοδολογία υπολογισμού. Το κίνητρο πίσω από την ανάπτυξη του νευρικού δικτύου ήταν ακριβώς η επιβεβαίωση ότι ο εγκέφαλος λειτουργεί με έναν εξ ολοκλήρου διαφορετικό τρόπο από το συμβατικό ψηφιακό υπολογιστή. Αν και οι σημερινοί υπολογιστές είναι πολύ γρήγοροι και εμφανίζουν τεράστια ταχύτητα στην επεξεργασία πληροφοριών, ακόμα είναι πολύ πίσω από την ικανότητα ενός βιολογικού εγκεφάλου. Παραδείγματος χάριν, το sonar σύστημα θέσης ήχους, μιας

νυχτερίδας . Εκτός από την παροχή των πληροφοριών για το πόσο μακριά βρίσκεται ένας στόχος (δηλαδή ένα ιπτάμενο έντομο) , το σύστημα sonar μεταβιβάζει τις πληροφορίες για τη σχετική ταχύτητα του στόχου, του μεγέθους και των διάφορων χαρακτηριστικών γνωρισμάτων, του αζιμουθίου και της ανύψωσης του στόχου. Αυτοί οι σύνθετοι νευρικοί υπολογισμοί που απαιτούνται για να εξαγάγουν όλες αυτές τις πληροφορίες από την στοχευόμενη ηχώ εμφανίζονται μέσα σε έναν εγκέφαλο πολύ μικρού μεγέθους . Πράγματι, μια νυχτερίδα με sonar σύστημα εντόπισης μπορεί να ακολουθήσει και να συλλάβει το στόχο της με ένα ποσοστό επιτυχίας που θα ήταν ζηλευτό από ένα μηχανικό ραντάρ ή sonar. Για να καταλαβαίνουμε τις λειτουργίες ενός τεχνητού νευρικού δικτύου, πρέπει να ξέρουμε πώς ο ανθρώπινος εγκέφαλος λειτουργεί.

#### 4.2.2

Ο εγκέφαλος είναι η μονάδα κεντρικής επεξεργασίας (ΚΜΕ) ενός βιολογικού νευρικού δικτύου. Η προσπάθεια να γίνει κατανοητός ο τρόπος λειτουργίας του εγκεφάλου, οφείλει πολύς στην πρωτοποριακή εργασία του Ramón y Cajal, ο οποίος εισήγαγε αρχικά την ιδέα των νευρώνων ως δομικά συστατικά ενός εγκεφάλου . Ο ανθρώπινος εγκέφαλος αποτελείται από 10 δισεκατομμύριο νευρώνες. Το σχήμα παρουσιάζει τη δομή ενός νευρώνα εγκεφάλου. Οι νευρώνες είναι συνδεδεμένοι στον τρισδιάστατο χώρο. Υπάρχουν περίπου 60 τρισεκατομμύρια συνάψεις ή διασυνδέσεις μεταξύ τους. Είναι ακόμα άγνωστο για το πώς ο εγκέφαλος εκπαιδεύεται για να επεξεργαστεί τις πληροφορίες, έτσι οι θεωρίες αφθονούν. Στον ανθρώπινο εγκέφαλο, ένας χαρακτηριστικός νευρώνας συλλέγει τα σήματα από άλλα μέσω ενός πλήθους των λεπτών δομών που αποκαλούνται δένδριτες. Ο νευρώνας στέλνει τις ακίδες της ηλεκτρικής δραστηριότητας μέσω μιας μακριάς, λεπτής απόφυσης γνωστής ως νευρίτης, ο οποίος χωρίζει σε χιλιάδες κλάδους . Στο τέλος κάθε κλάδου, μια δομή αποκαλούμενη σύναψη μετατρέπει τη δραστηριότητα από το νευρίτη στα ηλεκτρικά αποτελέσματα που εμποδίζουν ή διεγείρουν τη δραστηριότητα στους συνδεδεμένους νευρώνες. Όταν ένας νευρώνας λαμβάνει την διεγερωμένη είσοδο που είναι αρκετά μεγάλη έναντι της ανασταλτικής , στέλνει μια ακίδα της ηλεκτρικής δραστηριότητας κάτω από το νευρίτη του. Η εκμάθηση εμφανίζεται με την αλλαγή της αποτελεσματικότητας των συνάψεων έτσι ώστε η επιρροή ενός νευρώνα σε άλλον να αλλάζει. Κατά τη διάρκεια των πρώτων σταδίων της ανάπτυξης, περίπου ένα εκατομμύριο συνάψεις διαμορφώνονται ανά δευτερόλεπτο.

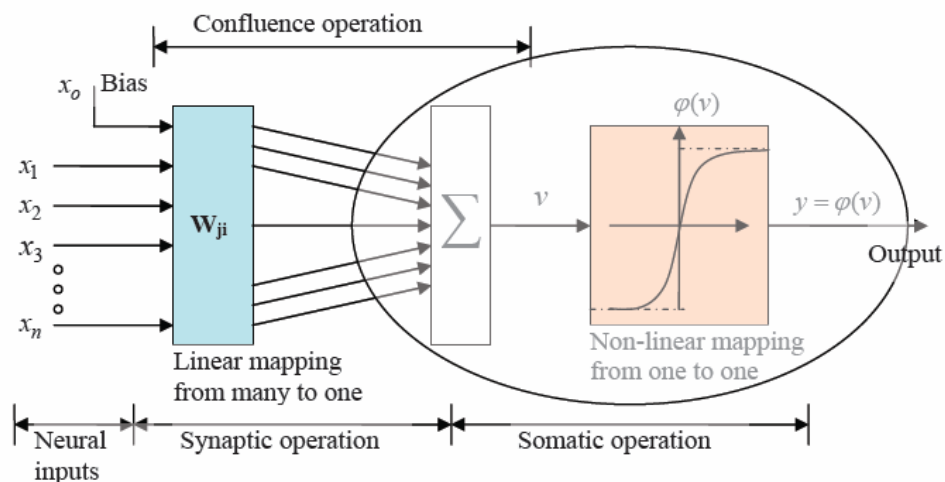


#### μ 4.1 Βιολογικό νευρωνικό δίκτυο

Ένας εγκέφαλος είναι ένας ιδιαίτερα σύνθετος, μη γραμμικός, και παράλληλος υπολογιστής. Έχει την ικανότητα της οργάνωσης των νευρώνων ώστε να εκτελεστούν ορισμένοι υπολογισμοί (π.χ. αναγνώριση σχεδίων, αντίληψη, και έλεγχος μηχανών) πολύ γρηγορότερα από το γρηγορότερο ψηφιακό υπολογιστή σήμερα. Η ενεργητική αποδοτικότητα του εγκέφαλου είναι επίσης πολύ καλύτερη που οποιοσδήποτε αποδοτικό υπολογιστή. Ο εγκέφαλος παίρνει μόνο  $10^{-16}$  τζάουλ ανά λειτουργία ανά δευτερόλεπτο ενώ η αντίστοιχη αξία για τους καλύτερους υπολογιστές σε λειτουργία κατά τη διάρκεια του 1994 ήταν περίπου  $10^{-6}$  τζάουλ ανά λειτουργία [20]. Ένας βιολογικός νευρώνας μπορεί να έχει τουλάχιστον 10.000 διαφορετικές εισόδους, και μπορεί να στείλει την παραγωγή του σε πολλούς άλλους νευρώνες [21]. Μπορεί να μάθει από πείρα, και από τις αισθήσεις που λαμβάνονται από οποιαδήποτε αισθητήρια όργανα. Οι πραγματικοί εγκέφαλοι, εντούτοις, πολλές φορές πιο σύνθετοι από οποιοδήποτε τεχνητό νευρικό δίκτυο εξετάζονται μέχρι και σήμερα.

#### 4.2.3 μ μ

Ένα κύτταρο νεύρου, που είναι η δομική μονάδα του ανθρώπινου νευρικού συστήματος συμπεριλαμβανομένου του εγκέφαλου, καλείται νευρώνας. Στη φύση, οι βιολογικοί νευρώνες περιλαμβάνονται σε διάφορες σύνθετες διεργασίες όπως στο αισθητήριο, τον έλεγχο και τις γνωστικές πτυχές της μαθηματικής επεξεργασίας καθώς και στις διαδικασίες λήψης απόφασης. Ομοίως ένα τεχνητό νευρωνικό δίκτυο αποτελείται από πολλούς ίδιους νευρώνες. Το σχήμα παρουσιάζει μαθηματικό πρότυπο ενός νευρώνα:



μ 4.2 Μαθηματικό πρότυπο νευρώνα.

#### 4.2.4

Οι νευρικές προσομοιώσεις των δικτύων φαίνονται να είναι μια πρόσφατη ανάπτυξη. Εντούτοις, αυτός ο τομέας καθιερώθηκε πριν από την εμφάνιση των υπολογιστών. Άρχισε με τη διαμόρφωση των λειτουργιών ενός ανθρώπινου εγκεφάλου από τους McCulloch και Pitts το 1943, οι οποίοι δημοσίευσαν ένα έγγραφο που περιγράφει το λογικό υπολογισμό των νευρικών δικτύων. Η σημαντικότερη ανάπτυξη των νευρικών δικτύων ήρθε το 1949 με τη δημοσίευση του βιβλίου του Hebb με τίτλο 'η οργάνωση της συμπεριφοράς' όπου μια αναφορά για την ύπαρξη ενός φυσιολογικού κανόνα εκμάθησης για τη συναπτική τροποποίηση παρουσιάστηκε για πρώτη φορά. Το βιβλίο του Hebb είναι μια πηγή έμπνευσης για την ανάπτυξη των υπολογιστικών προτύπων της εκμάθησης και της προσαρμοστικότητας. Το 1954, ο Minsky έγραψε μια διατριβή στο «νευρικό δίκτυο» στη μελέτη του διδακτορικού του. Το 1961, έγραψε ότι ένα έγγραφο για την τεχνητή νοημοσύνη με τίτλο 'τα βήματα προς την τεχνητή νοημοσύνη'. Το 1954, ο Gabor, ο πρώτος πρωτοπόρος της επικοινωνίας πρότεινε την ιδέα του μη γραμμικού προσαρμοστικού φίλτρου. Προσπάθησε να χτίσει μια μηχανή, στην οποία η εκμάθηση ολοκληρώθηκε με την τροφοδότηση των δειγμάτων μιας πιθανολογικής διαδικασίας στη μηχανή, μαζί με τη λειτουργία στόχων που η μηχανή αναμενόταν να παραγάγει. Το 1958, Rosenbatt πρότεινε μια νέα προσέγγιση στο πρόβλημα αναγνώρισης σχεδίων. Τα επιτεύγματα της εργασίας Rosenbatt ονομάστηκαν : perceptron θεώρημα σύγκλισης. Το 1960, Widrow και Hoff εισήγαγαν τον αλγόριθμο ελαχίστων μέσων τετράγωνων (LMS). Ένα από τα πιο πρόωρα εκπαιδευσιμα πολυστρωματικά νευρικά δίκτυα με τα πολλαπλάσια προσαρμοστικά στοιχεία ήταν η δομή Madaline (multiple-adaline) που προτάθηκε από τον Widrow (1962).

Το σοβαρό πρόβλημα στην πρόωρη έρευνα για το νευρικό δίκτυο ήταν εν μέρει τεχνολογικό και εν μέρει οικονομικό. Στην απουσία των σημερινών προσωπικών Η/Υ ή τερματικών σταθμών, το νευρικό σχέδιο δικτύων και η κατάρτιση έπρεπε να

γίνονται στα αναλογικά κυκλώματα. Παραδείγματος χάριν, ο Gabor ανέπτυξε το μη γραμμικό φίλτρο του, το οποίο πήρε στην ερευνητική ομάδα του έξι έτη για να το χτίσει με τις αναλογικές συσκευές. Δεν υπήρξε αρκετή χρηματοδότηση στις πρώτες μέρες για να διεξαγάγει την έρευνα. Εντούτοις, στη δεκαετία του '80, με την ανάπτυξη των προσωπικών Η/Υ, υπήρξε μια αναβίωση του ενδιαφέροντος για τα νευρικά δίκτυα.

Στη δεκαετία του '80, σημαντικές συνεισφορές στη θεωρία και το σχέδιο των νευρικών δικτύων έγιναν σε διάφορα μέτωπα. Ο Grossberg (1980) καθιέρωσε μια νέα αρχή της ατομικής -οργάνωσης (self organization). Με αυτή τη λογική υπάρχει η ικανότητα, εάν το πρότυπο εισόδου και ανατροφοδοτούμενης μάθησης είναι σε αντιστοιχία, μια δυναμική κατάσταση αποκαλούμενη adaptive resonance πραγματοποιείται. Αυτό το φαινόμενο παρέχει τη βάση της νέας κατηγορίας νευρικών δικτύων γνωστών ως adaptive resonance theory (ART). Το 1982, ο Hopfield χρησιμοποίησε την ιδέα της ενεργειακής λειτουργίας να διατυπωθεί ένας νέος τρόπος κατανόησης του υπολογισμού που εκτελέστηκε από τα επαναλαμβανόμενα δίκτυα με τις συμμετρικές συναπτικές συνδέσεις. Ανέπτυξε μια νέα κατηγορία νευρικού δικτύου με ανατροφοδοτεί, το οποίο είναι γνωστό ως δίκτυα Hopfield. Μια άλλη σημαντική ανάπτυξη το 1982 έγινε από Kohonen. Ανέπτυξε έναν self-organizing χάρτη χρησιμοποιώντας ένα δικτυωτό πλέγμα. Το 1983, οι Kirpatrick, Gallat και Vecchi περιέγραψαν μια νέα διαδικασία αποκαλούμενη simulated annealing, για την επίλυση του συνδυαστικού προβλήματος βελτιστοποίησης.


Το 1986, οι Rumelhart, Hinton και ο Williams ανέπτυξαν έναν αλγόριθμο εκμάθησης αποκαλούμενο back propagation ο οποίος έχει προκύψει ως δημοφιλέστερος αλγόριθμος εκμάθησης για την κατάρτιση πολυστρωματικού perceptron. Αργότερα, ο back-propagation αλγόριθμος τροποποιήθηκε από πολλούς ερευνητές για να αυξήσει την ταχύτητα της κατάρτισης. Οι Broomhead και Lowe, το 1988, περιέγραψαν μια διαδικασία για το σχεδιασμό των ακτινωτών δικτύων ο οποίος παρέχει μια εναλλακτική λύση πολυστρωματικών perceptrons.

Τα νευρικά δίκτυα έχουν προέλθει βεβαίως μετά από μια μακροχρόνια μελέτη από τις πρώτες μέρες των McCulloch και Pitts. Το έγγραφο του 1982 από τον Hopfield και το βιβλίο από τους Rumelhart και McClelland ήταν οι δημοσιεύσεις, αρμόδιες για την αναβίωση του ενδιαφέροντος για το νευρικό δίκτυο στη δεκαετία του '80. Σήμερα, τα νευρικά δίκτυα έχουν καθιερωθεί ως διεπιστημονικό θέμα με τις βαθιές ρίζες στη νευρολογία, την ψυχολογία, τα μαθηματικά, τις φυσικές επιστήμες και την εφαρμοσμένη μηχανική.

#### 4.2.5

Υπάρχει ευρεία ποικιλία των νευρικών δικτύων και των αρχιτεκτονικών τους. Οι τύποι νευρικών δικτύων κυμαίνονται από τα απλά Boolean δίκτυα (perceptions) ως τα σύνθετα self-organizing δίκτυα (δίκτυα Kohonen). Υπάρχουν επίσης πολλοί άλλοι τύποι δικτύων όπως τα δίκτυα Hopfield, δίκτυα παλμού, δίκτυα λειτουργίας ακτινωτής βάσης, μηχανή Boltzmann. Αν και η αρχιτεκτονική των νευρικών δικτύων δεν μπορεί να δεσμευθεί από κάποιους καθορισμένους κανόνες, υπάρχουν μερικές τυποποιημένες δικτυακές αρχιτεκτονικές όπως περιγράφονται κατωτέρω.

Single-Layer feedforward δίκτυα: Είναι ο απλούστερος τύπος δικτύου που αποτελείται από ένα στρώμα εισόδων που κατευθύνονται άμεσα στους νευρώνες του στρώματος εξόδου. Δεν υπάρχει κανένα κρυμμένο στρώμα σε αυτήν την αρχιτεκτονική. Είναι αυστηρά feedforward τύπου, δεδομένου ότι δεν υπάρχει κανένα σύστημα ανατροφοδότησης από το στρώμα εξόδου. Το σχήμα παρουσιάζει ένα Single-Layer Feedforward δίκτυο:




μ 4.3 Single-Layer Feedforward δίκτυο.


Πολυστρωματικά feedforward δίκτυα: Ένα πολυστρωματικό feedforward δίκτυο, συχνά γνωστό ως πολυστρωματικό Perceptron (MLP) διακρίνεται από την παρουσία ενός ή περισσότερων κρυμμένων στρωμάτων. Οι κρυμμένοι νευρώνες στα κρυμμένα στρώματα επεμβαίνουν μεταξύ της εξωτερικής εισαγωγής και των αποτελεσμάτων των δικτύων. Η προσθήκη των κρυμμένων στρωμάτων σε MLP αυξάνει την ικανότητά της εξόδου από τα αυστηρά πλαίσια των κανόνων. Αυτό το χαρακτηριστικό γνώρισμα των MLP αυξάνει την ικανότητά τους να εξετάζουν σε υψηλό βαθμό φαινόμενα μη γραμμικότητα και σύνθετων καταστάσεων. Τα MLPs μπορεί να συνδεθούν πλήρως ή να συνδεθούν μερικώς. Στα πλήρως συνδεδεμένα πολυστρωματικά feedforward δίκτυα, κάθε νευρώνας σε κάθε στρώμα συνδέεται με κάθε άλλο νευρώνα στο παρακείμενο μπροστινό στρώμα. Το σχήμα παρουσιάζει ένα πλήρως συνδεδεμένο πολυστρωματικό feedforward δίκτυο. Εάν μερικές συναπτικές συνδέσεις μεταξύ των νευρώνων λείπουν, το δίκτυο καλείται ως μερικώς



συνδεδεμένο feedforward δίκτυο. Το σχήμα παρουσιάζει μερικώς συνδεδεμένο feedforward δίκτυο.




**μ 4.4.** Πλήρως συνδεδεμένο πολυστρωματικό feedforward δίκτυο



**μ 4.4.** Μερικώς συνδεδεμένο πολυστρωματικό feedforward δίκτυο


Επαναλαμβανόμενα δίκτυα: Αντίθετα από ένα feedforward δίκτυο, σε ένα επαναλαμβανόμενο δίκτυο πρέπει να υπάρξει τουλάχιστον ένας ανατροφοδοτούμενος βρόχος. Ένα ή περισσότερα αποτελέσματα του στρώματος εξόδου οδηγούνται πίσω στην είσοδο ή το κρυμμένο στρώμα. Μπορεί να αποτελείται από οποιοδήποτε αριθμό στρωμάτων. Εάν οποιαδήποτε έξοδο οδηγείται πίσω στην είσοδο της, το δίκτυο καλείται επαναλαμβανόμενο δίκτυο με μονή -ανατροφοδότηση. Η ανατροφοδότηση των βρόγχων περιλαμβάνει τη χρήση των στοιχείων καθυστέρησης, η οποία οδηγεί στη μη γραμμική δυναμική συμπεριφορά. Τα στοιχεία καθυστέρησης μονάδων δείχνονται ως  $z^{-1}$ . Η παρουσία ανατροφοδότησης στους βρόχους στο επαναλαμβανόμενο δίκτυο ασκεί βαθιά επίδραση στην εκμάθηση και την απόδοση. Το σχήμα παρουσιάζει ένα επαναλαμβανόμενο δίκτυο :



μ 4.5 επαναλαμβανόμενο δίκτυο

#### 4.2.6

Οι λύσεις με τεχνητά νευρωνικά δίκτυα είναι πολύ ελκυστικές χάρη στην απλότητα και τη σχετική ταχύτητά τους. Αν και ένα ANN μπορεί να λύσει το ιδιαίτερα σύνθετο μη γραμμικό πρόβλημα, η αρχή της εργασίας του είναι πολύ απλή. Η διαδικασία εργασίας ενός πλήρως συνδεδεμένου πολυστρωματικού feedforward δικτύου, που παρουσιάζεται στο σχήμα, περιγράφεται εδώ.



μ 4.6 Νευρωνικό δίκτυο


Το στρώμα εισόδου συνδέεται με ένα παρακείμενο στρώμα, χαρακτηριστικά γνωστό ως κρυμμένο στρώμα, με μερικά συναπτικά βάρη. Οι νευρώνες εισαγωγής ενεργοποιούνται από τα εξωτερικά σήματα εισαγωγής και αυτοί περνούν τα σήματα μέσω των συναπτικών βαρών στο επόμενο στρώμα. Περνώντας μέσω των συναπτικών βαρών, τα σήματα εισαγωγής πολλαπλασιάζονται με τα αντίστοιχα βάρη ( $W_{ji}$ ). Όλα τα σήματα που φθάνουν σε έναν νευρώνα του κρυμμένου στρώματος αθροίζονται, περιγράφονται από την εξίσωση, και μετατρέπονται στην έξοδο εκείνου του νευρώνα μετά από μερικές λειτουργίες ενεργοποίησης.

$$v_j(n) = \sum_{i=1}^n w_{ji}(n) y_i(n)$$

Οι συναρτήσεις  $y$  που χρησιμοποιούνται σε κάθε νευρώνα ονομάζονται συναρτήσεις ενεργοποίησης και η μορφή που επιλέγουμε ποικίλει. Η συνάρτηση ενεργοποίησης παίζει σημαντικό ρόλο και πρέπει να επιλεγεί κατάλληλα ανάλογα με το πρόβλημα που αντιμετωπίζουμε κάθε φορά. Υπάρχουν διάφορες μορφές που συνήθως παίρνει η συνάρτηση ενεργοποίησης όπως γραμμική, βηματική, λογαριθμική, υπερβολική εφαπτομένη.

#### Υπερβολική εφαπτομένη

Μια συνάρτηση ενεργοποίησης που χρησιμοποιείται πολύ συχνά είναι η υπερβολική εφαπτομένη. Τη συνάρτηση αυτή θα χρησιμοποιήσουμε και στο τεχνητό νευρωνικό δίκτυο που θα κάνει πρόβλεψη της κατανομής των απωλειών. Στο παρακάτω διάγραμμα φαίνεται η μορφή της:



**μ 4.7** Συνάρτηση υπερβολικής εφαπτόμενης

### Βηματική συνάρτηση


Σε περιπτώσεις που επιθυμούμε να κάνουμε διαχωρισμό των δεδομένων εισόδου χρησιμοποιούμε τη βηματική συνάρτηση η οποία μπορεί να πάρει δύο μορφές. Η μία είναι η μη συμμετρική και δίνει τιμές 0 ή 1 και η άλλη είναι συμμετρική και δίνει τιμές από το  $-1$  έως το  $+1$ . στο παρακάτω διάγραμμα φαίνονται και οι δύο αυτές συναρτήσεις:



**μ 4.8** Βηματική συνάρτηση

### Λογαριθμική συνάρτηση


Η λογαριθμική συνάρτηση μοιάζει στη μορφή της με τη συνάρτηση της υπερβολικής εφαπτομένης με τη διαφορά ότι λογαριθμική συνάρτηση δίνει τιμές από το 0 έως το 1, ενώ η υπερβολική εφαπτομένη από το  $-1$  έως το 1. Στο παρακάτω διάγραμμα βλέπουμε τη μορφή της λογαριθμικής συνάρτησης



**μ 4.9** Λογαριθμική συνάρτηση

### Γραμμική συνάρτηση

Μια απλή μορφή συνάρτησης ενεργοποίησης είναι η γραμμική. Αυτή έχει την παρακάτω μορφή:

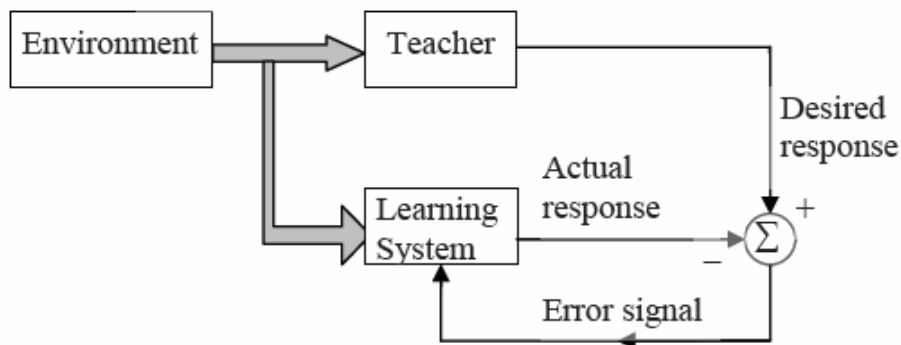


**μ 4.10** Γραμμική συνάρτηση

Συνήθως αποφεύγουμε να χρησιμοποιήσουμε μια τέτοια συνάρτηση ως συνάρτηση ενεργοποίησης, και κυρίως στους κρυμμένους νευρώνες.

#### 4.2.7

Τα νευρωνικά δίκτυα μαθαίνουν μέσα από παραδείγματα, με τρόπο δηλαδή παρόμοιο μ' αυτόν που μαθαίνει ο άνθρωπος. Η βασική ιδέα είναι να τροφοδοτηθεί το δίκτυο με μια σειρά από σήματα εισόδων και τις αντίστοιχες εξόδους που θέλουμε να προκύπτουν ως αποτέλεσμα αυτών των εισόδων. Όπως είδαμε τα βάρη που συνδέουν τους νευρώνες προσαρμόζονται κατά τη διαδικασία της μάθησης έτσι ώστε να ελαχιστοποιείται το σφάλμα ανάμεσα στην πραγματική έξοδο του δικτύου και την αντίστοιχη επιθυμητή. Κατά τη μάθηση τροφοδοτούμε συνεχώς το δίκτυο με το πρότυπο εισόδων-εξόδων. Κάθε πλήρης προβολή του συνόλου εκπαίδευσης καλείται εποχή (epoch). Η εκπαίδευση του δικτύου γίνεται μέσα από διαδοχικές εποχές μέχρι να σταθεροποιηθούν τα βάρη και να συγκλίνει το άθροισμα των τετραγωνικών σφαλμάτων. Η διαδικασία με την οποία γίνεται η εκπαίδευση φαίνεται στο παρακάτω σχήμα:



μ 4.11 Εκπαίδευση νευρωνικού δικτύου.

Υπάρχουν διάφοροι αλγόριθμοι με τους οποίους επιτυγχάνουμε την εκπαίδευση ενός νευρωνικού δικτύου. Ο δημοφιλέστερος από αυτούς είναι ο αλγόριθμος της προς τα πίσω διάδοσης σφάλματος (backpropagation algorithm). Ο αλγόριθμος αυτός είναι μια γενίκευση της μεθόδου μάθησης των Widrow-Hoff που πρώτοι παρουσίασαν αυτή την μέθοδο. Τα διανύσματα εξόδου χρησιμοποιούνται για να εκπαιδεύσουν το δίκτυο μέχρι να μπορέσει αυτό να προσεγγίσει μια συνάρτηση ή να ταξινομήσει τις εισόδους. Υπάρχουν διάφορες τροποποιήσεις του αλγορίθμου, οι οποίες μπορούν να χρησιμοποιηθούν για να καλύψουν τις ανάγκες του εκάστοτε προβλήματος. Οι πιο βασικές από αυτές είναι:

#### 4.2.7. . STEEPEST DECENT TRAINING

Τα βάρη και οι πολώσεις ενημερώνονται στην κατεύθυνση της αρνητικής κλίσης της συνάρτησης απόδοσης. Μια επανάληψη του αλγορίθμου αυτού έχει την παρακάτω μορφή:

$$\Delta w_{pl,qk}^{(n+1)} = l_r \delta_{qk} OUT_{pl} + m \Delta w_{pl,qk}^{(n)} \quad (4.1)$$

$$w_{pl,qk}^{(n+1)} = w_{pl,qk}^{(n)} + \Delta w_{pl,qk}^{(n+1)} \quad (4.2)$$

όπου:

$n$ : ο αύξων αριθμός ανακύκλωσης της διαδικασίας εκπαίδευσης.

$w_{pl,qk}^{(n)}$ : η τιμή του βάρους που συνδέει το νευρώνα  $p$  του στρώματος  $l$  με το νευρώνα  $q$  του στρώματος  $k$  κατά τη διάρκεια της ανακύκλωσης  $n$ .

$\Delta w_{pl,qk}^{(n)}$ : η μεταβολή του βάρους  $w_{pl,qk}$  κατά τη διάρκεια της ανακύκλωσης  $n$ .

$\delta_{qk}$ : ο συντελεστής μεταβολής του νευρώνα  $q$  του στρώματος  $k$

$OUT_{pl}$ : Η έξοδος του νευρώνα  $p$  του στρώματος  $l$ .

$l_r$ : ο ρυθμός μάθησης

$m$ : ο συντελεστής ορμής

Ο τρόπος υπολογισμού του  $\delta$  εξαρτάται από τη θέση του νευρώνα στο δίκτυο. Αν είναι νευρώνας εξόδου τότε το  $\delta$  υπολογίζεται από την παρακάτω σχέση:


$$\delta_{qk} = OUT_{qk} (1 - OUT_{qk}) (OUT_{desired\ qk} - OUT_{qk}) \quad (4.3)$$

Για τους υπόλοιπους νευρώνες χρησιμοποιείται η εξής σχέση:

$$\delta_{pl} = OUT_{pl} (1 - OUT_{pl}) \sum_q \delta_{qk} W_{pl,qk} \quad (4.4)$$

Ο ρυθμός μάθησης είναι μια παράμετρος που ελέγχει το ρυθμό με τον οποίο τα υπολογιζόμενα σφάλματα αλλάζουν τα βάρη του δικτύου. Η επιλογή της παραμέτρου αυτής είναι πολύ σημαντική. Αυτό γιατί ένας μεγάλος ρυθμός μάθησης εξασφαλίζει από τη μια ταχύτητα στη σύγκλιση, όμως υπάρχει από την άλλη ο κίνδυνος να υπερπηδηθεί η θέση ελαχίστου της αντικειμενικής συνάρτησης.

Για παράδειγμα στο παρακάτω σχήμα , με ένα μικρό συντελεστή μάθησης μεταβαίνουμε από τη θέση 1 στη θέση 2 , οδεύοντας προς τη θέση ελαχίστου. Αντίθετα με ένα μεγάλο ρυθμό μάθησης μεταβαίνουμε από τη θέση 1 στη θέση 3 , υπερπηδώντας τη θέση ελαχίστου:



Ο συντελεστής ορμής παίρνει τιμές συνήθως από 0.01 έως 1.0. Ο ρόλος του είναι να επιτρέπει την αξιοποίηση πληροφορίας από προηγούμενες τιμές σφάλματος και να εμποδίζει τον εγκλωβισμό σε τοπικό ελάχιστο.

#### 4.2.7. . $\mu$ $\mu$

Με την παραπάνω μέθοδο, το ποσοστό εκμάθησης κρατιέται σταθερό σε όλη την κατάρτιση. Η απόδοση του αλγορίθμου είναι πολύ ευαίσθητη στον κατάλληλο καθορισμό του ποσοστού εκμάθησης. Εάν το ποσοστό εκμάθησης τίθεται πάρα πολύ υψηλό, ο αλγόριθμος μπορεί να ταλαντευτεί και να γίν ει ασταθής. Εάν το ποσοστό εκμάθησης είναι πάρα πολύ μικρό, ο αλγόριθμος θα πάρει πάρα πολύ χρόνο για να συγκλίνει. Η απόδοση του αλγορίθμου καθόδου μπορεί να βελτιωθεί εάν επιτρέπουμε στο ποσοστό εκμάθησης να αλλάζει κατά τη διάρκεια της διαδικασίας κατά ρισης. Ένα προσαρμοστικό ποσοστό εκμάθησης θα προσπαθήσει να κρατήσει το μέγεθος βημάτων εκμάθησης όσο το δυνατόν μεγαλύτερο συνεχίζοντας την εκμάθηση. Το ποσοστό εκμάθησης γίνεται ανάλογο στην πολυπλοκότητα της τοπικής περιοχής λάθους.

#### 4.2.7. . *Resilient Backpropagation*

Τα πολυστρωματικά δίκτυα χρησιμοποιούν τις sigmoid συναρτήσεις μεταφοράς στα κρυμμένα στρώματα. Αυτές καλούνται συχνά «συμπιεσμένες» , δεδομένου ότι συμπιέζουν μια άπειρη σειρά εισόδου σε μια πεπερασμένη σειρά εξόδου. Οι Sigmoid συναρτήσεις χαρακτηρίζονται από το γεγονός ότι η κλίση τους πρέπει να πλησιάζει μηδέν καθώς η είσοδο παίρνει μεγάλη τιμή. Αυτό δημιουργεί ένα πρόβλημα κατά τη χρησιμοποίηση της απότομης καθόδου για να εκπαιδεύσει ένα πολυστρωματικό δίκτυο με τις sigmoid, δεδομένου ότι η κλίση μπορεί να έχει ένα πολύ μικρό μέγεθος και επομένως, οδηγεί σε μικρές αλλαγές σε βάρη και πολώσεις , ακόμα κι αν αυτά είναι μακριά από τις βέλτιστες τιμές τους.

Ο σκοπός του resilient backpropagation αλγορίθμου εκμάθησης είναι να εξαλειφτούν αυτά τα επιβλαβή αποτελέσματα των μεγεθών των μερικών παραγώγων. Μόνο η ολικότητα της παραγώγου χρησιμοποιείται για να καθορίσει την κατεύθυνση της αναπροσαρμογής του βάρους, το μέγεθος του παραγώγου δεν έχει καμία επίδραση στην αναπροσαρμογή βάρους. Το μέγεθος της αλλαγής βάρους καθορίζεται από μια χωριστή αξία αναπροσαρμογών. Η αξία αναπροσαρμογών για κάθε βάρους και πόλωση αυξάνεται από έναν παράγοντα  $\text{delt\_inc}$  όταν η παράγωγος της συνάρτησης απόδοσης σε εκείνο το βάρους έχει την ίδια ολικότητα για δύο διαδοχικές επαναλήψεις. Η νέα αξία μειώνεται από έναν παράγοντα  $\text{delt\_dec}$  όταν η παράγωγος της συνάρτησης στο αντίστοιχο βάρους διαφέρουν από την προηγούμενη επανάληψη. Εάν η παραγωγός είναι μηδέν, η αξία αναπροσαρμογών παραμένει η ίδια. Όποτε τα βάρη ταλαντεύονται η τιμή της αλλαγής βάρους θα μειωθεί. Εάν το βάρους συνεχίσει να αλλάζει στην ίδια κατεύθυνση για διάφορες επαναλήψεις, η τιμή της αλλαγής βάρους θα αυξηθεί.

#### 4.2.7. . Conjugate Gradient Algorithms

Ο βασικός backpropagation αλγόριθμος ρυθμίζει τα βάρη στην steepest decent κατεύθυνση (αρνητική της κλίσης). Αυτό είναι η κατεύθυνση στην οποία η συνάρτηση λειτουργίας μειώνεται πιο γρήγορα. Προκύπτει ότι, αν και η συνάρτηση μειώνεται γρήγορα κατά μήκος του αρνητικού της κλίσης, αυτό δεν παράγει απαραίτητως τη γρηγορότερη σύγκλιση. Στους συζευγμένους αλγορίθμους κλίσης μια αναζήτηση εκτελείται κατά μήκος των συζευγμένων κατευθύνσεων, η οποία παράγει τη γενικά γρηγορότερη σύγκλιση σε σχέση με την μέθοδο που αναφέραμε αρχικά. Υπάρχουν διάφορες παραλλαγές των συζευγμένων αλγορίθμων κλίσης. Στους περισσότερους από τους αλγορίθμους εκμάθησης που συζητήσαμε μέχρι αυτό το σημείο, ένας ρυθμός εκμάθησης χρησιμοποιείται για να καθορίσει το μήκος της αναπροσαρμογής βάρους (μέγεθος βημάτων). Στους συζευγμένους αλγορίθμους κλίσης, το μέγεθος βημάτων ρυθμίζεται σε κάθε επανάληψη. Μια αναζήτηση γίνεται κατά μήκος της συζευγμένης κατεύθυνσης κλίσης για να καθορίσει το μέγεθος βημάτων, το οποίο ελαχιστοποιεί τη συνάρτηση απόδοσης σύμφωνα με εκείνη την γραμμή. Απλά ονομαστικά τέσσερις από τις παραλλαγές του conjugate gradient αλγορίθμου είναι:

- A) Fletcher-Reeves Update.
- B) Polak-Ribière Update.
- C) Powell-Beale Restarts.
- D) Scaled Conjugate Gradient.

#### 4.2.7. . Quasi-Newton Algorithms

Η μέθοδος Newton είναι μια εναλλακτική λύση στις συζευγμένες μεθόδους κλίσης για τη γρήγορη βελτιστοποίηση. Το βασικό βήμα της μεθόδου Newton είναι

$$x_{k+1} = x_k - A_k^{-1} g_k \quad (4.5)$$



Οπου  $A_k$  είναι η Hessian μήτρα (δεύτερες παράγωγοι) του δείκτη απόδοσης στις τρέχουσες τιμές των βαρών και των πολώσεων. Η μέθοδος Newton συγκλίνει συχνά γρηγορότερα από τις συζευγμένες μεθόδους κλίσης. Δυστυχώς, είναι σύνθετο και ακριβό να υπολογιστεί η Hessian μήτρα για feedforward τα νευρικά δίκτυα. Υπάρχει μια κατηγορία αλγορίθμων που είναι βασισμένη στη μέθοδο Newton, αλλά που δεν απαιτεί τον υπολογισμό των δευτέρων παραγώγων. Αυτοί καλούνται quasi-Newton (ή secant) μέθοδοι. Υπολογίζουν κατά προσέγγιση την Hessian μήτρα σε κάθε επανάληψη του αλγορίθμου. Η αναπροσαρμογή υπολογίζεται ως συνάρτηση της κλίσης. Η quasi-Newton μέθοδος που είναι η πιο επιτυχημένη στις δημοσιευμένες μελέτες είναι η (BFGS) αναπροσαρμογή.

#### 4.2.7. . Levenberg-Marquardt $\mu$

Η μαθηματική μορφή μιας επανάληψης του αλγορίθμου αυτού είναι η εξής:

$$x_{k+1} = x_k - (H + \mu I)g \quad (4.6)$$

Όπου:

- $X_k$  είναι το άνωσμα των βαρών και των πολώσεων του δικτύου.
- $H$  είναι η μήτρα των δευτέρων παραγώγων ( Hessian matrix).
- $I$  είναι ο μοναδιαίος πίνακας.
- $g$  είναι η κλίση gradient.
- $\mu$  είναι ένας συντελεστής που καθορίζει το μέγεθος κάθε βήματος.

Η μήτρα  $H$  υπολογίζεται από την ακόλουθη σχέση:

$$H = J^T J$$

Όπου η μήτρα  $J$  είναι η Ιακωβιανή που περιέχει τις πρώτες παραγώγους της συνάρτησης σφάλματος ως προς τα βάρη και τις πολώσεις του δικτύου.

Η κλίση μπορεί να υπολογισθεί από τη σχέση:

$$g = J^T e$$

Όπου το  $e$  είναι ένα διάνυσμα των σφαλμάτων του δικτύου.

Έτσι μια επανάληψη του αλγορίθμου θα έχει τη μορφή:

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (4.7)$$


Όταν ο συντελεστής  $\mu$  είναι 0 τότε ο αλγόριθμος εκφυλίζεται σε μορφή αλγορίθμου Newton. Όταν είναι μεγάλο τότε μειώνεται και το βήμα της κάθε επανάληψης. Έτσι το  $\mu$  μειώνεται μετά από κάθε επιτυχές βήμα και αυξάνεται μετά από ένα ανεπιτυχές βήμα.

#### 4.2.8

Η διαδικασία της εκπαίδευσης αποσκοπεί στην ελαχιστοποίηση του σφάλματος ανάμεσα στην επιθυμητή έξοδο του δικτύου και στην αντίστοιχη πραγματική. Όμως το να επιτύχουμε ένα πολύ μικρό σφάλμα δε σημαίνει απαραίτητα ότι έχουμε καταφέρει να δημιουργήσουμε ένα λειτουργικό μοντέλο που να ικανοποιεί τις απαιτήσεις μας με δεδομένα που βρίσκονται εκτός από το σύνολο μάθησης. Για να είναι το νευρωνικό δίκτυο επιτυχημένο πρέπει να έχει την ικανότητα της γενίκευσης. Αυτό σημαίνει ότι πρέπει να δίνει ακριβείς εξόδους και όταν δέχεται δεδομένα εισόδων εκτός του συνόλου μάθησης.

Ένα πρόβλημα που συναντάται συχνά κατά τη σχεδίαση και εκπαίδευση ενός νευρωνικού δικτύου είναι η υπερπροσαρμογή (overfitting), η απομνημόνευση δηλαδή του συνόλου μάθησης. Αυτό που επιδιώκουμε με τα τεχνητά νευρωνικά δίκτυα δεν είναι η απεικόνιση των δεδομένων εισόδων στα αντίστοιχα δεδομένα εξόδου μέσα από μια διαδικασία απομνημόνευσης. Αντίθετα θέλουμε μέσα από τα βάρη που ενώνουν τους νευρώνων να ευρεθούν πρότυπα ( patterns) και συσχετίσεις ανάμεσα σε εισόδους και εξόδους.

Στο παρακάτω σχήμα βλέπουμε ένα παράδειγμα σωστής προσαρμογής με τις διακεκομμένες γραμμές και ένα παράδειγμα υπερπροσαρμογής όπου φαίνεται με τη συνεχή γραμμή:



Μια μέθοδος για τη γενίκευση δικτύων είναι να χρησιμοποιηθεί ένα δίκτυο που είναι ακριβώς αρκετά μεγάλο ώστε να παρέχει μια επαρκή ταυτοποίηση. Όσο μεγαλύτερο είναι ένα δίκτυο που χρησιμοποιούμε, τόσο πιο σύνθετες είναι οι συναρτήσεις που το δίκτυο μπορεί να δημιουργήσει. Εάν χρησιμοποιούμε ένα αρκετά μικρό δίκτυο, δεν θα έχει αρκετή ισχύ στο να συνδυάσει τα στοιχεία. Δυστυχώς, είναι δύσκολο να είναι γνωστό εκ των προτέρων πόσο μεγάλο ένα δίκτυο πρέπει να είναι για μια συγκεκριμένη εφαρμογή. Μπορεί να γίνει βελτίωση του δικτύου με συνεχείς δόκιμες στο σύνολο εκπαίδευσης όμως αυτή είναι μια επίπονη διαδικασία που δεν εξασφαλίζει και σίγουρα αποτελέσματα.

Υπάρχουν ωστόσο και δύο άλλοι τρόποι για να βελτιώσουμε τη γενίκευση. Αυτοί είναι η κανονικοποίηση και το έγκαιρο σταμάτημα στην εκπαίδευση στις οποίες υπάρχει εκτενή αναφορά παρακάτω. Σημειώνουμε ότι εάν ο αριθμός των παραμέτρων στο δίκτυο είναι πολύ μικρότερος από το συνολικό αριθμό των σημείων στο σύνολο εκμάθησης, τότε υπάρχει ελάχιστη ή καμία πιθανότητα για overfitting. Εάν μπορούν εύκολα να συλλεχθούν περισσότερα στοιχεία και να αυξηθεί το μέγεθος του συνόλου εκπαίδευσης, τότε δεν υπάρχει κανένα ενδιαφέρον για τις παρακάτω μεθόδους που εμποδίζουν την υπερπροσαρμογή. Αν όμως δεν υπάρχει περιθώριο συλλογής δεδομένων τότε οι δυο μέθοδοι είναι αναγκαίες :

### (Regularization)

Η μέθοδος αυτοί περιλαμβάνει την τροποποίηση της συνάρτησης απόδοσης (performance function), η οποία συνήθως είναι το άθροισμα των τετραγωνικών σφαλμάτων ανάμεσα στις εξόδους του δικτύου που δημιουργήσαμε και τις πραγματικές τιμές που αναμένουμε. Ένας τρόπος που φαίνεται πως μπορεί να τροποποιηθεί η συνάρτηση επίδοσης έτσι ώστε να βελτιωθεί η ικανότητα του δικτύου για γενίκευση παρουσιάζεται :

$\mu$

Η τυπική συνάρτηση απόδοσης που χρησιμοποιείται κατά την εκπαίδευση των δικτύων εμπρόσθιας τροφοδότησης έχει τη μορφή:

$$mse = \frac{1}{N} \sum_{i=1}^N (T_i - A_i)^2 \quad (4.8)$$

όπου  $A_i, T_i$  είναι οι τιμές εξόδου του δικτύου και οι επιθυμητές αντίστοιχα.

Μπορούμε να τροποποιήσουμε την παραπάνω συνάρτηση και να συμπεριλάβουμε σ' αυτήν τη μέση τιμή των τετραγώνων των παραμέτρων του δικτύου (βάρη και πλώσεις). Τότε η συνάρτηση απόδοσης θα έχει τη μορφή :

$$msreg = \gamma * mse + (1 - \gamma) * msw \quad (4.9)$$

όπου ο συντελεστής  $\gamma$  είναι ένας συντελεστής απόδοσης στο διάστημα  $[0,1]$  και ισχύει:

$$msw = \frac{1}{N} \sum_{i=1}^N W_i^2 \quad (4.10)$$

Χρησιμοποιώντας αυτή τη συνάρτηση οδηγούμε το δίκτυο στο να έχει μικρότερα βάρη και πολώσεις και ως εκ τούτου να αποκρίνεται ομαλότερα στις εισόδους οδηγώντας σε μικρότερη πιθανότητα για υπερπροσαρμογή.


$\mu$

Είναι πολλές φορές επιθυμητό να καθορίσουμε τις βέλτιστες παραμέτρους κανονικοποίησης με έναν αυτόματο τρόπο. Μια προσέγγιση σ' αυτό το πρόβλημα είναι η Bayesian. Σ' αυτή την προσέγγιση τα βάρη και οι πολώσεις θεωρούνται τυχαίες μεταβλητές με συγκεκριμένες κατανομές. Οι παράμετροι κανονικοποίησης σχετίζονται με τις άγνωστες μεταβλητότητες αυτών των κατανομών. Με στατιστικές τεχνικές μπορούμε να εκτιμήσουμε αυτές τις τιμές των παραμέτρων.

$\mu \quad \mu$  (early stopping)

Μια άλλη μέθοδος για να βελτιώσουμε τη γενίκευση είναι το έγκαιρο σταμάτημα της εκπαίδευσης. Σ' αυτή την τεχνική τα δεδομένα χωρίζονται σε τρεις κατηγορίες. Η πρώτη ομάδα δεδομένων είναι τα δεδομένα που θα χρησιμοποιηθούν για την εκπαίδευση του δικτύου. Η δεύτερη ομάδα είναι τα δεδομένα που χρησιμοποιούνται για validation. Αρχικά των σφάλμα στη δεύτερη ομάδα θα μειώνεται ταυτόχρονα με το σφάλμα στην πρώτη ομάδα. Καθώς όμως προχωρεί η διαδικασία της εκπαίδευσης, το δίκτυο αρχίζει να κάνει υπερπροσαρμογή και έτσι παρατηρείται το μεν σφάλμα στα δεδομένα εκπαίδευσης να μειώνεται και το σφάλμα στα δεδομένα ελέγχου να αυξάνεται. Τότε είναι η κατάλληλη στιγμή για να σταματήσουμε τη διαδικασία εκπαίδευσης. Το τρίτο σετ δεδομένων δε χρησιμοποιείται στη διαδικασία της εκπαίδευσης αλλά μετά, με στόχο να συγκριθούν διαφορετικές δομές νευρωνικών δικτύων.

Το έγκαιρο σταμάτημα μπορεί να χρησιμοποιηθεί με οποιοσδήποτε από τις συναρτήσεις εκπαίδευσης που περιγράφηκαν νωρίτερα σε αυτό το κεφάλαιο. Πρέπει απλά να περαστούν τα στοιχεία του συνόλου στη συνάρτηση. Μια βελτιστοποίηση των αποτελεσμάτων του δικτύου με την χρήση του early stopping φαίνεται στο σχήμα:



#### 4.2.9 μ - μ -

Η κλιμάκωση των μεταβλητών έχει ως στόχο την κανονικοποίηση τους και είναι απαραίτητη στα τεχνητά νευρωνικά δίκτυα για τους εξής λόγους:

- Αποφεύγεται η πιθανότητα το δίκτυο να συντονισθεί σε μια συγκεκριμένη περιορισμένη περιοχή των δεδομένων εισόδου-εξόδου.
- Κλιμακώνονται οι τιμές εισόδου στους νευρώνες ώστε να βρίσκονται εντός της περιοχής λειτουργίας. Εάν θεωρήσουμε για παράδειγμα ότι η συνάρτηση των νευρώνων είναι μη συμμετρική (π.χ.σιγμοειδής), στο διάστημα  $[0,1]$  τότε οι εισόδοι που βρίσκονται έξω από την περιοχή λειτουργίας θα οδηγήσουν το νευρώνα στην τιμή 1 ή στην τιμή 0. Η παράγωγος τότε της σιγμοειδούς θα είναι ίση με μηδέν και δεν θα μπορεί να συνεχιστεί η μάθηση. Θα έχουμε δηλαδή παράλυση του δικτύου.
- Η απ' ευθείας τροφοδότηση του δικτύου με τις πρωτογενείς τιμές των μεταβλητών εισόδου θα έχει ως αποτέλεσμα μεγάλες διαφορές στις περιοχές τιμών ανάμεσα στις αντίστοιχες εισόδους. Τις διαφορές αυτές το δίκτυο θα μπορούσε να τις εκλάβει ως σημαίνουσες τη βαρύτητα των αντίστοιχων εισόδων. Τότε το μοντέλο θα εξαρτάται σημαντικά από τις μεταβλητές με υψηλές τιμές και λιγότερο από τις μεταβλητές με χαμηλές τιμές. Αυτό όμως δεν είναι πληροφοριακά σωστό, γιατί οι υψηλές τιμές που μπορεί να πάρει μια μεταβλητή εισόδου δεν συνεπάγονται και μεγαλύτερη εξάρτηση της εξόδου από την μεταβλητή αυτή.

Επιδιώκουμε λοιπόν να μετασχηματίσουμε τις μεταβλητές εισόδου με τέτοιο τρόπο ώστε να έχουν μηδενική μέση τιμή και μοναδιαία τυπική απόκλιση. Με την βοήθεια του matlab και των συναρτήσεων του μπορούμε εύκολα να επιτύχουμε την επεξεργασία των αρχικών δεδομένων. Οι τρεις βασικές ομάδες συναρτήσεων που χρησιμοποιούνται στο στάδιο της επεξεργασίας είναι :

**a) Min and Max (premmx, postmmx, trammx)**

Τα δεδομένα επεξεργάζονται με τέτοιο τρόπο ώστε η μέγιστη ένδειξη να παίρνει την τιμή 1 και η ελάχιστη την τιμή -1. Κατόπιν οι νέες τιμές καλούνται από το δίκτυο και τα αποτελέσματα της εξόδου ξανά επεξεργάζονται ώστε να επιστρέψουν στην αρχική τους μορφή.

**b) Mean and Stand. Dev. (prestd, poststd, trastd)**

Τα δεδομένα επεξεργάζονται ώστε η μέση τιμή των δεδομένα να είναι 0 και η τυπική απόκλιση να λάβει την τιμή 1. Τα αποτελέσματα της εξόδου υπόκεινται στην αντίθετη διαδικασία όπως αναφέρθηκε και στον πρώτο τρόπο επεξεργασίας .

**c) Principal Component Analysis (prepc, trapca)**

Πρόκειται για μια πρωταρχική βασική επεξεργασία ώστε τα μεγέθη που συμβάλουν στην δημιουργία του δικτύου να είναι ασυσχέτιστα μεταξύ τους. Όσα δεδομένα θεωρούνται ότι συσχετίζονται μεταξύ τους τότε απομακρύνονται από το σύνολο εκπαίδευσης .

**4.2.10 μ**

Τέλος σαν επίλογος στην θεωρία των νευρωνικών αναφέρουμε βιβλιογραφικά μερικές εφαρμογές των νευρωνικών στην σύγχρονη εποχή. Αν και η έρευνα για τα τεχνητά νευρικά δίκτυα είχε αρχίσει στις πρώτες δεκαετίες του 20ου αιώνα, η ανάπτυξη και η εφαρμογή ήταν πολύ περιορισμένες πριν από την εμφάνιση των προσωπικών Η/Υ. Η ανάπτυξη των νευρικών δικτύων παρατηρήθηκε τις τελευταίες δύο δεκαετίες. Σήμερα, τα τεχνητά νευρικά δίκτυα έχουν χρησιμοποιηθεί σε μια ευρεία ποικιλία των προβλημάτων του πραγματικού κόσμου. Πολλά σύνθετα προβλήματα που απαιτούν τους χρονοβόρους υπολογισμούς έχουν λυθεί από τα τεχνητά νευρικά δίκτυα με έναν απλούστερο και γρηγορότερο τρόπο. Τα δίκτυα είχαν άμεση εφαρμογή στην επεξεργασία εικόνας, παραδείγματος χάριν, προσδιορίζοντας τους χειρόγραφους χαρακτήρες, ταιριάζοντας μια φωτογραφία ενός πρόσωπου με μια διαφορετική φωτογραφία σε μια βάση δεδομένων, εκτέλεση της συμπίεσης στοιχείων σε μια εικόνα με την ελάχιστη απώλεια περιεχομένου κ.α. Άλλες εφαρμογές είναι: η αναγνώριση φωνής, η ανάλυση των δεδομένων PANTAP , η πρόβλεψη χρηματιστηρίου, η πρόβλεψη καιρού, η πρόβλεψη ηλεκτρικού φορτίου , στα διαγνωστικά μηχανών, στη διαχείριση χαρτοφυλακίων, στην αναγνώριση στόχων, στην ιατρική διάγνωση, στη στοχοθετημένο μάρκετινγκ, στον ποιοτικό έλεγχο, στην ευφυή έρευνα . Όλα αυτά τα προβλήματα περιλαμβάνουν μεγάλο πλήθος δεδομένων και σύνθετες σχέσεις μεταξύ των διαφορετικών παραμέτρων. Στις μέρες μας , έχουν χρησιμοποιηθεί στα συστήματα ελέγχου, συστήματα προστασίας και σε πολλές στρατιωτικές εφαρμογές. Το νευρωνικό δίκτυο αποδείχθηκε ελπιδοφόρο στη χρήση του στα συστήματα ελέγχου και τις ρομποτικές εφαρμογές. Οι άνθρωποι προσπαθούν να χτίσουν την τεχνητή νοημοσύνη με την ικανότητα ενός ανθρώπινου εγκεφάλου χρησιμοποιώντας τα νευρικά δίκτυα. Ο στόχος αυτής της

μελέτης είναι να αναπτυχθεί ένα νευρικό δίκτυο ως εργαλείο για να κατανέμει την απώλεια μεταφοράς σε ένα ηλεκτρικό σύστημα.

### 4.3

### CPP

Μετά την περιγραφή του τρόπου λειτουργίας του νευρωνικού δικτύου, το εφαρμόζουμε στο πρόβλημα CPP όπως αναφέραμε στην εισαγωγή και με την σειρά καθορισμού των βημάτων που είδαμε στη θεωρία των νευρωνικών.

#### 4.3.1

μ

Για τον καθορισμό του νευρωνικού δικτύου που θα χρησιμοποιήσουμε πρέπει αρχικά να επιλέξουμε τον αλγόριθμο που θα χρησιμοποιήσουμε για να πάρουμε τα αποτελέσματα που θα εφαρμοστούν στην εκπαίδευση αλλά και στον έλεγχο του νευρωνικού. Αυτό είναι το προπαρασκευαστικό στάδιο πριν την ανάπτυξη του ANN. Επιλέγουμε από τις δυο μεθόδους που αναπτύχθηκαν παραπάνω αυτή των γενετικών αλγορίθμων αλλά με μια μικρή τροποποίηση στην διαδικασία της διασταύρωσης. Η εφαρμογή δεν γίνεται επιλέγοντας τη multipoint διασταύρωση δηλαδή την τυχαίου σημείου διασταύρωση αλλά την single point, δηλαδή σε ένα δεδομένο σημείο που στην περίπτωση επιλεχθεί το μεσαίο ακριβώς.

#### 4.3.2

-

μ

-

Μετά τον ορισμό του αλγόριθμου που θα χρησιμοποιήσουμε για να πάρουμε τα αποτελέσματα της ρύθμισης του νευρωνικού καθορίζουμε ποια από τα δεδομένα θα χρησιμοποιήσουμε στην εφαρμογή. Αρχικά επιλέγουμε το δίκτυο που γίνεται η μελέτη μας. Για λόγους ομοιομορφίας και καλύτερης επεξεργασίας των αποτελεσμάτων επιλέγουμε το δίκτυο IEEE-15 ζυγών που είδαμε και στις προηγούμενες εφαρμογές. Σαν στοιχεία εισόδου καθορίζουμε όλες τις εγχύσεις άεργου και ενεργού ισχύος από τους ζυγούς του δικτύου, αφού αυτά μεταβάλλονται δυναμικά κατά τη διάρκεια του χρόνου. Πρόκειται δηλαδή στην περίπτωση μας για  $2 \times 14 = 28$  μεταβλητές εισόδου. Ως στοιχεία εξόδου επιλέγονται τα μεγέθη των πυκνωτών στους επιθυμητούς ζυγούς. Επειδή οι ζυγοί αυτοί είναι συνολικά πέντε, τόσες είναι και οι τιμές των μεταβλητών εξόδου.

Το επόμενο στάδιο είναι ο καθορισμός του εύρους των τιμών των εγχύσεων ενεργού και άεργου ισχύος, δηλαδή σε ποιο όριο κυμαίνονται αυτές οι τιμές. Επιλέξαμε ένα μικρό περιθώριο εύρους δηλαδή, 90%-110% της βασικής τιμής ισχύος που λαμβάνουμε από τα δεδομένα. Η παραγωγή των δεδομένων αυτών προέρχεται στην πράξη από χρονοσειρές ή προβλέψεις που παρέχουν την τιμή του φορτίου κάθε στιγμή. Στην εφαρμογή μας έγινε με την βοήθεια μίας συνάρτησης


τυχαιοτητας η παραγωγή των τιμών του φορτίου. Για τις τιμές εξόδου αναμένουμε τιμές εγχύσεως από 0 έως 400 Kvar σε κάθε ένα από τους πέντε ζυγούς .

Μετά την επιλογή των δεδομένων εισόδου – εξόδου αυτά υπόκεινται σε επεξεργασία πριν την εφαρμογή τους στο νευρωνικό δίκτυο .Αρχικά ελέγχουμε αν κάποια από τα στοιχεία εισόδου είναι εκτός των ορίων που ορίστηκαν παραπάνω (δηλαδή στο εύρος 0,9P-1,1P). Αν βρεθεί κάποιο, αυτό απομακρύνεται από τα δεδομένα . Κατόπιν ακολουθεί η διαδικασία επεξεργασίας που επιλέγεται για τα δεδομένα εισόδου και στην εφαρμογή μας είναι αυτή της κανονικοποίησης με βάση την κανονική κατανομή. Όλα τα δεδομένα παίρνουν τις νέες τους τιμές στο διάστημα [-1,1]. Η ακριβώς αντίστροφη διαδικασία ακολουθείται για τα στοιχεία εξόδου ώστε από το εύρος τιμών [-1,1] που είναι αρχικά , να πάρουν τις διακριτές τιμές 0...4.

### 4.3.3

Μετά τον καθορισμό των εισόδων-εξόδων ,σειρά έχει ο ορισμός του ενδιάμεσου βήματος δηλαδή ο καθορισμός των νευρώνων και των επιπέδων που θα περιλαμβάνει το ANN. Αρχικά τίθεται το ερώτημα του αριθμού των επιπέδων. Επιλέγεται ένα κρυφό επίπεδο (layer) γιατί το πρόβλημα δεν είναι σύνθετο στα δεδομένα εξόδου και δεν απαιτούν ιδιαίτερη επεξεργασία. Για τον αριθμό των νευρώνων στο ένα κρυφό επίπεδο χρησιμοποιούμε την τεχνική των συνεχών επαναλήψεων.

Αρχίζοντας από την επιλογή 10 νευρώνων μέχρι την επιλογή 20 νευρώνων έχουμε το διάγραμμα :



**μ 4.12** Επιλογή αριθμού νευρώνων-Απόδοση




Ο οριζόντιος άξονας είναι ο αριθμός των κρυμμένων νευρώνων. Ο κατακόρυφος είναι το ποσοστό επιτυχίας του αλγόριθμου. Το αποτέλεσμα αυτό προκύπτει με την ολοκλήρωση της διαδικασίας του αλγόριθμου που περιγράφεται στα επόμενα στάδια. Απλά εδώ παρουσιάζεται η μεταβολή των αποτελεσμάτων του αλγόριθμου συναρτήσει των νευρώνων ώστε να επιλέγει ο αριθμός αυτών . Με βάση το διάγραμμα ,αν και η διάφορα είναι πολύ μικρή στην απόδοση ,επιλέγουμε  $N=10$ .

#### 4.3.4

Το νευρωνικό δίκτυο που εφαρμόζουμε για την επιλογή των πυκνωτών εκπαιδεύεται χρησιμοποιώντας την μέθοδο backpropagation και συγκεκριμένα με τη μέθοδο gradient descent. Πρόκειται για μια απλή μέθοδο που δίνει παρόμοια αποτελέσματα με τις άλλες όπως είναι οι: Levenberg-Marquardt, Resilient Backpropagation κ.α.

Τα διαθέσιμα δεδομένα χωρίζονται σε δυο ομάδες. Η πρώτη ομάδα είναι το σύνολο των δεδομένων της εκπαίδευσης ( training data) και αποτελείται από τις τιμές 4000 περιπτώσεων εισόδου-εξόδου που έχουμε συλλέξει με την μέθοδο GA.Αυτή η ομάδα ταυτόχρονα αποτελεί και ομάδα έλεγχου ( testing data) αφού τις τιμές εισόδου τις επανατοποθετούμε στο νευρωνικό και συγκρίνουμε τις τιμές εξόδου του νευρωνικού με το αρχείο των εξόδων που έχουμε υπολογίσει αρχικά. Η δεύ τερη ομάδα (testing data) αποτελείται από 50 τιμές εισόδου –εξόδου που έχουμε υπολογίσει και οι οποίες είναι διαφορετικές από τις τιμές του πρώτου αρχείου δεδομένων. Το δεύτερο αυτό αρχείο είναι απαραίτητο γιατί έτσι αποφεύγουμε την περίπτωση της προσαρμογής ,αφού αν χρησιμοποιούσαμε μόνο το αρχείο εκπαίδευσης ως αρχείο έλεγχου τότε μπορεί να συνέπιπτε η ομοιότητα στα αποτελέσματα. Παίρνοντας όμως διαφορετικές τιμές σαν είσοδο αποφεύγουμε αυτή την πιθανότητα.


Από τις συναρτήσεις συμμετοχής των νευρώνων που υπάρχουν επιλέγουμε την tansig:



ενώ ρυθμίζεται και ο ρυθμός εκμάθησης του νευρωνικού ( learning rate) στην τιμή 0,01 και η σταθερά βήματος (momentum rate) ίση με 0,8.

Για την πιο γρήγορη προσαρμογή των νευρωνικών στην εφαρμογή μας χρησιμοποιούμε αρχικές τιμές για τους νευρώνες κάθε layer που προέρχονται από τον αλγόριθμο αρχικοποίησης Nguyen-Widrow . Με τον τρόπο αυτό επιτυγχάνουμε την γρηγορότερη ρύθμιση των βαρών κάθε νευρώνα όποτε και βέλτιστη επίλυση .

Για να βελτιώσουμε την ικανότητα των τεχνητών νευρωνικών δικτύων για γενίκευση επιλέγουμε τη μέθοδο του έγκαιρου σταματήματος της διαδικασίας της εκπαίδευσης, η οποία αναπτύσσεται στο κεφάλαιο θεωρίας . Συγκεκριμένα το δίκτυο μας εκπαιδεύεται με βήμα 5 εποχών , υπολογίζεται το μέσο τετραγωνικό σφάλμα (MSE) που προκύπτει από τα δεδομένα επαλήθευσης και αν βρεθεί μικρότερο τότε σταματά η διαδικασία. Όμως ορίζουμε και ένα αριθμό επαναλήψεων ώστε ακόμη και αν το όριο του μέσου τετραγωνικού σφάλματος να μην έχει επιτευχθεί η διαδικασία να σταματά. Παράλληλα υπάρχει ένα ανώτατο επιτρεπόμενο όριο του πλήθους των εποχών ,ώστε να μην οδηγηθούμε σε μια ατέρμονη διαδικασία. Με αυτόν τον τρόπο , όχι μόνο αποφεύγουμε το ενδεχόμενο απομνημόνευσης των δεδομένων της εκπαίδευσης , αλλά ταυτόχρονα καθιστούμε τη διαδικασία της εκπαίδευσης λιγότερο χρονοβόρα. Παρακάτω φαίνεται το διάγραμμα που δείχνει πως μεταβάλλεται το μέσο τετραγωνικό σφάλμα μετά από την εκπαίδευση του δικτύου :



μ 4.13 Καμπύλη σφάλματος –αριθμού επαναλήψεων

Παρατηρούμε ότι το μέσο τετραγωνικό σφάλμα, των δεδομένων εκπαίδευσης αρχικά μειώνεται απότομα και στη συνέχεια με αργότερους ρυθμούς. Μετά από κάποιο σημείο, υπάρχει ελάχιστη πτώση στο τετραγωνικό σφάλμα και αυτό σημαίνει ότι η διαδικασία δεν βελτιώνεται και άλλο οπότε και πρέπει να σταματήσει.

#### 4.3.5

μ

Μετά τη λειτουργία του νευρωνικού ελέγχουμε την αξιοπιστία και τον τρόπο που μπορούμε να εκμεταλλευτούμε τα αποτελέσματα που εξέρχονται από αυτό. Για το σκοπό αυτό χρησιμοποιούμε και τα δυο αρχεία δεδομένων Train Data και Test Data. Ελέγχουμε για τα δυο αρχεία αν τα αποτελέσματα του νευρωνικού συμπίπτουν με αυτά που αναμέναμε και τα οποία έχουν προέλθει από τον γενετικό αλγόριθμο. Επειδή τα αποτελέσματα που προέρχονται από την εφαρμογή δεν είναι ακέραιοι αριθμοί, αρχικά τα στρογγυλοποιούμε και παίρνουμε τους αντιστοίχους ακέραιους. Η σύγκριση όμως με το αρχείο δεδομένων δεν είναι δυνατή γιατί η πράξη της στρογγυλοποίησης έχει οδηγήσει σε αλλοίωση των αποτελεσμάτων. Ένας τρόπος να ξεπεράσουμε την αυθαιρεσία της στρογγυλοποίησης είναι να λάβουμε υπόψη την διακύμανση των μετρήσεων.

Για την διακύμανση των μετρήσεων θεωρούμε την τιμή 0,5 όπου είναι το μέγιστο της στρογγυλοποίησης που έχει επιτευχθεί με τον αλγόριθμο της στρογγυλοποίησης. Η διαδικασία που ακολουθείται για την αξιολόγηση των αποτελεσμάτων είναι η εξής:

- a. Ελέγχουμε αν το τελικό αποτέλεσμα που προκύπτει από το ANN είναι ίδιο με το επιθυμητό.
- b. Αν δεν είναι τότε εκτελούμε την εξής διαδικασία:
  1. Αν το αποτέλεσμα του νευρωνικού, προστιθέμενο στην διακύμανση 0,5 και μετά στρογγυλοποιούμενο είναι διαφορετικό από το αρχικό στρογγυλοποιούμενο τότε θέτουμε και αυτό σαν εναλλακτική λύση.
  2. Αν το αποτέλεσμα του νευρωνικού, αφαιρούμενο της διακύμανσης 0,5 και κατόπιν στρογγυλοποιούμενο είναι διαφορετικό από το αρχικό στρογγυλοποιούμενο, τότε τίθεται και αυτό σαν υποψήφια λύση.

Έτσι για την επιλογή των πυκνωτών σε κάθε νευρώνα έχουμε στην χειρότερη περίπτωση δυο εναλλακτικές. Την αρχική τιμή που προήλθε από την στρογγυλοποίηση και την πιο κοντινή ακέραια τιμή. Οπότε ο αριθμός των εναλλακτικών που πρέπει να ελέγξουμε σε όλη την εφαρμογή είναι στη χειρότερη  $2^k$  όπου  $k$  λαμβάνεται ο αριθμός των θέσεων πυκνωτή. Στην μελέτη που γίνεται όπου είναι 5 οι υποψήφιας θέσεις του πυκνωτή τότε οι εναλλακτικές είναι 32. Αυτή η τιμή

είναι πολύ μικρή συγκρινόμενη με τις 500 επαναλήψεις που απαιτούνται για την εξεύρεση των αποτελεσμάτων με την χρήση των γενετικών αλγόριθμων.

Μπορεί ο αριθμός των επαναλήψεων να είναι πολύ μικρότερος με την χρήση νευρωνικών όποτε και ο χρόνος εξεύρεσης λύσης , όμως πρέπει να ελεγχθεί αν ο αλγόριθμος είναι εφαρμόσιμος , δηλαδή αν τα αποτελέσματα που προκύπτουν μετά από αυτή τη διαδικασία είναι ίδια με αυτά που επιθυμούσαμε. Συγκρίνουμε αρχικά τα αποτελέσματα με την βοήθεια του Train Data. Τα αποτελέσματα που συμπίπτουν είναι τα επιθυμητά με ποσοστό :

89,5% (17.782/20.000)

Κατόπιν την ίδια διαδικασία την ακολουθούμε για το αρχείο Test Data όπου τα δεδομένα είναι τελείως διαφορετικά από αυτά του Train Data ώστε να αποφευχθεί το πρόβλημα της προσαρμογής .Στην περίπτωση αυτή ο αριθμός των αποτελεσμάτων που είναι σύμφωνα με τα επιθυμητά είναι :

86,4% (216/250)

Βλέπουμε ότι η επιτυχία του αλγόριθμου δεν είναι η βέλτιστη δυνατή αλλά είναι αρκετά υψηλή σε σχέση με την βελτίωση του χρόνου επίλυσης του προβλήματος για την εξεύρεση πυκνωτών. Η τιμή του σφάλματος είναι λίγο μεγαλύτερο από 10% αλλά έχουμε επιτύχει 20 φορές πιο γρήγορη έξοδο αποτελεσμάτων.

Επειδή όμως και το σφάλμα δεν είναι αμελητέο αναζητούμε μια πιο αξιόπιστη λύση του νευρωνικού. Αυτό γίνεται με την εξής τροποποίηση στον παραπάνω αλγόριθμο επιλογής εξόδων. Σε κάθε μια πιθανή θέση , δεν ασχολούμαστε μό νο με το αποτέλεσμα του αλγόριθμου και το άμεσο γειτονικό αλλά με τα δυο άμεσα γειτονικά, και τον αμέσως μικρότερο ακέραιο και τον αμέσως μεγαλύτερο . Αυτομάτως ο αριθμός των επαναλήψεων σε κάθε δεδομένη θέση του πυκνωτή γίνεται στη χειρότερη περίπτωση 3 , όποτε ο συνολικός αριθμός επαναλήψεων είναι  $3^k$  όπου το k οι επιθυμητές θέσεις . Στην εφαρμογή μας ο αριθμός των επαναλήψεων είναι  $3^5 = 243$ , οι μισές από ότι αυτές που χρειάζονται για την εκτέλεση του γενετικού αλγόριθμου (είδαμε ότι είναι 500 επαναλήψεις ).

Αναζητούμε βέβαια και την βελτίωση στο αποτέλεσμα της μεθόδου με την αύξηση του αριθμού των επαναλήψεων. Έτσι για το αρχείο Train Data η απόδοση είναι:

98,1 % (19615/20000)

ενώ η απόδοση στα δεδομένα του Test Data είναι :

97,2 % ( 243/250 )

Τα ποσοστά αυτά είναι παρά πολύ υψηλά και το σφάλμα θεωρείται αμελητέο. Βέβαια και ο χρόνος εκτέλεσης έχει αυξηθεί αρκετά ώστε να λάβουμε βέλτιστα αποτελέσματα. Εξακολουθεί όμως να χρειάζεται τον μισό χρόνο από αυτόν που απαιτείται από τους γενετικούς αλγόριθμους .

## ΚΑΤΑΝΟΜΗ ΑΠΩΛΕΙΩΝ ΜΕΤΑΦΟΡΑΣ ΣΤΟΥΣ ΖΥΓΟΥΣ ΕΝΟΣ Σ.Η.Ε.

### 5.1

Η μείωση των απωλειών στις γραμμές μεταφοράς είναι ένα από τα σημαντικότερα ζητήματα που απασχολούν σήμερα τους μηχανικούς . Όμως είναι ένα πρόβλημα που η εξάλειψη του είναι αδύνατη. Πάντα θα υπάρχουν απώλειες στις γραμμές που ισοδυναμούν με οικονομικό κόστος . Αυτό το οικονομικό κόστος κάποιος πρέπει να το πληρώσει. Όποτε ένα εξίσου σημαντικό ζήτημα είναι ο διαχωρισμός των απωλειών στους παραγωγούς και στους καταναλωτές . Το ζήτημα αυτό έχει ιδιαίτερη σημασία στα διανεμημένα συστήματα παραγωγής ενέργειας γιατί σε αυτά υπάρχουν πολλοί ανεξάρτητοι παραγωγοί και διανομείς ενέργειας . Πριν γίνει αναφορά στην κατανομή των απωλειών στα διάφορα τμήματα του δικτύου γίνεται μια αναφορά στην δομή και στον τρόπο λειτουργίας των διανεμημένων δικτύων.

### 5.2

Τα τελευταία χρόνια, τα παραδοσιακά πλήρως ενσωματωμένα συστήματα ενέργειας έχουν αποσυντεθεί σε τρεις κλάδους : στην παραγωγή, μετάδοση, και διανομή ενέργειας . Ένας από τους κύριους λόγους είναι να παρασχεθεί μια μείωση των τιμών ηλεκτρικής ενέργειας στους πελάτες μέσω της καθιέρωσης των αγορών ενέργειας. Με την καθιέρωση ανοιχτών αγορών ενέργειας εξασφαλίζεται συνεχής εξέλιξη στον τεχνολογικό τομέα αφού ο ανταγωνισμός ωθεί τις εταιρίες να βελτιώνουν συνεχώς το προϊόν τους . Επίσης με την μη ύπαρξη μονοπωλίου δίνεται η δυνατότητα στον πελάτη να διαλέξει τον παροχό και τον παραγωγό ενέργειας με τον τρόπο που αυτός επιθυμεί και έχοντας υποξή τις τιμές να εξασφαλίσει μια πιο οικονομική λύση. Εξάλλου το άνοιγμα της αγοράς ενέργειας προσφέρει και έσοδα για το κράτος από την εκχώρηση δικαιωμάτων παραγωγής και παροχής ενέργειας σε υποψήφιες εταιρίες . Από τις πρώτες χώρες που προχώρησαν στο άνοιγμα των αγορών ήταν η Αγγλία και η Αργεντινή αλλά υπάρχει ραγδαία εξάπλωση πλέον σε όλο τον κόσμο.

#### 5.2.1 μ μ μ μ

Αντίθετα από το παραδοσιακό κάθετα ενσωματωμένο ηλεκτρικό σύστημα, το μονοπώλιο αφαιρείται πλήρως από τους τομείς της παραγωγής και διανομής (συμπεριλαμβανομένης της λιανικής υπηρεσίας) σε ένα διανεμημένο ηλεκτρικό

σύστημα. Από την άλλη οι περισσότερες κυβερνήσεις και ρυθμιστές συνειδητοποίησαν ότι είναι καλύτερο να υπάρξει μόνο ένα σύστημα μετάδοσης. Επομένως, στις περισσότερες περιπτώσεις ο τομέας της μετάδοσης παρέμεινε ρυθμισμένος. Η Βραζιλία προσπαθεί να απορυθμίσει τον τομέα της μετάδοσης, όχι με τη δημιουργία πολλών γραμμών μετάδοσης, αλλά με τη μίσθωση των τμημάτων των γραμμών μετάδοσης στις διαφορετικές επιχειρήσεις. Τα βασικά χαρακτηριστικά γνωρίσματα ενός διανεμημένου ηλεκτρικού συστήματος συζητούνται κατωτέρω.

#### a) Ανεξάρτητος χειριστής συστημάτων

Ένας ανεξάρτητος χειριστής συστημάτων (ISO) διαδραματίζει το ρόλο ενός επόπτη για τη λειτουργία, τον προγραμματισμό και την ασφάλεια συστημάτων. Έχει τη λειτουργική αρχή ελέγχου σε ολόκληρο το ηλεκτρικό σύστημα και ενεργοποιεί κανονικά τις γραμμές μετάδοσης. Ο ISO εκτελεί κανονικά τις ακόλουθες λειτουργίες:

- παρέχει την ανοικτή και συγκρίσιμη πρόσβαση στους ομοίως τοποθετημένους πελάτες στις εγκαταστάσεις μετάδοσης .
- λειτουργεί αποκλειστικά το λεγόμενο ISO Controlled grid κατά τρόπο αποδοτικό και αξιόπιστο .
- υιοθετεί, προστατεύει και ελέγχει τη συμμόρφωση με τα πρότυπα επιθεώρησης, συντήρησης, επισκευής και αντικατάστασης για το ISO Controlled grid ώστε να παρασχεθεί η υψηλής ποιότητας, ασφαλής και αξιόπιστη ηλεκτρική υπηρεσία που περιλαμβάνει και τις περιόδους έκτακτης ανάγκης και καταστροφής.
- παρέχει ή λαμβάνει τις επαρκείς βοηθητικές υπηρεσίες για το ελεγχόμενο ISO πλέγμα και αποστέλλει τέτοιες υπηρεσίες ανάλογα με τις ανάγκες .
- προγραμματίζει τις υπηρεσίες μετάδοσης για όλες τις συναλλαγές στο ISO Controlled grid.
- αναδιανέμει τους διαθέσιμους πόρους για να ανακουφίσει τη συμφόρηση μετάδοσης .
- αναπτύσσει και υποβάλλει (i) τις μεθοδολογίες μετάδοσης και (ii) τις τιμές για τέτοιες υπηρεσίες μετάδοσης και τις βοηθητικές υπηρεσίες και καθορίζει τα διοικητικά έξοδα.
- θεσπίζει τους λειτουργούντες κανόνες και τα πρωτόκολλα για την αξιόπιστη λειτουργία και για τη συμμετοχή στην αγορά βοηθητικών υπηρεσιών.
- διατηρεί την αξιοπιστία των διαδικασιών του ελεγχόμενου ISO πλέγματος .
- παρέχει τις πληροφορίες τιμολόγησης ελεύθερης αγοράς για τις αγορές υπηρεσιών μετάδοσης και βοηθητικών υπηρεσιών
- εξασφαλίζει τους πόρους παραγωγής και μετάδοσης ανάλογα με τις ανάγκες του προγραμματισμού και της λειτουργίας των κριτηρίων αποθήκευσης
- προωθεί την ανάπτυξη, και εισάγει, συμφωνίες για την αγορά και πώληση ισχύος συμπεριλαμβανομένων των διμερών συμβάσεων
- διαθέτει και διαχειρίζεται τις απώλειες μετάδοσης στα συμμετέχοντα συμβαλλόμενα μέρη

b) Power exchange

Μια οργάνωση, κάτι σαν χρηματιστήριο, η οποία επιτρέπει στους αγοραστές και τους πωλητές της χονδρικής ηλεκτρικής ενέργειας να αγοράζουν και να πωλούν τη ηλεκτρική ενέργεια ως προϊόν. Διαχειρίζεται την ηλεκτρική ενέργεια με ταξύ των αγοραστών και των πωλητών ηλεκτρονικά.


c) Ανταγωνιστικοί παραγωγοί ενέργειας.

Μια ανοικτή πρόσβαση στον τομέα της παραγωγής, στον οποίο οποιαδήποτε οντότητα που είναι κατάλληλη, ικανή να ανταποκριθεί στα πρότυπα μπορεί να πάρει χορηγημένη άδεια και μπορεί να παραγάγει και να πωλήσει την ισχύ. Συνήθως πολλοί ανεξάρτητοι παραγωγοί ισχύος (IPP) ανταγωνίζονται μεταξύ τους για να παραγάγουν και να πωλήσουν τη ηλεκτρική δύναμη σε μια χονδρική αγορά.

d) Ανταγωνιστικοί διανομείς

Οι ανταγωνιστικοί διανομείς αγοράζουν ισχύ σε μεγάλη ποσότητα στο χονδρικό επίπεδο και την πωλούν στους καταναλωτές. Κάνουν πρόσφορες αγορές για την αγοραστική ισχύ στο «ανταλλακτήριο ισχύος» ή το ISO ομοίως όπως οι IPP προσφέρουν ισχύ. Οι διανομείς παρέχουν τη δύναμη στο μεμονωμένο σπίτι, την επιχείρηση ή άλλη οντότητα. Χρεώνουν τα άτομα για την ενέργεια που κατανάλωσαν σε ένα ποσοστό που καθορίστηκε από το κράτος ή τις κυβερνήσεις ή σε ένα ποσοστό που τέθηκε από «την πράξη της άρσης των ελέγχων ηλεκτρικής ενέργειας» σε εκείνη την αρμοδιότητα. Οι διανομείς μπορούν να επιλέξουν τους προμηθευτές τους. Οποιοσδήποτε διανομέας ή μαζικός καταναλωτής ισχύος μπορεί να αγοράσει την ενέργεια από μια γεννήτρια μέσω μιας διμερούς σύμβασης επίσης.

Ένα συνοπτικό διάγραμμα που δείχνει την λειτουργία των διανεμημένων συστημάτων παρουσιάζεται στο σχήμα :



μ 5.1 Μορφή διανεμημένου δικτύου



Στα διασυνδεδεμένα δίκτυα μεγάλη σημασία έχει και η κοστολόγηση. Δεν είναι ενιαία και μη διαπραγματεύσιμη όπως στα μονοπώλια όπου η τιμή καθορίζεται από τον παραγωγό που στον τομέα της ενέργειας είναι το κράτος, αλλά η τιμολόγηση μπορεί να καθοριστεί. Οι δυο βασικές κατηγορίες κοστολόγησης είναι :

- I) **μ μ** . Πολλοί μαζικοί καταναλωτές ενέργειας εισάγονται στις διμερείς συμβάσεις με τους παραγωγούς ή τους προμηθευτές ισχύος για να αποφύγουν τις διακυμάνσεις τιμών της αγοράς ενέργειας σε ένα διανεμημένο περιβάλλον. Ο πωλητής τακτοποιεί τη μεταφορά της ενέργειας με τη χρήση ενός δικτύου μεταφοράς τρίτου. Αυτές είναι μεμονωμένες συμβάσεις και δεν έχουν επιπτώσεις σε οποιεσδήποτε συμβάσεις που είναι ήδη σε ισχύ. Η έννοια των διμερών συμβάσεων επιτρέπει στους πελάτες και τις παραγωγικές εγκαταστάσεις να λειτουργήσουν σύμφωνα με την πολιτική τους και δεν τις καθιστά εξαρτώμενες από την καθημερινή προσφορά όπως σε ένα σύστημα εμπορίας ενέργειας. Η σταθεροποίηση τιμών και άλλες υπηρεσίες και λεπτομέρειες του συμβολαίου καθορίζονται από τις δυο συμβαλλόμενες μεριές. Αυτό δίνει με ευελιξία στην επιλογή. Οι διμερείς συμφωνίες είναι χρήσιμες σε μεγάλους παραγωγούς και καταναλωτές που έχουν μια συνεχεία στην αγορά. Αποφεύγουν την υποχρέωση των διαρκών συμφωνιών και καθορισμών τιμών, και εξοικονομούν σε χρόνο και κόστος.
- II) **Power Pool**. Είναι η πιο κοινή μορφή αγοράς αυτή τη στιγμή που οφείλεται στην απλή δομή της. Οι IPPs και οι καταναλωτές κάνουν πρόσφορες για την πώληση και για την αγορά ισχύος. Μια αγορά ενέργειας διευθύνει τους διαφορετικούς τύπους δημοπρασιών όπως την αγορά ημέρας μπροστά, την αγορά ώρας μπροστά, πραγματικού χρόνου αγορά κ.λπ. για να αγοράσει την απαραίτητη ενέργεια για τους πελάτες της. Στην αγορά, οι παραγωγοί δεν έχουν οποιοδήποτε στόχο για οποιοδήποτε συγκεκριμένο πελάτη παρά μόνο προσφέρουν για να έχουν πρόσβαση στον χώρο. Το μεγάλο πλεονέκτημα είναι ότι η ίδια η αγορά καθορίζει μια ενιαία τιμή για κάθε ώρα που καθορίζεται από τη βασική σχέση των οικονομικών προσφοράς - ζήτησης. Όλα τα συμβαλλόμενα μέρη που συμμετέχουν στην αγορά έχουν το ίδιο δικαίωμα να έχουν πρόσβαση στις πληροφορίες σχετικά με την τιμή και τη ν απαίτηση όποτε αποφεύγεται ο κίνδυνος δημιουργίας ολιγοπωλίων. Εκτός από την ημέρα – μπροστά αγορά και ώρα – μπροστά αγορά, η αγορά πραγματικού χρόνου είναι η πιο σημαντική. Και αυτό γιατί η ηλεκτρική ενέργεια είναι γενικά ένα μη ελαστικό στοιχείο και πρέπει να καταναλωθεί όταν παράγεται. Μια αγορά πραγματικού χρόνου μπορεί να ενημερώσει τις προσφορές της κάθε 10 λεπτά ή 30 λεπτά ή σε οποιοδήποτε κατάλληλο χρόνο.

## 5.3

Σε ένα διανεμημένο ηλεκτρικό σύστημα η απώλεια μετάδοσης πρέπει να διατεθεί στους μεμονωμένους προμηθευτές, τις γεννήτριες και τις συμβάσεις. Η κατανομή απώλειας δεν έχει επιπτώσεις στα επίπεδα παραγωγής ή στις ροές ισχύος, εντούτοις τροποποιεί τη διανομή των εισοδημάτων και των πληρωμών στους ζυγούς των δικτύων μεταξύ των προμηθευτών και των καταναλωτών. Σε ένα διανεμημένο ηλεκτρικό σύστημα, κάθε προμηθευτής πρέπει να παρέχει, την ισχύ που πρέπει να πωλήσει συν την απώλεια μετάδοσης που αντιστοιχεί σε κάθε συναλλαγή. Επομένως, ο χειριστής συστημάτων πρέπει να διαθέσει τις απώλειες σε κάθε μεμονωμένη παραγωγή και φορτίο. Ανάλογα με τη σύμβαση, ένας προμηθευτής μπορεί να παρέχει την ενέργεια και την αντίστοιχη απώλεια ή να παρέχει την ενέργεια και να πληρώσει για την απώλεια. Ανάλογα με ποιους θα παράσχει την απώλεια, η κατανομή ποικίλει ως ένα ορισμένο βαθμό.

### 5.3.1 μ μ

Η κατανομή των απωλειών μετάδοσης έγινε ένα σημαντικό ζήτημα διαπραγματεύσεων αφού αντιστοιχεί σε ένα τεράστιο ποσό των χρημάτων. Αναφέρεται ωστόσο ότι η απώλεια μετάδοσης εξαρτάται από διάφορους παράγοντες του ηλεκτρικού συστήματος. Η απώλεια μεταφοράς είναι μια ιδιαίτερη μη γραμμική λειτουργία αυτών των παραγόντων. Το κύριο πρόβλημα που συνδέεται με την κατανομή απώλειας είναι το γεγονός ότι η απώλεια μετάδοσης είναι μια μη διακριτή οντότητα. Οποιαδήποτε προσπάθεια διαχωρισμού περιπλέκεται περαιτέρω από τη μη γραμμική φύση της. Η πρόκληση που αντιμετωπίζεται σήμερα λοιπόν είναι πώς θα διατεθεί η απώλεια μετάδοσης και ποιο πρέπει να είναι το κριτήριο για τη χρέωση άλλων λειτουργιών. Οι λειτουργίες αυτές ασχολούνται με τη συνέπεια, την απλότητα, την ακρίβεια και την προβλεψιμότητα σε μια μέθοδο κατανομής απώλειας. Είναι ένας εξαιρετικά σκληρός στόχος να προσαρμοστούν όλες αυτές οι εκτιμήσεις σε ένα σύνθετο φαινόμενο όπως την κατανομή απωλειών μετάδοσης. Σε ένα διανεμημένο περιβάλλον, οι οικονομικοί και οι σχετικοί με την αγορά παράγοντες είναι τόσο σημαντικοί όσο και οι τεχνικοί παράγοντες. Όχι μόνο οι ακριβείς υπολογισμοί είναι απαραίτητοι, αλλά και η δίκαιη κατανομή των απωλειών σε όλους τους συμμετόχους είναι επίσης σημαντική. Αν και καμία ιδανική ή τυποποιημένη μέθοδος κατανομής απώλειας δεν υπάρχει, μερικές μέθοδοι έχουν αναφερθεί στη λογοτεχνία αλλά όλες αυτές οι μέθοδοι απαιτούν τους χρονοβόρους και σύνθετους μαθηματικούς υπολογισμούς.

### 5.3.2 μ

Τα τελευταία χρόνια, μερικές μέθοδοι κατανομής απώλειας μετάδοσης έχουν αναφερθεί στη λογοτεχνία. Η απουσία μιας ιδανικής ή ομόφωνης μεθόδου κατανομής απώλειας μετάδοσης, οδηγεί τα συστήματα ενέργειας σε όλο τον κόσμο να

χρησιμοποιούν διάφορες από αυτές τις μεθόδους. Πριν από την ανάπτυξη των διανεμημένων συστημάτων, η περιστροφή της ισχύος μέσω της γραμμής μετάδοσης επιτράπηκε σε πολλές εφαρμογές. Ο H.H. Happ εισήγαγε μερικές μεθόδους για το κόστος της περιστροφής ισχύος. Μια μεθοδολογία είναι η λεγόμενη Pro rata, μια τεχνική που χρησιμοποιείται στην Ισπανία για την κατανομή της απώλειας μετάδοσης, όπου οι απώλειες ορίζονται συνολικά στις γεννήτριες και στους καταναλωτές, και έπειτα ένας ανάλογος κανόνας κατανομής χρησιμοποιείται. Η απώλεια που διατίθεται σε μια γεννήτρια ή έναν καταναλωτή είναι ανάλογη προς το επίπεδο ενεργειακής παραγωγής της. Η διαδικασία pro rata αγνοεί το δίκτυο και, επομένως, δεν είναι σύμφωνη με τη δεδομένη ροή ισχύος. Έχουν συζητηθεί επίσης δύο άλλες μεθόδους αποκαλούμενες 'οριακή διαδικασία' (marginal procedure) και 'proportional Sharing'.

Στην 'marginal procedure', οι απώλειες ορίζονται στις γεννήτριες και στους καταναλωτές μέσω του αποκαλούμενου επαυξητικού συντελεστή απώλειας μετάδοσης (ITL). Μια κανονικοποίηση πρέπει να εκτελεσθεί μετά από την κατανομή, δεδομένου ότι αυτή η μέθοδος οδηγεί μόνο στα ποσοστά κατανομής. Η τυποποιημένη 'οριακή διαδικασία' βασισμένη στους συντελεστές ITL εξαρτάται από την επιλογή του ζυγού ταλάντωσης επειδή οι συντελεστές ITL εξαρτώνται από το slack bus. Ο συντελεστής ITL του slack bus είναι μηδέν εξ ορισμού, κατά συνέπεια το slack bus δεν διατίθεται καμία απώλεια. Αυτό είναι ένας δραστικός περιορισμός για αυτήν την μέθοδο που απαιτεί ότι οι παραγωγοί και καταναλωτές συμφωνούν εκ των προτέρων σχετικά με την επιλογή του ζυγού ταλάντωσης.

Η 'proportional sharing' απαιτεί την υπόθεση της αρχής αναλογικής διανομής. Σύμφωνα με αυτόν τον νόμο «οι ροές εισόδου σε ένα ζυγό είναι ανάλογες προς τις εκροές από αυτό το ζυγό» που δεν θα μπορούσε ούτε να αποδειχθεί ούτε να ανασκευαστεί.

Διάφοροι μελετητές πρότειναν μια ακόμη μέθοδο, την αποκαλούμενη «Z-buss allocation» κατανομής απωλειών. Είναι βασισμένη στις ακριβείς εξισώσεις δικτύου όπως καθορίζονται από τη σύνθετη μήτρα αγωγιμοτήτων και τις σύνθετες κομβικές εγχύσεις. Όλοι οι υπολογισμοί είναι βασισμένοι στην αραιή μήτρα αγωγιμοτήτων. Χρησιμοποιεί τις σύνθετες ροές ρεύματος αντί της ροής ισχύος. Η ροή ισχύος απαιτήθηκε για τον υπολογισμό του ρεύματος στους κλάδους.

Ο Strbac έχει προτείνει μια μέθοδο κατανομής απώλειας μεταφοράς με την κατανομή των συνεισφορών γεννητριών και φορτίων στις ροές γραμμών. Αυτή η μέθοδος επισημαίνει τις συνεισφορές κάθε γεννήτριας και κάθε φορτίου στις ροές γραμμών αντί των οριακών συνεισφορών. Δεδομένου όμως ότι η μέθοδος κατανομής είχε προταθεί βάσει των μέγιστων ροών στις γραμμές, δεν απεικονίζει την πραγματική συνθήκη φορτίων. Ο Bialek είχε προτείνει μια άλλη μέθοδο κατανομής απώλειας στην οποία οι ροές ισχύος στις γραμμές επισημαίνονται και μια αρχή αναλογικής διανομής χρησιμοποιείται.

Ο Cheng και οι συνεργάτες του εξέτασαν τις διαφορετικές προκλήσεις που συνδέθηκαν με τις διμερείς συμβάσεις σε ένα διανεμημένο δίκτυο ηλεκτρικών συστημάτων. Οι συντάκτες περιέγραψαν τη διαμόρφωση των διμερών συμβάσεων χρησιμοποιώντας μια μήτρα συναλλαγής. Μια δυσδιάστατοι μήτρα που περιλαμβάνει τις γεννήτριες ισχύος και τις απαιτήσεις φορτίων καλείται ως μήτρα συναλλαγής.

Οι Anderson και Yang [11] πρότειναν μια δομή για να καθορίσουν τη χρήση του συστήματος μετάδοσης. Αντί της proportional sharing, μια σύγκριση της ροής ισχύος χρησιμοποιείται για να καθορίσει τη χρήση της γραμμής μετάδοσης. Οι συγκρίσεις των ροών ισχύος χρησιμοποιούν τη μελέτη των ροών φορτίων για να βρεθεί η συμβολή μιας γεννήτριας με την τοποθέτηση της γεννήτριας στο φορτίο μελέτης. Η διαφορά που λαμβάνεται από τις δύο ροές φορτίων αποδίδεται στον απολογισμό της γεννήτριας. Αυτή η μέθοδος χρησιμοποιεί στη σειρά κάθε γεννήτρια για να υπολογίσει την επίδρασή της στις μελέτες ροής φορτίων. Η κατανομή απώλειας εξαρτάται από την ακολουθία της γεννήτριας που χρησιμοποιείται. Τα αποτελέσματα ποικίλουν ευρέως για τις διαφορετικές ακολουθίες.

Ο Exposito και συνεργάτες του έχουν προτείνει μια μέθοδο βασισμένη στο διαχωρισμό των ροών κλάδων. Η μέθοδος που παρουσιάζεται σε αυτό το έγγραφο είναι μια τροποποιημένη επαυξητική μέθοδος ITL και ισχύει. Οι συντάκτες πρότειναν τέσσερις μεθόδους για τις ροές κλάδων: ανάλογη κατανομή (proportional allocation), τετραγωνική κατανομή (quadratic allocation), γεωμετρική κατανομή (geometric allocation) και γρήγορη γεωμετρική κατανομή (fast geometric allocation).

Οι Bhuiya και Chowdhury [14] έχουν προτείνει δύο μεθόδους κατανομής απώλειας συγκεκριμένα: της επαυξητικής προσέγγισης ροής φορτίων (ILFA) και της οριακής προσέγγισης απώλειας μετάδοσης (MTLA). Η πρώτη χρησιμοποιεί μια τροποποιημένη τεχνική ροής φορτίων για να αξιολογηθεί η απώλεια μετάδοσης. Σε αυτήν την μέθοδο, σε κάθε ζυγό φορτίων, το φορτίο αυξάνεται σε ένα ιδιαίτερο βήμα ενώ τα φορτία στους άλλους ζυγούς κρατούνται σταθερά. Η προκύπτουσα διαφορική απώλεια μετάδοσης αποδίδεται στην αντίστοιχη γεννήτρια. Τα φορτία αυξάνονται σε μια εναλλασσόμενη ακολουθία, με διακριτά βήματα, από μηδέν στα αντίστοιχα επίπεδά τους. Αυτή η μέθοδος είναι σύμφωνη με τη δεδομένη ροή φορτίων και ανταμείβει την αντίθετη ροή (counter flow) στο σύστημα αλλά απαιτεί έναν υψηλό χρόνο υπολογισμού. Η δεύτερη μέθοδος είναι βασισμένη στην έκφραση απώλειας μετάδοσης Kron και οδηγεί σε μια επαναληπτική διαδικασία. Για να απεικονίσει την επίδραση των διμερών συμβάσεων, η έκφραση απώλειας Kron τροποποιείται και εκφράζεται με βάση τα φορτία αντί των γεννητριών. Στην MTLA, το μερίδιο μιας γεννήτριας στις απώλειες μετάδοσης μπορεί να βρεθεί με την πραγματοποίηση μιας επαυξητικής αλλαγής στην ενεργό απαίτηση ισχύος της γεννήτριας, κρατώντας όλα τα άλλα φορτία σταθερά. Αυτή η μέθοδος απαιτεί πολλές σύνθετες μαθηματικές αναλύσεις και διαδικασίες. Και οι δυο αυτές μέθοδοι έχουν ως βάση την αρκτική marginal procedure αφού και αυτές ασχολούνται με οριακές μεταβολές είτε στο φορτίο είτε στη γεννήτρια.

## 5.4

Μετά την σύντομη αναφορά στις μεθοδολογίες που χρησιμοποιούνται σήμερα για την κατανομή των απωλειών μεταφοράς γίνεται εκτενή περιγραφή και εφαρμογή σε ένα δίκτυο των αλγόριθμων των τεσσάρων βασικών μεθόδων που αποτελούν και την βάση για τις υπόλοιπες κατηγορίες. Οι τέσσερις αυτές κατηγορίες είναι οι ακόλουθες:

### 5.4.1. Pro rata technique

Η αναλογική μέθοδος για την κατανομή απώλειας μπορεί να βασιστεί στην έγχυση ισχύος ή στην έγχυση ρεύματος για κάθε ζυγό. Για να διανεμηθούν οι ηλεκτρικές απώλειες συστημάτων με βάση την αναλογική τεχνική η ακόλουθη εξίσωση πρέπει να χρησιμοποιηθεί:

$$L_i = \frac{|P_i|}{\sum_{i=1}^N |P_i|} \quad (5.1)$$

όπου  $L_i$  είναι η αξία των απωλειών που κατανέμονται στον ζυγό  $i$  και  $|P_i|$  είναι η έγχυση ενεργού ισχύος στο ζυγό  $i$ , με  $N$  τον αριθμό των ζυγών

Αν χρησιμοποιηθεί η έγχυση των ρευμάτων των ζυγών τότε ο τύπος που χρησιμοποιείται για τον καθορισμό των απωλειών είναι :

$$L_i = \frac{|I_i|}{\sum_{i=1}^N |I_i|} \quad (5.2)$$

Για μια πιο κατανοητή λειτουργία του αλγόριθμου και μια πιο ποσοτική θεώρηση των δεδομένων παρουσιάζεται στη συνέχεια σε συνδυασμό με τις άλλες μεθόδους μια κατανομή των απωλειών με βάση αυτή τη μέθοδο.

### 5.4.2. Proportional sharing

Η αναλογική μέθοδος κατανομής είναι βασισμένη στις ακαθάριστες ροές γραμμών. Αυτή η μέθοδος υποθέτει ότι το σύστημα τροφοδοτείται με την πραγματική παραγωγή, και έπειτα η κομβική παραγωγή παραμένει αμετάβλητη αλλά οι κομβικές απαιτήσεις πρέπει να τροποποιηθούν ελαφρώς προκειμένου να ικανοποιηθούν οι νόμοι Kirchhoff. Εντούτοις, δεν είναι δυνατό, να διατεθούν οι απώλειες στις γεννήτριες και τα φορτία συγχρόνως. Γενικά, ο upstream looking algorithm εφαρμόζεται για να διαθέσει τις απώλειες ισχύος σε ποσοστό 50% μεταξύ των

γεννητριών και ο downstream looking algorithm για να διαθέσει το άλλο 50% των απωλειών ισχύος μεταξύ των απαίτησεων.

#### 5.4.2. . Downstream looking algorithm

Η συνολική ακαθάριστη ροή ισχύος  $P_i$  (δηλ. το ποσό όλων των εκροών από τον κόμβο  $i$ ) μπορεί να εκφραστεί όπως:

$$P_i^{gross} = P_{Gi} + \sum_{j \in \alpha_i^{down}} \delta_{ji} P_j^{gross} \quad i=1, \dots, n$$

$$\delta_{ji} = P_{ji}^{gross} / P_j^{gross} \quad (5.3)$$

όπου  $\sum_{j \in \alpha_i^{down}} \delta_{ji} P_j^{gross}$  : η ροή που βγαίνει από το ζυγό  $i$ .  
 $\alpha_i^{down}$  : ο αριθμός των ζυγών που δέχονται ισχύ από το ζυγό  $i$ .

Η αρχική εξίσωση μπορεί να γράφει σαν άθροισμα γραμμικών όρων όποτε παίρνει τη μορφή:

$$A_i P^{gross} = P_G \quad (5.4)$$

κατόπιν η ακαθάριστη ζήτηση στο ζυγό  $i$  μπορεί να εκφραστεί με τη σχέση:

$$P_{Gi}^{gross} = \frac{P_{Gi}}{P_i} \sum_{j=1}^n [A_{ij}^{-1}] P_{Dj} \quad i=1, \dots, n \quad (5.5)$$

που το  $P_i$  είναι η πραγματική ροή ισχύος στο ζυγό όπως προκύπτει από την επίλυση της ροής φορτίου και οι απώλειες στον ζυγό παραγωγής προκύπτουν από τον τύπο :

$$L_{Gi} = P_{Gi}^{gross} - P_{Gi} \quad i=1, \dots, n \quad (5.6)$$

#### 5.4.2. . Upstream looking algorithm

Όμοιος με τον παραπάνω αλγόριθμο έχουμε τη συνολική ακαθάριστη ροή ισχύος  $P_i$

$$P_i^{gross} = P_{Gi} + \sum_{j \in \alpha_i^{up}} \delta_{ji} P_j^{gross} \quad i=1, \dots, n$$

$$\delta_{ji} = P_{ji}^{gross} / P_j^{gross} \quad (5.7)$$

όπου:

$$\sum_{j \in \text{αφ}} \delta_{ji} P_j^{gross} \quad \text{: η ροή που φτάνει στο ζυγό } i \text{ από γραμμές συνδεδεμένες με αυτόν}$$

$$\alpha_i \quad \text{: ο αριθμός των ζυγών στέλνουν ισχύ προς το ζυγό } i.$$

Άρα η εξίσωση μπορεί να πάρει τη παρακάτω μορφή με πίνακες :

$$A_n P^{gross} = P_G \quad (5.8)$$

και η ακαθάριστη ζήτηση στο ζυγό  $i$  είναι :

$$P_{Di}^{gross} = \frac{P_{Di}}{P_i} \sum_{j=1}^n [A_{ij}^{-1}] P_{Gj} \quad i=1, \dots, n \quad (5.9)$$

ενώ οι απώλειες στους ζυγούς φορτίου είναι :

$$L_{Di} = P_{Di}^{gross} - P_{Di} \quad i=1, \dots, n \quad (5.10)$$

### 5.4.3. Marginal allocation

Πρόκειται για την πιο διαδεδομένη μέθοδο κατανομής των απωλειών και χρησιμοποιείται σε πραγματικά δίκτυα σε όλο τον κόσμο. Κάτω από την επαυξητική ανάλυση όπως ονομάζεται η διαδικασία αυτή οι απώλειες ισχύος μπορούν να διατεθούν στους παραγωγούς και τους καταναλωτές ταυτόχρονα μέσω των οριακών συντελεστών απώλειας (MLC's) στο δεδομένο λειτουργούν σημείο. Εξ ορισμού, αυτοί οι συντελεστές μετρούν την αλλαγή στις ενεργές απώλειες ισχύος λόγω της επαυξητικής αλλαγής στις εγχύσεις ισχύος σε κάθε κόμβο στο δίκτυο, και ορίζονται ως:

$$MPC_i^P = \frac{\partial L}{\partial (P_{Gi} - P_{Di})} \quad (5.11)$$

$$MPC_i^Q = \frac{\partial L}{\partial (Q_{Gi} - Q_{Di})} \quad (5.12)$$

Δεδομένου ότι δεν υπάρχει καμία ρητή σχέση μεταξύ των απωλειών και των εγχύσεων ισχύος, ο τυποποιημένος κανόνας που εφαρμόζεται στον υπολογισμό των MLC's χρησιμοποιεί τις ενδιάμεσες μεταβλητές, τις τάσεις και γωνίες που λαμβάνονται από την επίλυση μίας εναλλασσόμενης ροής ισχύος :

$$\begin{bmatrix} MLC_{ac}^P \\ MLC_{ac}^Q \end{bmatrix} = \begin{bmatrix} \frac{\partial P_1}{\partial \theta_1} & \frac{\partial P_2}{\partial \theta_1} & \dots & \frac{\partial P_n}{\partial \theta_1} & \frac{\partial Q_1}{\partial \theta_1} & \frac{\partial Q_2}{\partial \theta_1} & \dots & \frac{\partial Q_n}{\partial \theta_1} & \frac{\partial L}{\partial \theta_1} \\ \frac{\partial P_1}{\partial \theta_2} & \frac{\partial P_2}{\partial \theta_2} & \dots & \frac{\partial P_n}{\partial \theta_2} & \frac{\partial Q_1}{\partial \theta_2} & \frac{\partial Q_2}{\partial \theta_2} & \dots & \frac{\partial Q_n}{\partial \theta_2} & \frac{\partial L}{\partial \theta_2} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \frac{\partial P_1}{\partial \theta_n} & \frac{\partial P_2}{\partial \theta_n} & \dots & \frac{\partial P_n}{\partial \theta_n} & \frac{\partial Q_1}{\partial \theta_n} & \frac{\partial Q_2}{\partial \theta_n} & \dots & \frac{\partial Q_n}{\partial \theta_n} & \frac{\partial L}{\partial \theta_n} \\ \frac{\partial P_1}{\partial V_1} & \frac{\partial P_2}{\partial V_1} & \dots & \frac{\partial P_n}{\partial V_1} & \frac{\partial Q_1}{\partial V_1} & \frac{\partial Q_2}{\partial V_1} & \dots & \frac{\partial Q_n}{\partial V_1} & \frac{\partial L}{\partial V_1} \\ \frac{\partial P_1}{\partial V_2} & \frac{\partial P_2}{\partial V_2} & \dots & \frac{\partial P_n}{\partial V_2} & \frac{\partial Q_1}{\partial V_2} & \frac{\partial Q_2}{\partial V_2} & \dots & \frac{\partial Q_n}{\partial V_2} & \frac{\partial L}{\partial V_2} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \frac{\partial P_1}{\partial V_n} & \frac{\partial P_2}{\partial V_n} & \dots & \frac{\partial P_n}{\partial V_n} & \frac{\partial Q_1}{\partial V_n} & \frac{\partial Q_2}{\partial V_n} & \dots & \frac{\partial Q_n}{\partial V_n} & \frac{\partial L}{\partial V_n} \end{bmatrix} \quad (5.13)$$

Το γενικό σύστημα των γραμμικών εξισώσεων λύνεται με εξάλειψη των στηλών και σειρών του slack bus και τους κόμβους PV και για τον ορισμό των παραγωγών αυτών παίρνουμε:

$$MLC_{sl}^P = MLC_{sl}^Q = MLC_{pv}^Q = 0$$

Για τον υπολογισμό των υπόλοιπων MLC's απαιτείται ο υπολογισμός της Jacobian και της παραγωγού των απωλειών ως προς τις εγχύσεις ισχύος. Για τον υπολογισμό αυτών των στοιχείων εκτελούμε τους τύπους :

$$\frac{\partial P_i}{\partial d_j} = V_i V_j [G_{ij} \sin(d_i - d_j) - B_{ij} \cos(d_i - d_j)]$$

$$\frac{\partial P_i}{\partial d_i} = -B_{ii} V_i^2 - \sum_{j=1}^n V_i V_j [G_{ij} \sin(d_i - d_j) - B_{ij} \cos(d_i - d_j)]$$

$$\frac{\partial P_i}{\partial V_j} = V_i [G_{ij} \cos(d_i - d_j) + B_{ij} \sin(d_i - d_j)]$$

$$\frac{\partial P_i}{\partial V_i} = G_{ii} V_i + \sum_{j=1}^n V_j [G_{ij} \cos(d_i - d_j) + B_{ij} \sin(d_i - d_j)]$$



$$\frac{\partial Q_i}{\partial d_j} = -V_i V_j [G_{ij} \cos(d_i - d_j) + B_{ij} \sin(d_i - d_j)]$$

$$\frac{\partial Q_i}{\partial d_i} = -G_{ii} V_i^2 + \sum_{j=1}^n V_i V_j [G_{ij} \cos(d_i - d_j) + B_{ij} \sin(d_i - d_j)]$$

$$\frac{\partial Q_i}{\partial V_j} = V_i [G_{ij} \sin(d_i - d_j) - B_{ij} \cos(d_i - d_j)]$$

$$\frac{\partial Q_i}{\partial V_i} = -B_{ii} V_i + \sum_{j=1}^n V_j [G_{ij} \sin(d_i - d_j) - B_{ij} \cos(d_i - d_j)]$$

$$\frac{\partial L}{\partial d_i} = 2 \sum_{j=1}^n V_i V_j G_{ij} \sin(d_i - d_j)$$

$$\frac{\partial L}{\partial V_i} = 2 \sum_{j=1}^n G_{ij} [V_i - V_j \cos(d_i - d_j)]$$

Μετά τον ορισμό των παραγωγών των απωλειών ,ο υπολογισμός πλέον των απωλειών σε κάθε κόμβο υπολογίζεται με τη βοήθεια των παρακάτω τύπων :

$$L_{Gi} = P_{Gi} MLC_i^P \quad i = 1, 2, \dots, n \quad (5.14)$$

$$L_{Di} = P_{Di} MLC_i^P \quad i = 1, 2, \dots, n \quad (5.15)$$

Όμως λόγω της μη γραμμικότητας των παραγωγών από όπου υπολογίζονται οι συντελεστές MLC , το άθροισμα όλων αυτών των απωλειών είναι διαφορετικό από τις συνολικές απωλειες δηλαδή ισχύει :

$$\begin{aligned} L &\neq \sum_{i=1}^{N_G} L_{Gi} + \sum_{j=1}^{N_D} L_{Dj} \\ &= \sum_{i=1}^{N_G} P_{Gi} K_i + \sum_{j=1}^{N_D} P_{Dj} K_j = L' \end{aligned} \quad (5.16)$$

Για αυτό το λόγο ακολουθείται μια διαδικασία εξομάλυνσης ώστε να κατανεμηθούν οι σωστές απωλειες απωλειών . Αυτή είναι :

$$L = L' \frac{L}{L'} = \left( \sum_{i=1}^{Pg} P_{Gi} K_{Gi} + \sum_{i=1}^{Pd} P_{Di} K_{di} \right) \frac{L}{L'} =$$

$$\sum_{i=1}^{Pg} P_{Gi} K'_{Gi} + \sum_{i=1}^{Pd} P_{Di} K'_{di} \quad (5.17)$$

όπου το

$$K'_i = K_i \frac{L}{L'} \quad (5.18)$$

Οι συνολικές απωλειες προκύπτουν από το γινόμενο των νέων τελεστών με τις ενεργές παραγόμενες η καταναλισκόμενες ισχύς .

Πρέπει να σημειωθεί ότι συχνά το αποτέλεσμα της διαδικασίας των οριακών απωλειών παίρνει αρνητικές τιμές. Για να αποφεύγονται οι αρνητικές τιμές εφαρμόζεται η τεχνική U-ITL (Unsubsidized marginal allocation). Πρέπει να υπογραμμιστεί ότι ο σκοπός αυτή η μέθοδος είναι να διατεθεί το κόστος των απωλειών, και όχι να εξηγήσει τα φυσικά γεγονότα.

Οι συντελεστές ITL, που υπολογίζονται για ένα δεδομένο slack bus, μπορούν εύκολα αναφέρεται σε ένα διαφορετικό slack bus με τον καθορισμό ενός συντελεστή μετατροπής  $\beta$  ( $0 \leq \beta \leq 1$ ) . Αυτό χρησιμοποιείται παρακάτω. Οι συνολικές απωλειες είδαμε ότι εκφράζονται ως:

$$L = \sum_{i=1}^N K'_i P_i$$

Όμως ισχύει ακόμη ότι:

$$L = \sum_{i=1}^N (P_{Gi} - P_{di}) = \sum_{i=1}^N P_i \quad (5.19)$$

Πολλαπλασιάζοντας την πρώτη με  $\beta$  και τη δεύτερη με  $(1 - \beta)$  και με την πρόσθεση λαμβάνουμε ότι:

$$L = \sum_{i=1}^N \beta K'_i P_i + \sum_{i=1}^N (1 - \beta) P_i = \sum_{i=1}^N (\beta K'_i + 1 - \beta) P_i \quad (5.20)$$

οπότε οι νέοι τελεστές καταμερισμού είναι πλέον  $K_i = \beta K_i' + 1 - \beta$ .

Όσον αφορά την παραγωγή, μια αλλαγή του slack bus εκτελείται κατά τέτοιο τρόπο ώστε ο συντελεστής ΙΤΛ γεννητριών με τη μικρότερη αξία να γίνεται μηδέν. Αυτό το καθιστά αδύνατο να οριστούν αρνητικές απώλειες στις γεννήτριες. Η διαδικασία που ακολουθείται είναι η κάτωθι :

Έστω  $K_{GK}'$  είναι ο συντελεστής ΙΤΛ γεννητριών με το μικρότερο μέγεθος. Με την μετατροπή ο συντελεστής αυτός παίρνει την τιμή 0. Όποτε :

$$K_{GK} = 0 = \beta_G K_{GK}' + 1 - \beta_G \quad (5.21)$$

και 
$$\beta_G = \frac{1}{1 - K_{GK}'}$$

έτσι ο νέος τελεστής για τις γεννήτριες είναι :

$$K_{Gi} = \beta_G K_{Gi}' + 1 - \beta_G \quad (5.22)$$

Ακριβώς η ίδια διαδικασία ακολουθείται και όταν ορίζονται αρνητικά αποτελέσματα στους ζυγούς φορτίου όποτε οι τροποποιημένοι τελεστές είναι :

$$K_{di} = \beta_d K_{di}' + 1 - \beta_d \quad \text{με} \quad \beta_d = \frac{1}{1 - K_{dk}'} \quad (5.23)$$

#### 5.4.4. Z-bus loss allocation

Μια νέα μέθοδος για τις απώλειες μετάδοσης μεταξύ των φορτίων και των γεννητριών, αποκαλούμενη Z-bus loss allocation παρουσιάζεται. Αυτή η μέθοδος εισάγει τρία πρόσθετα χαρακτηριστικά:

I) τα ρεύματα περισσότερο από τις ισχύς υπογραμμίζονται στη διαδικασία κατανομής. Αυτό το σημείο απεικονίζει το γεγονός ότι τα ρεύματα είναι ο κυρίαρχος παράγοντας στον προσδιορισμό των απωλειών μετάδοσης.

II) Ο φυσικός μαθηματικός χωρισμός των απωλειών του συστήματος μεταξύ των διάφορων ζυγών είναι προσδιορισμένος και εκμεταλλευμένος.

III) γεννήτριες ή φορτία απόμακρες από «το κέντρο βαρύτητας» τείνουν να είναι κατανεμημένες με αναλογικά υψηλότερες απώλειες.

Για να υπολογίσουμε τους όρους  $L_k$  (απώλειες σε κάθε κόμβο) σύμφωνα με αυτή τη μέθοδο κατανομής απώλειας, υπολογίζουμε τη μήτρα αγωγιμοτήτων  $Y = G + jB$ . Δεχόμαστε μια λύση ροής φορτίου στο σύστημα με μια από τις γνωστές μεθόδους και υπολογίζουμε τα ρεύματα και τις τάσεις σε όλα τα σημεία του δικτύου. Οι απώλειες του συστήματος μπορούν να εκφραστούν είτε με τη βοήθεια της μήτρας  $Y$  είτε ορίζοντας ένα νέο πίνακα  $Z = Y^{-1} = R + jX$ . Οι ολικές απώλειες εκφράζονται ως :

$$P_{loss} = \Re \left\{ \sum_{k=1}^n V_k I_k^* \right\} \quad (5.24)$$

ή με τη βοήθεια της μήτρας  $Z$  που ορίσαμε ως :

$$P_{loss} = \Re \left\{ \sum_{k=1}^n I_k^* \left( \sum_{j=1}^n Z_{kj} I_j \right) \right\} \quad (5.25)$$

Η βασική ιδέα πίσω από τη μέθοδο Z-Bus είναι να χωριστεί ο τύπος των απωλειών σε δύο κύρια αθροίσματα, ένας λόγω της μήτρας αντίστασης, και το άλλο στη μήτρα άεργης αντίδρασης. Κατόπιν έχουμε :

$$P_{loss} = \Re \left\{ \sum_{k=1}^n I_k^* \left( \sum_{j=1}^n R_{kj} I_j \right) \right\} + \Re \left\{ \sum_{k=1}^n I_k^* \left( \sum_{j=1}^n jX_{kj} I_j \right) \right\} \quad (5.26)$$

όμως εύκολα αποδεικνύεται ότι το δεύτερο άθροισμα ισούται με μηδέν όποτε ο τελικός τύπος έκφρασης των συνολικών απολήων στο σύστημα είναι :

$$P_{loss} = \Re \left\{ \sum_{k=1}^n I_k^* \left( \sum_{j=1}^n R_{kj} I_j \right) \right\} \quad (5.27)$$

Ένας φυσικός χωρισμός των απωλειών συστήματος μεταξύ των ζυγών του δικτύου παρουσιάζεται τώρα. Για να ανασχηματίσετε αυτό με μορφή μήτρων, θεωρήστε το διάνυσμα των πραγματικών εγχύσεων ισχύος που εκφράζονται ως :

$$P = \Re \{ \text{diag}(I^*)RI \} + \Re \{ j \text{diag}(I^*)XI \} \quad (5.28)$$

Οι πραγματικές ροές ισχύος χωρίζονται σε δυο τμήματα. Αυτά του πρώτου όρου που αποτελούν τις απώλειες  $L$  και αυτά του δεύτερου που αποτελούν τη ζήτηση φορτίου  $D$ . Από τις δυο τελευταίες σχέσεις φαίνεται ότι το άθροισμα των απωλειών σε όλους τους ζυγούς είναι ίσο με το συνολικό άθροισμα. Επίσης το άθροισμα των  $D$  ισούται με μηδέν. Έτσι το σύστημα απωλειών είναι φυσικά χωρισμένο σε  $L_k$  όρους. Οποτε με βάση τις δυο σχέσεις αυτές παίρνουμε ότι :

$$L_k = \Re \left\{ I_k^* \left( \sum_{j=1}^n R_{kj} I_j \right) \right\} \quad (5.29)$$

όποτε έχει επιτευχθεί ο στόχος του καταμερισμού των απωλειών στους ζυγούς του δικτύου.

Απομένει πλέον διαχωρισμός των απωλειών ανάλογα με το φορτίο και τις γεννήτριες σε κάθε ζυγό. Γενικά αν κάθε ζυγός έχει και γεννήτριες και φορτίο ο διαμοιρασμός γίνεται με ένα αναλογικό τρόπο. Ορίζουμε την ποσότητα :

$$\gamma_k = (P_{gk} / (P_{gk} - P_{dk}))$$

όποτε η γεννήτρια εισπράττει έσοδα για παραγωγή ενέργειας ίση με :

$$(P_{gk} - \gamma_k L_k)$$

ενώ τα φορτία χρεώνονται για κατανάλωση ενέργειας ίση με :

$$(P_{dk} + (1 - \gamma_k) L_k)$$

## 5.5

Μια ανάλυση των αποδόσεων των μεθόδων κατανομής απώλειας ,θεωρώντας διαφορετικές καταστάσεις της αποστολής ισχύος, συγκρίνοντας τις διαφορετικές μεθόδους , παρουσιάζεται. Όλες οι δοκιμασμένες μέθοδοι κατανέμουν απώλειες ίσες με μηδέν για ζυγούς που δεν έχουν ούτε γεννήτριες ούτε φορτία. Η αναλογική μέθοδο pro rata διαθέτει πάντα ένα μέρος των απωλειών για τις γεννήτριες και τα φορτία, έτσι αυτό σημαίνουν ότι όλα οι γεννήτριες και τα φορτία πρέπει «να πληρώσουν» για τις ηλεκτρικές απώλειες. Αντίθετα οι marginal allocation και Z-bus allocation διαθέτουν θετικές και αρνητικές τιμές για τις απώλειες , έτσι σημαίνει ότι οι γεννήτριες και τα φορτία μπορούν «να πληρώσουν» (θετική κατανομή) ή «να λάβουν» (αρνητική κατανομή) για τις ηλεκτρικές απώλειες. Όταν η αρνητική κατανομή εμφανίζεται για ένα ζυγό, σημαίνει ότι αυτός ο κόμβος πρέπει να λάβει τα νομισματικά κίνητρα, και προφανώς οι άλλοι κομβοί του συστήματος πρέπει να συμβάλουν προκειμένου να πληρώσουν αυτά τα κίνητρα. Οι αναλύσεις θα γίνουν στο σύστημα IEEE 14 ζυγών .

Πριν την εκτέλεση των υπολογισμών ανάλογα με την μέθοδο πρέπει να υπολογιστούν τα στοιχεία του δικτύου , δηλαδή οι τάσεις και τα ρεύματα στους ζυγούς . Ο υπολογισμός αυτός επιτυγχάνεται με την εκτέλεση μιας ροής φορτίου ,π.χ. με την μέθοδο Newton-Raphson. Πρώτα όμως πρέπει να καθοριστούν οι εγχύσεις άεργου και ενεργού ισχύος στο δίκτυο . Σαν δεδομένα στην εφαρμογή παίρνουμε τα πρότυπα στοιχεία όπως δίνονται από το εγχειρίδιο της IEEE για το δίκτυο των 14 ζυγών.

Μετά την εκτέλεση της επαναληπτικής διαδικασίας παίρνουμε τα αποτελέσματα για την παραγωγή ενέργειας και τα μεγέθη της τάσης :

| Bus No | Volt Mag. | angle deg. |  | load MW | load Mvar |  | generation MW | generation Mvar |
|--------|-----------|------------|--|---------|-----------|--|---------------|-----------------|
| 1      | 1,060     | 0          |  | 0       | 0         |  | 232,53        | -29,37          |
| 2      | 1,045     | -4,95      |  | 21,7    | 12,7      |  | 40            | 18,98           |
| 3      | 1,010     | -12,61     |  | 94,2    | 19        |  | 0             | 15,88           |
| 4      | 1,028     | -10,39     |  | 47,8    | -3,9      |  | 0             | 0               |
| 5      | 1,035     | -8,980     |  | 7,6     | 1,6       |  | 0             | 0               |
| 6      | 1,070     | -14,88     |  | 11,2    | 7,5       |  | 0             | 47,74           |
| 7      | 1,046     | -13,47     |  | 0       | 0         |  | 0             | 0               |
| 8      | 1,090     | -13,47     |  | 0       | 0         |  | 0             | 27,38           |
| 9      | 1,029     | -15,09     |  | 29,5    | 16,6      |  | 0             | 0               |
| 10     | 1,028     | -15,33     |  | 9       | 5,8       |  | 0             | 0               |
| 11     | 1,045     | -15,22     |  | 3,5     | 1,8       |  | 0             | 0               |
| 12     | 1,053     | -15,72     |  | 6,1     | 1,6       |  | 0             | 0               |
| 13     | 1,046     | -15,74     |  | 13,5    | 5,8       |  | 0             | 0               |
| 14     | 1,018     | -16,40     |  | 14,9    | 5         |  | 0             | 0               |
| Total  |           |            |  | 259     | 73,5      |  | 272,53        | 80,61           |

### 5.1 Αποτελέσματα ροής φορτίου IEEE 14

Ο αριθμός των επαναλήψεων της μεθόδου είναι 4 και οι συνολικές απώλειες στις γραμμά μεταφοράς είναι:

$$P_{\text{loss}}=13,53 \text{ MW}$$

Αυτό το πόσο είναι που πρέπει να καταναμηθεί στους διάφορους εμπλεκόμενους φορείς .

### 5.5.1 Pro rata

Όπως αναφέραμε και στην θεωρητική αναφορά ,για την μέθοδο Pro rata χρησιμοποιείται η σχέση για τον υπολογισμό των λόγων :

$$L_i = \frac{|P_i|}{\sum_{i=1}^{14} |P_i|}$$

Ο πίνακας με τους λόγους σε κάθε ζυγό με βάση τους οποίους γίνεται ο καταμερισμός των απωλειών υπολογίζεται με βάση τις εγχεομενες ροές και είναι:

|        |        |       |        |        |        |   |
|--------|--------|-------|--------|--------|--------|---|
| 1      | 2      | 3     | 4      | 5      | 6      | 7 |
| 0,4764 | 0,0375 | 0,193 | 0,0979 | 0,0156 | 0,0229 | 0 |

|   |        |        |        |        |        |        |
|---|--------|--------|--------|--------|--------|--------|
| 8 | 9      | 10     | 11     | 12     | 13     | 14     |
| 0 | 0,0604 | 0,0184 | 0,0072 | 0,0125 | 0,0277 | 0,0305 |

### 5.2 Αποτελέσματα κατανομής pro rata

Το άθροισμα  $\sum |P_i| = 488,13 \text{ MW}$ .

Όποτε με τον υπολογισμό των λόγων αρκεί ο πολλαπλασιασμός με το συνολικό κόστος των απωλειών για να γίνει η κατανομή αυτών σε όλο το δίκτυο.

Με την ίδια διαδικασία μπορούμε με την βοήθεια των εγχύσεων ρεύματος να υπολογίζουμε τις απώλειες .

Τα αποτέλεσμα της κατανομής στον δίκτυο 14 ζυγών γίνεται συνολικά από όλες τις μεθόδους ώστε να είναι εμφανής η σύγκριση των αποτελεσμάτων.

### 5.5.2 Proportional sharing

Με βάση τη μεθοδολογία πρέπει να βρεθούν οι ροές ισχύος από και προς τους κόμβους του συστήματος. Με τη διαδοχική άθροιση των ροών που εισέρχονται σε κάθε κόμβο έχουμε για τους 14 ζυγούς :

| $P_1$  | $P_2$ | $P_3$ | $P_4$  | $P_5$  | $P_6$ | $P_7$ |
|--------|-------|-------|--------|--------|-------|-------|
| 232,53 | 191,7 | 94,2  | 115,33 | 114,48 | 45,24 | 27,62 |

| $P_8$ | $P_9$ | $P_{10}$ | $P_{11}$ | $P_{12}$ | $P_{13}$ | $P_{14}$ |
|-------|-------|----------|----------|----------|----------|----------|
| 0     | 43,19 | 9        | 7,75     | 7,95     | 19,72    | 14,9     |

### 5.3 Εγγεόμενες ροές proportional sharing

Κατόπιν υπολογίζουμε πρώτα για τον downstream looking algorithm και τον υπολογισμό των απωλειών των γεννητριών τον πίνακα  $A_{d_{ij}}$  όπου κάθε στοιχείο του δίνεται από την σχέση

$$[A_d]_{il} = \begin{cases} 1 & \text{για } i = l \\ -c_{li} = -|P_{l-i}|/P_l & \text{για } l \in \alpha_i^{(d)} \\ 0 & \text{αλλιώς} \end{cases}$$

όποτε έχουμε  $A_{d_{ij}} =$

|   |       |       |        |       |    |    |   |        |         |    |    |       |        |
|---|-------|-------|--------|-------|----|----|---|--------|---------|----|----|-------|--------|
| 1 | -0,79 | 0     | 0      | -0,64 | 0  | 0  | 0 | 0      | 0       | 0  | 0  | 0     | 0      |
| 0 | 1     | -0,75 | -0,469 | -0,35 | 0  | 0  | 0 | 0      | 0       | 0  | 0  | 0     | 0      |
| 0 | 0     | 1     | 0      | 0     | 0  | 0  | 0 | 0      | 0       | 0  | 0  | 0     | 0      |
| 0 | 0     | -0,26 | 1      | 0     | 0  | -1 | 0 | -0,36  | 0       | 0  | 0  | 0     | 0      |
| 0 | 0     | 0     | -0,53  | 1     | -1 | 0  | 0 | 0      | 0       | 0  | 0  | 0     | 0      |
| 0 | 0     | 0     | 0      | 0     | 1  | 0  | 0 | 0      | 0       | -1 | -1 | -0,91 | 0      |
| 0 | 0     | 0     | 0      | 0     | 0  | 1  | 0 | -0,639 | 0       | 0  | 0  | 0     | 0      |
| 0 | 0     | 0     | 0      | 0     | 0  | 0  | 1 | 0      | 0       | 0  | 0  | 0     | 0      |
| 0 | 0     | 0     | 0      | 0     | 0  | 0  | 0 | 1      | -0,53   | 0  | 0  | 0     | -0,589 |
| 0 | 0     | 0     | 0      | 0     | 0  | 0  | 0 | 0      | 1       | 0  | 0  | 0     | 0      |
| 0 | 0     | 0     | 0      | 0     | 0  | 0  | 0 | 0      | -0,4656 | 1  | 0  | 0     | 0      |
| 0 | 0     | 0     | 0      | 0     | 0  | 0  | 0 | 0      | 0       | 0  | 1  | -0,09 | 0      |
| 0 | 0     | 0     | 0      | 0     | 0  | 0  | 0 | 0      | 0       | 0  | 0  | 1     | -0,41  |
| 0 | 0     | 0     | 0      | 0     | 0  | 0  | 0 | 0      | 0       | 0  | 0  | 0     | 1      |

### 5.4 Downstream looking algorithm proportional sharing



Και με τη βοήθεια του Matlab υπολογίζουμε τον ανάστροφο και κατόπιν τις διανεμημένες στις γεννήτριες απώλειες.

Με την ίδια λογική και με βάση τον upstream looking algorithm έχουμε τον πίνακα  $A_{u_{ij}}$  :

|         |        |   |        |        |        |    |   |        |   |        |        |        |   |
|---------|--------|---|--------|--------|--------|----|---|--------|---|--------|--------|--------|---|
| 1       | 0      | 0 | 0      | 0      | 0      | 0  | 0 | 0      | 0 | 0      | 0      | 0      | 0 |
| -0,6707 | 1      | 0 | 0      | 0      | 0      | 0  | 0 | 0      | 0 | 0      | 0      | 0      | 0 |
| 0       | -0,378 | 1 | -0,202 | 0      | 0      | 0  | 0 | 0      | 0 | 0      | 0      | 0      | 0 |
| 0       | -0,291 | 0 | 1      | -0,538 | 0      | 0  | 0 | 0      | 0 | 0      | 0      | 0      | 0 |
| -0,3293 | -0,217 | 0 | 0      | 1      | 0      | 0  | 0 | 0      | 0 | 0      | 0      | 0      | 0 |
| 0       | 0      | 0 | 0      | -0,395 | 1      | 0  | 0 | 0      | 0 | 0      | 0      | 0      | 0 |
| 0       | 0      | 0 | -0,239 | 0      | 0      | 1  | 0 | 0      | 0 | 0      | 0      | 0      | 0 |
| 0       | 0      | 0 | 0      | 0      | 0      | 0  | 1 | 0      | 0 | 0      | 0      | 0      | 0 |
| 0       | 0      | 0 | -0,135 | 0      | 0      | -1 | 0 | 1      | 0 | 0      | 0      | 0      | 0 |
| 0       | 0      | 0 | 0      | 0      | 0      | 0  | 0 | -0,112 | 1 | -0,548 | 0      | 0      | 0 |
| 0       | 0      | 0 | 0      | 0      | -0,174 | 0  | 0 | 0      | 0 | 1      | 0      | 0      | 0 |
| 0       | 0      | 0 | 0      | 0      | -0,177 | 0  | 0 | 0      | 0 | 0      | 1      | 0      | 0 |
| 0       | 0      | 0 | 0      | 0      | -0,401 | 0  | 0 | 0      | 0 | 0      | -0,233 | 1      | 0 |
| 0       | 0      | 0 | 0      | 0      | 0      | 0  | 0 | -0,206 | 0 | 0      | 0      | -0,315 | 1 |

### 5.5 Upstream looking algorithm proportional sharing

Και με τη βοήθεια του ανάστροφου αλλά και τα μεγέθη των φορτίων βρίσκουμε τις κατανομές απωλειών σε αυτά.

Τα τελικά αποτελέσματα συνοψίζονται σε ένα πίνακα .

#### 5.5.3. -Bus allocation

Αρχικά υπολογίζουμε εύκολα τον πίνακα  $Z$  βρίσκοντας τον αντίστροφο του πίνακα αγωγιμωτήτων. Κατόπιν από την μελέτη της ροής φορτίου και με τη γνώση της συνολικής ισχύος και της τάσης σε κάθε ζυγό υπολογίζουμε και την ροή ρεύματος για κάθε ένα από αυτούς που στην περίπτωση του συστήματος IEEE-14 είναι:

$$\begin{aligned}
 I_1 &= 1589.6-200.78i & I_8 &= -41.8+17.73i \\
 I_2 &= 130.19-32.4i & I_9 &= -170.1-167.9i \\
 I_3 &= -654.6-168.9i & I_{10} &= -50.53-56.23i \\
 I_4 &= -336.4-33.6i & I_{11} &= -20.15-18.4i \\
 I_5 &= -50.86-19.3i & I_{12} &= -37.45-21.98i \\
 I_6 &= -142.4+244.8i & I_{13} &= -79.46-63.89i \\
 I_7 &= 0 & I_{14} &= -91.77-64.1i
 \end{aligned}$$

Όποτε με την γνώση του I, Z υπολογίζονται οι κατανομές απωλειών από τον τύπο:

$$L_k = \Re \left\{ I_k^* \left( \sum_{j=1}^n R_{kj} I_j \right) \right\}$$

όπου n=14 .

#### 5.5.4. Marginal loss allocation

Ενδιαφερόμαστε για τον υπολογισμό των τελεστών :

$$MPC_i^P = \frac{\partial L}{\partial (P_{Gi} - P_{Di})}$$

Όμως επειδή δεν είναι άμεση αυτή η διαδικασία υπολογίζεται ως γινόμενο των λόγων :

$$MPC_i^P = \frac{\partial(V, \theta)}{\partial (P_G - P_d)} \frac{\partial L}{\partial (V, \theta)}$$

ο πρώτος λόγος είναι ο ανάστροφος Ιακωβιανός  $(J^T)^{-1}$  και ο δεύτερος υπολογίζεται από τις σχέσεις (5.14-5.15). Το γινόμενο των δυο πινάκων μας δίνει το αποτέλεσμα των συντελεστών ITL σε ένα πίνακα μεγέθους (1 x 13) για το δίκτυο IEEE 14. Για τον πρώτο ζυγό με βάση και την μεθοδολογία , αφού πρόκειται για τον ζυγό αναφοράς παίρνουμε  $MPC_1^P = 0$ .

Ο πίνακας με τα αποτελέσματα είναι :

|   | $K_i$  |    | $K_i$  |
|---|--------|----|--------|
| 1 | 0      | 8  | 0,1063 |
| 2 | 0,0584 | 9  | 0,1058 |
| 3 | 0,1362 | 10 | 0,1064 |
| 4 | 0,1076 | 11 | 0,1042 |
| 5 | 0,0925 | 12 | 0,1105 |
| 6 | 0,1018 | 13 | 0,1073 |
| 7 | 0,1063 | 14 | 0,115  |

#### 5.6 Τελεστές ITL

Με βάση την μεθοδολογία επιλέγουμε να κατανεμηθούν οι απωλειες στους ζυγούς ζήτησης και παραγωγής ισόποσα. Άρα είναι  $P_{loss, g} = P_{loss, d} = 6.7 \text{ MW}$ . Αρχικά για την ζήτηση και εφόσον όλοι οι συντελεστές είναι θετικοί( άρα δεν χρειάζεται ο υπολογισμός των U-ITL) υπολογίζουμε το γινόμενο :

$$L_{Di} = P_{Di} MLC_i^P$$

Με την πρόσθεση όλων των απωλειών παίρνουμε το άθροισμα  $P_{loss} = 29,36 \text{ MW}$ . Οποτε πρέπει να προχωρήσουμε στην κανονικοποίηση με βάση την σχέση :

$$K_i' = K_i \frac{L}{L'}$$

και έτσι λαμβάνουμε τους νέους τελεστές  $K_i'$

|   | $K_i$    |    | $K_i$    |
|---|----------|----|----------|
| 1 | 0        | 8  | 0,024269 |
| 2 | 0,013333 | 9  | 0,024155 |
| 3 | 0,031096 | 10 | 0,024292 |
| 4 | 0,024566 | 11 | 0,02379  |
| 5 | 0,021119 | 12 | 0,025228 |
| 6 | 0,023242 | 13 | 0,024498 |
| 7 | 0,024269 | 14 | 0,026256 |

### 5.7 Κανονικοποιημένοι τελεστές ITL

Με την εύρεση των νέων γινόμενων των τελεστών με τις ισχύς των ζυγών φορτίου παίρνουμε τις κατανομές των απωλειών στους ζυγούς που φαινονται στον συγκεντρωτικό πίνακα .

Για την κατανομή των αντιστοιχών απωλειών στους ζυγούς γεννητριών έχουμ ε την αντίστοιχη διαδικασία. Πάλι επειδή οι τελεστές δεν είναι αρνητικοί δεν προχωράμε στη εύρεση των U-ITL τελεστών. Με βάση τις κανονικοποιημενες τιμές των συντελεστών  $K_i'$  υπολογίζουμε με το γινόμενο των παραγόμενων ισχύων πλέον τις απωλειες στους ζυγούς . Πιο συγκεκριμένα στην εφαρμογή μας όπου ζυγός παραγωγής με παραγόμενη ισχύ είναι ο ζυγός 2 , η κατανομή των απωλειών παραγωγής σε αυτόν είναι :

$$P_{l,2,g} = 0.0133 * 40 = 0.53 \text{ MW}$$

Για τον ζυγό αναφοράς αφαιρούμε όλες τις απωλ ειες των ζυγών από τις συνολικές απωλειες παραγωγής. Έτσι έχουμε :

$$P_{l,1,g} = 6.7 - 0.53 = 6.17 \text{ MW}$$

Συνοψίζοντας τα αποτελέσματα για τις άνωθεν κατηγορίες ο διαχωρισμός των απωλειών στους ζυγούς είναι:

| Pro rata | Proportional Sharing | Z-bus | Marginal loss allocation |
|----------|----------------------|-------|--------------------------|
| 6,445692 | 6,3759               | 6,96  | 6,17                     |
| 0,507375 | 0,4134               | 0,08  | 0,81                     |
| 2,61129  | 2,62                 | 3,05  | 2,929232877              |
| 1,324587 | 1,29                 | 1,02  | 1,17426484               |
| 0,211068 | 0,16                 | 0,1   | 0,160502283              |
| 0,309837 | 0,2385               | 0,55  | 0,260310502              |
| 0        | 0                    | 0     | 0                        |
| 0        | 0                    | 0,1   | 0                        |
| 0,817212 | 0,795                | 0,64  | 0,712579909              |
| 0,248952 | 0,29                 | 0,21  | 0,218630137              |
| 0,097416 | 0,1                  | 0,06  | 0,08326484               |
| 0,169125 | 0,16                 | 0,11  | 0,153892694              |
| 0,374781 | 0,39                 | 0,28  | 0,330719178              |
| 0,412665 | 0,53                 | 0,5   | 0,391210046              |
| 13,53    | 13,3628              | 13,46 | 13,39460731              |

### 5.8 Αποτελέσματα μεθόδων κατανομής απωλειών

## ΚΑΤΑΝΟΜΗ ΑΠΩΛΕΙΩΝ ΜΕΤΑΦΟΡΑΣ ΣΤΟΥΣ ΖΥΓΟΥΣ ΜΕ ΤΗ ΒΟΗΘΕΙΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

### 6.1

Είδαμε στο κεφαλαίο 5 την διαδικασία για την κατανομή των απωλειών στους ζυγούς όταν έχουμε δεδομένα τα στοιχεία του δικτύου δηλαδή τις εν εργούς και άεργες ισχύς καθώς και τα μέτρα-γωνίες των τάσεων. Όμως στην πρακτική θεώρηση της μελέτης του προβλήματος ,σπάνια μένουν σταθερές αυτές οι ποσότητες. Ένα δίκτυο εμφανίζει μια δυναμική λειτουργία όπου κάθε μέγεθος μεταβάλλεται συνεχώς. Η μεταβολή αυτή φαίνεται από τις χρονοσειρες που είναι διαθέσιμες για κάθε περίοδο. Εξαιτίας της συνεχούς αυτής εναλλαγής των δεδομένων , επιβάλλεται ο συνεχής υπολογισμός της κατανομής των απωλειών μεταφοράς.

Για να αποφύγουμε την συχνή επανάληψη των ντετερμινιστικών μεθόδων που απαιτούν και των υπολογισμό άλλων μεγεθών που δεν μας ενδιαφέρουν άμεσα , εφαρμόζουμε την τεχνολογία των νευρωνικών δικτύων όπως αυτή αναπτύχθηκε στο Κεφαλαίο 4. Εκτός όμως από αυτή την τεχνική χρησιμοποιείται για την επίλυση του προβλήματος της κατανομής μια πιο σύγχρονη μέθοδος τεχνητής νοημοσύνης βασισμένη τόσο στα νευρωνικά δίκτυα όσο και στα ασαφή σύνολα που αναφέρθηκαν στο Κεφαλαίο 3. Η νέα αυτή τεχνική ονομάζεται νευροασαφής λογική και την χρησιμοποιούμε για την επίλυση του προβλήματος της κατανομής απωλειών.

### 6.2

#### 6.2.1

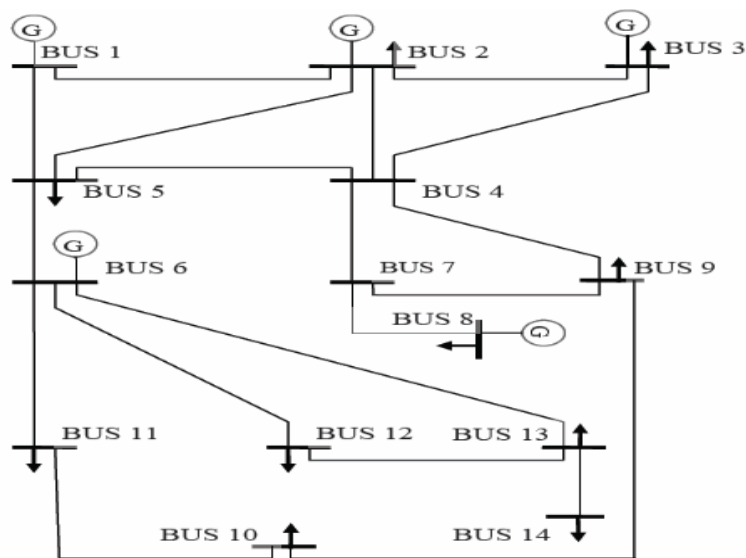
Στο κεφάλαιο αυτό περιγράφεται και αξιολογείται ως προς την επίδοση του ένα μοντέλο κατανομής των απωλειών σε ένα τυχαίο δίκτυο χρησιμοποιώντας τεχνολογίες τεχνητών νευρωνικών δικτύων. Το πρόβλημα που αντιμετωπίζεται είναι ένα δυναμικό πρόβλημα με συνεχή αλλαγή των δεδομένων του δικτύου. Το σύστημα που χρησιμοποιούμε είναι αυτό των 14 ζυγών (14-IEEE). Στο επόμενο κεφαλαίο εξετάζεται το ίδιο παράδειγμα με νευροασαφή λογική στα πρότυπα του ANFIS και κατόπιν αυτά τα δυο συγκρίνονται μεταξύ τους.

### 6.2.2 μ

Ο στόχος οποιασδήποτε μεθόδου κατανομής απώλειας είναι να ληφθεί μια λυμένη ροή ισχύος και να διανεμηθούν συστηματικά οι απώλειες μετάδοσης του συστήματος σε όλες τις συμμετέχουσες γεννήτριες και τα αντίστοιχα φορτία. Η μέθοδος Z-bus όπως αναφέραμε και παραπάνω χρησιμοποιεί τη μήτρα σύνθετης αντίστασης και το εγχειρόμενο ρεύμα ζυγών ώστε να κατανέμουν τις απώλειες συστημάτων σε όλους τους ζυγούς. Εάν ένας ζυγός περιέχει και τη γεννήτρια και το φορτίο, κατόπιν η απώλεια που διατίθεται σε εκείνον διαιρείται μεταξύ της γεννήτριας και του φορτίου χρησιμοποιώντας την αναλογική τεχνική. Η κατανομή Z-bus είναι αυτή που επιλέχθηκε για την εφαρμογή του νευρωνικού αφού χρησιμοποιείται ευρύτατα στα σύγχρονα δίκτυα και συνάμα απαιτεί λίγο γέρος υπολογισμούς εκτέλεσης ώστε να παρθούν τα απαραίτητα δεδομένα. Θα μπορούσε κατά αντιστοιχία να επιλέγει οποιαδήποτε τεχνική από αυτές που αναλύθηκαν όπως είναι οι pro rata, proportional sharing ή η marginal loss.

### 6.2.3 μ

Το IEEE δίκτυο 14 ζυγών που παρουσιάζεται στο σχήμα χρησιμοποιήθηκε ως σύστημα δοκιμής για να επεξηγήσει το αριθμητικό παράδειγμα. Το σύστημα έχει τα φορτία σε 13 ζυγούς και τις γεννήτριες σε 5 ζυγούς. Τα στοιχεία γραμμών για το σύστημα παρουσιάζονται στον πίνακα. Μπορούν να μελετηθούν δυο περιπτώσεις με την εφαρμογή του νευρωνικού. Μια περίπτωση όπου θα δίνονται τα συγκεκριμένα δεδομένα τάσεως και ισχύος και θα έχουμε στην έξοδο τις απώλειες των ζυγών. Η πιο διευρυμένη περίπτωση είναι να δίνονται χρονοσειρές με μεταβλητές τιμές των δεδομένων του δικτύου. Προφανώς η δεύτερη εφαρμογή περιλαμβάνει και την πρώτη γι' αυτό και ασχολούμαστε μόνο με αυτή. Το δίκτυο IEEE έχει αναφερθεί ξανά στην εργασία αλλά για μια πιο εποπτική παρουσίαση εμφανίζεται ξανά εδώ :



14- μ .

Για τα στοιχεία των γραμμών του συγκεκριμένου δικτύου έχουμε τον πίνακα :

| γραμμή No. | Απο Ζυγο | Προς Ζυγο | R (p.u) | X (p.u.) | B (p.u.) |
|------------|----------|-----------|---------|----------|----------|
| 1          | 1        | 2         | 0.0194  | 0.0592   | 0.0528   |
| 2          | 1        | 5         | 0.0540  | 0.2230   | 0.0528   |
| 3          | 2        | 3         | 0.0470  | 0.1980   | 0.0438   |
| 4          | 2        | 4         | 0.0581  | 0.1763   | 0.0374   |
| 5          | 2        | 5         | 0.0570  | 0.1739   | 0.0340   |
| 6          | 3        | 4         | 0.0670  | 0.1710   | 0.0346   |
| 7          | 5        | 4         | 0.0134  | 0.0421   | 0.0128   |
| 8          | 4        | 7         | 0.0001  | 0.2091   | 0        |
| 9          | 4        | 9         | 0.0001  | 0.5562   | 0        |
| 10         | 5        | 6         | 0.0001  | 0.2520   | 0        |
| 11         | 6        | 11        | 0.0950  | 0.1989   | 0        |
| 12         | 6        | 12        | 0.1229  | 0.2558   | 0        |
| 13         | 6        | 13        | 0.0662  | 0.1303   | 0        |
| 14         | 7        | 8         | 0.0001  | 0.1762   | 0        |
| 15         | 7        | 9         | 0.0001  | 0.1100   | 0        |
| 16         | 9        | 10        | 0.0318  | 0.0845   | 0        |
| 17         | 9        | 14        | 0.1271  | 0.2704   | 0        |
| 18         | 10       | 11        | 0.0820  | 0.1921   | 0        |
| 19         | 12       | 13        | 0.2209  | 0.1999   | 0        |
| 20         | 13       | 14        | 0.1709  | 0.3480   | 0        |

μ μμ

Δεδομένου ότι το σύστημα δοκιμής που περιγράφεται στην παράγραφο αυτή έχει 14 ζυγούς , και εμείς ενδιαφερόμαστε μόνο για τα πραγματικά μέρη των απωλειών τα οποία είναι και τα κοστοβορα, το προτεινόμενο ANN έχει 14 εξόδους που αντιστοιχούν στις πραγματικές απώλειες για 14 ζυγούς . Σχεδόν όλες οι μεταβλητές του συστήματος δοκιμής χρησιμοποιήθηκαν ως εισαγωγή στο νευρικό δίκτυο για να καταστήσουν το ANN ευέλικτο σε όλες τις πρακτικές καταστάσεις. Όλα τα πραγματικά και φανταστικά μέρη των φορτίων και οι πραγματικές τιμές ισχύος των γεννητριών καθώς και τα μεγέθη τάσης των ζυγών ελέγχου τάσης ( slack bus-PV bus) χρησιμοποιήθηκαν ως εισαγωγές στο νευρικό δίκτυο. Εξάλλου είναι γνωστό ότι η κατάσταση του δικτύου επηρεάζεται από κάθε μια μεταβλητή ή που αναφέρθηκε.

Εκτός από τις λειτουργικές μεταβλητές του συστήματος, η κατάσταση των γραμμών μετάδοσης (εάν η γραμμή είναι διαθέσιμη ή αποτυχημένη) μπορεί να χρησιμοποιηθεί επίσης ως είσοδος στο ANN. Αυτό μπορεί να γίνει με την βοήθεια ενός δυαδικού συστήματος όπου η κατάσταση λειτουργίας ορίζεται ως 1 και η κατάσταση μη λειτουργίας ως 0.

Η τοποθέτηση όλων των παραπάνω δεδομένων ως εισόδους σε μια και μόνο εφαρμογή καθιστά το νευρωνικό και πολύ μεγάλο σε μέγεθος και μη λειτουργικό (καθώς είναι αδύνατο να μεταβληθούν όλα τα φορτία και όλες οι παραγωγές των γεννητριών την ίδια στιγμή πόσο μάλλον που πολλά φορτία είναι και στατικά.). Στην περίπτωση αυτή θα είχαμε ένα νευρωνικό με 2x13 δεδομένα εισόδου ενεργού και άεργου ισχύος ( P-Q) από τα φορτία και 2 x 5 δεδομένα ισχύος – τάσης (P-V) από τις γεννήτριες. Θα μπορούσαν να προστεθούν και οι μεταβλητές της κατάστασης του δικτύου. Όποτε αυτομάτως θα επιθυμούσαμε ένα τεράστιο αριθμό συνδυασμών από τις 38 τιμές εισόδων κάτι που δεν είναι δυνατόν να επιλυθεί με προσωπικούς υπολογιστές . Γι'αυτο το λόγο επιλέγουμε ένα μικρότερο αριθμό εισόδων στη μελέτη μας . Σαν στοιχεία εισόδου επιλέγουμε αυτά που μεταβάλλονται με την αλλαγή του φορτίου που είναι και αυτά που μπορούμε να ελέγχουμε ανά πάσα στιγμή. Έτσι επιλέγουμε στις γεννήτριες την αλλαγή της ενεργού ισχύος και στα φορτία την αλλαγή και της ενεργού και της άεργου ισχύος .Οποιαδήποτε άλλη πιο πολύπλοκη περίπτωση είναι συνδυασμός της επιλογής που κάναμε στην εφαρμογή μας . Οι εισοδοί και το εύρος των τιμών που αυτά μεταβάλλονται στην μελέτη μας συνοψίζονται στον πίνακα:

|   |          | min value |  | max value |
|---|----------|-----------|--|-----------|
| 2 | P ( MW ) | 25        |  | 55        |
| 3 | P ( MW ) | 75        |  | 105       |
| 3 | Q (Mvar) | 14        |  | 26        |
| 4 | P ( MW ) | 35        |  | 65        |
| 4 | Q (Mvar) | -12,5     |  | 2,5       |


### 6.1 Όρια μεταβολής ισχύος στο δίκτυο

Πρέπει να επισημάνουμε ότι στην έξοδο θα έπρεπε να παίρνομε 14 αποτελέσματα όσοι είναι και οι ζυγοί του συστήματος όπου κατανέμονται οι απώλειες . Όμως επειδή στον 7<sup>ο</sup> και στον 8<sup>ο</sup> ζυγό φορτίου δεν υπάρχει τιμή ενεργού και άεργου ισχύος οι απώλειες μεταφοράς όπως είδαμε και στους ντετερμινιστικούς αλγόριθμους παραπάνω τίθενται ίσες με μηδέν. Όποτε για να μην μεγαλώσει άσκοπα το μέγεθος της εφαρμογής παραλείπονται οι έξοδοι αυτοί. Επίσης σαν στοιχεία εξόδου προσθέτουμε την τιμή της ενεργού και άεργου ισχύος του slack bus.Πρόκειται για ένα μέγεθος που μεταβάλλεται με την αλλαγή των δεδομένων έγχυσης στους άλλους ζυγούς και η γνώση του είναι απαραίτητη ώστε να εξασφαλίζεται η ισορροπία σε ένα δίκτυο. Όποτε με την τροποποίηση αυτή έχουμε 14 εξόδους στο νευρωνικό μας δίκτυο.



## 6.2.4

Αφού επιλέξουμε με ποιες εισόδους θα τροφοδοτήσουμε το δίκτυο, πρέπει να πάρουμε αποφάσεις για την σύνθεση του δικτύου. Η πρώτη απόφαση αφορά το πλήθος των κρυμμένων στρωμάτων και τον αριθμό των νευρώνων που θα έχουν αυτά. Όσον αφορά το πλήθος των στρωμάτων ένα μόνο στρώμα του κρυμμένου νευρώνα εξετάστηκε λόγω της απλότητάς των βαρών. Εξάλλου με την προσθήκη επιπλέον επιπέδων όχι μόνο δεν παρουσιάζεται βελτίωση στα αποτελέσματα όπως φαίνεται και από το παρακάτω διάγραμμα αλλά είναι χειρότερα τα αποτελέσματα. Ακόμη με την προσθήκη επιπλέον επιπέδων έγκειται το ζήτημα της επιλογής των νευρώνων που καθιστά την βέλτιστη επιλογή πολύ δύσκολη.




**μ 6.1** Απόδοση- Αριθμός επιπέδων νευρωνικού

Όσο μεγαλύτερο είναι το ύψος της κάθε στήλης τόσο το καλύτερο είναι το αποτέλεσμα αφού το ύψος δείχνει τον αριθμό των επιτυχημένων εκτιμήσεων. Για την εκτίμηση χρησιμοποιήσαμε την  $4^H$  έξοδο του νευρωνικού, ενώ και οι άλλες έξοδοι εμφανίζουν παρόμοια συμπεριφορά.

Για την επιλογή του αριθμού των νευρώνων σε κάθε κρυμμένο επίπεδο (hidden layer) και συγκεκριμένα στο ένα επίπεδο που εμείς μελετάμε η κατάσταση είναι πιο περίπλοκη γιατί ο αριθμός των νευρώνων είναι πιο μεγάλος. Η επιλογή αυτή μπορεί να γίνει με δοκιμές διαφόρων δομών ANN με επανειλημμένες εκπαιδεύσεις του νευρικού δικτύου για διαφορετικό αριθμό κρυμμένων νευρώνων στενά ώστε να προσδιορίσει ο βέλτιστος αριθμός κρυμμένων νευρώνων που παράγει τα καλύτερα χαρακτηριστικά σύγκλισης και το χαμηλότερο μέσο τετραγωνικό λάθος. Εντούτοις σαν κανόνας που μας βοήθησε στην επιλογή μας, για ένα και μόνο κρυμμένο στρώμα, ο βέλτιστος αριθμός κρυμμένων νευρώνων έχει παρατηρηθεί ότι βρίσκεται σε τιμές μεγαλύτερες του  $n$ , όπου το  $n$  είναι ο αριθμός των εισόδων. Στο παρακάτω


σχήμα δείχνουμε πως μεταβάλλεται το σφάλμα της εξόδου καθώς μεταβάλλεται ο αριθμός των νευρώνων του κρυμμένου στρώματος.



#### μ 6.2 Απόδοση- Αριθμός νευρώνων

Το διάγραμμα μας δείχνει την τιμή που παίρνει η 6<sup>η</sup> έξοδος του νευρωνικού συναρτησει των νευρώνων. Το μέγεθος δείχνει την επιτυχία του. Η ίδια αντιστοιχία υπάρχει και για τις άλλες εξόδους. Όποτε επιλέγουμε n=12 για το νευρωνικό μας. Η επιλογή αυτή έγινε γιατί στις περιπτώσεις 11,13 τα αποτελέσματα στους άλλους ζυγής ήταν χειρότερα. Η απόφαση που πάρθηκε έγινε με γνώμονα τα αποτελέσματα σε όλους τους ζυγούς.

Με βάση τα παραπάνω στοιχεία η μορφή που παίρνει το νευρωνικό δίκτυο που χρησιμοποιούμε είναι η εξής:



μ 6.3 Μορφή νευρωνικού δικτύου

## 6.2.5

μ

Τα δεδομένα εισόδου δεν μπορούν να τροφοδοτήσουν απ' ευθείας στο δίκτυο. Όπως εξηγήθηκε στο κεφάλαιο της θεωρίας των νευρωνικών αυτό θα ήταν λανθασμένο και θα περιόριζε την ικανότητα του δικτύου για γενίκευση. Έτσι επιλέγουμε να κανονικοποιήσουμε τα δεδομένα εισόδου. Θα χρησιμοποιήσουμε τον ακόλουθο μετασχηματισμό δυο βημάτων. Αρχικά κανονικοποιούμε τα δεδομένα με βάση την κανονική κατανομή μέσω της επιλογής της `matlab mapstd`. Όποτε τα δεδομένα διαμορφώνονται με βάση την μέση τιμή και την διακύμανση. Κατόπιν τροποποιούμε τα δεδομένα με την βοήθεια της εντολής `premnx`. Με αυτή τη διαδικασία όλες οι τιμές εισάγονται στο διάστημα  $[-1,1]$  τα οποία είναι και τα όρια της συνάρτησης εκμάθησης όπως φαίνεται στη συνέχεια.

Προφανώς και οι έξοδοι του δικτύου πρέπει να υπόκεινται στην ίδια ακριβώς διαδικασία ώστε να παίρνουμε τα σωστά αποτελέσματα. Αρχικά μετά την έξοδο του νευρωνικού τα αποτελέσματα κυμαίνονται μεταξύ  $[-1,1]$ . Όποτε εκτελούμε πρώτα τη διαδικασία `postmnmx` (αντίστροφη της `premnmx` στα στοιχεία εισόδου) και κατόπιν εκτελούμε την `mapstd` ('reverse'). Για την διαχείριση των τιμών αναφορά έγινε και στο θεωρητικό τμήμα.

## 6.2.6

μ


Τα ακραία σημεία στις μεταβλητές εισόδου – εξόδου απαιτούν ειδική μεταχείριση, και μπορούν να δημιουργήσουν τα εξής προβλήματα:

- Ωθούν την πλειοψηφία του συνόλου των τιμών της μεταβλητής σε πολύ περιορισμένη δυναμική περιοχή, η οποία απαιτεί εξαιρετικά υψηλή αριθμητική ακρίβεια από την υλοποίηση του αλγορίθμου.
- Η συντριπτική πλειοψηφία των παρατηρήσεων θα εμπίπτει στη γραμμική περιοχή της σιγμοειδούς συνάρτησης με αποτέλεσμα να απολεσθούν οι ιδιότητες μη - γραμμικότητας του μοντέλου.

Ως ακραία σημεία μπορούμε να ορίσουμε ασυνήθιστα υψηλές ή χαμηλές τιμές του φορτίου για τις οποίες δεν μπορεί να δοθεί κάποια λογική εξήγηση, και οι οποίες δεν επαναλαμβάνονται σε τακτά χρονικά διαστήματα. Τα ακραία σημεία πρέπει να εντοπισθούν και να απομακρυνθούν από το σύνολο των δεδομένων εκπαίδευσης.

Ένας τρόπος για να εντοπίσουμε τις ακραίες καταστάσεις είναι να παρατηρήσουμε τη γραφική παράσταση της χρονοσειράς και να απομακρύνουμε τις τιμές πέρα από τα όρια. Στο πρόγραμμα μας αυτό γίνεται με την εφαρμογή φραγμών στα δεδομένα εισόδου όπου οι τιμές τους είναι πέρα από τα όρια που ορίσαμε στον πίνακα. Επίσης μπορούμε να εκτιμήσουμε το εύρος των ακραίων τιμών όχι με τα στενά όρια που

ορίσαμε παραπάνω αλλά παίρνοντας ένα ιστόγραμμα των δεδομένων εισόδου. Έτσι παίρνοντας για παράδειγμα τα στοιχεία της εισόδου και κάνοντας το αντίστοιχο ιστόγραμμα επιλέγουμε και τα όρια των ακραίων τιμών. Η μορφή του ιστογράμματος για την πρώτη μεταβλητή εισόδων είναι :



μ 6.4 Κανονικοποιημένη μορφή εισόδου 1.

Τα αποτελέσματα έχουν προέλθει μετά από την επεξεργασία που αναφέρθηκε όποτε τα όρια είναι  $[-1,1]$  .Στην συγκεκριμένη περίπτωση βλέπουμε δυο τιμές να είναι έξω από το όριο. Με τον ίδιο τρόπο ελέγχουμε και για τις άλλες εισόδους τις ακραίες τιμές και τις οποίες απομακρύνουμε από το αρχείο δεδομένων.

### 6.2.7

Αφού καθορίσουμε το είδος και το μέγεθος του δικτύου πρέπει να εκτιμηθούν και τα δεδομένα εκπαίδευσης του δικτύου που είναι ο αριθμός εκπαίδευσης ,ο αλγόριθμος εκπαίδευσης κτλ.

Το νευρωνικό δίκτυο που αποτελεί το μοντέλο υπολογισμού των απωλειών στις γραμμές εκπαιδεύεται χρησιμοποιώντας την μέθοδο `backpropagation` και συγκεκριμένα με τη μέθοδο `Levenberg-Marquardt`.Με πειραματικές διαδικασίες βλέπουμε ότι και οι άλλες δυνατές μέθοδοι εκπαίδευσης που μελετήσαμε στο κεφαλαίο με τα νευρωνικά είναι ικανοποιητικές αλλά αυτή έχει πιο γρήγορα

αποτελέσματα .Οι αριθμοί επαναλήψεων της κάθε μεθόδου φαινεται στο παρακάτω σχήμα:


|          |  |      |
|----------|--|------|
|          |  |      |
| traingdx |  | 1000 |
|          |  |      |
| traingd  |  | 1000 |
|          |  |      |
| traingda |  | 1000 |
|          |  |      |
| traingdm |  | 1000 |
|          |  |      |
| trainlm  |  | 12   |

## 6.2 Απόδοση αλγόριθμων εκπαίδευσης

Η μεγάλη διάφορα στον αριθμό των επαναλήψεων οφείλεται στην διαφορετική λογική του αλγόριθμου trainlm. Πάντως και σε απόλυτο χρόνο η μέθοδος που χρησιμοποιείται είναι πιο γρήγορη λόγω του μικρού αριθμού επαναλήψεων μέχρι την έξοδο των αποτελεσμάτων.


Τα διαθέσιμα δεδομένα χωρίζονται σε δυο ομάδες. Η πρώτη ομάδα είναι το σύνολο των δεδομένων της εκπαίδευσης ( training data) και αποτελείται από τις τιμές 2000 περιπτώσεων εισόδου-εξόδου που έχουμε συλλέξει με την μέθοδο Z-bus.Αυτή η ομάδα ταυτόχρονα αποτελεί και ομάδα έλεγχου ( testing data) αφού τις τιμές εισόδου τις επανατοποθετούμε στο νευρωνικό και συγκρίνουμε τις τιμές εξόδου του νευρωνικού με το αρχείο των εξόδων που έχουμε υπολογίσει αρχικά. Η δεύτερη ομάδα (testing data) αποτελείται από 50 τιμές εισόδου –εξόδου που έχουμε υπολογίσει και οι οποίες είναι διαφορετικές από τις τιμές του πρώτου αρχείου δεδομένων. Το δεύτερο αυτό αρχείο είναι απαραίτητο γιατί έτσι αποφεύγουμε την περίπτωση της προσαρμογής ,αφού αν χρησιμοποιούσαμε μόνο το αρχείο εκπαίδευσης ως αρχείο έλεγχου τότε μπορεί να συνέπιπτε η ομοιότητα στα αποτελέσματα. Παίρνοντας όμως διαφορετικές τιμές σαν είσοδο αποφεύγουμε αυτή την πιθανότητα.

Σημαντικό είναι να ορίσουμε και τα σταθερά μεγέθη που είναι απαραίτητα για τη λειτουργία ενός νευρωνικού δικτύου , και στα οποία αναφερθήκαμε στην θεωρητική προσέγγιση. Έτσι θέτουμε τον ρυθμό εκμάθησης ίσο με 0,2 τη σταθερά βήματος (momentum rate) ίση με 0,8 . παράλληλα για την πιο γρήγορη εκμάθηση των νευρώνων και των επιπέδων χρησιμοποιούμε βοηθητικές συναρτήσεις αρχικοποίησης όπως είναι ο αλγόριθμος Nguyen-Widrow. Σαν συνάρτηση εκμάθησης των νευρώνων επιλέγουμε από τις πολλές εναλλακτικές την tansig η μορφή της οποίας φαίνεται στο σχήμα :



Για να βελτιώσουμε την ικανότητα των τεχνητών νευρωνικών δικτύων για γενίκευση επιλέγουμε τη μέθοδο του έγκαιρου σταματήματος της διαδικασίας της εκπαίδευσης, η οποία αναπτύσσεται στο κεφάλαιο θεωρίας. Συγκεκριμένα το δίκτυο μας εκπαιδεύεται διαδοχικά, υπολογίζεται το μέσο τετραγωνικό σφάλμα (MSE) που προκύπτει από τα δεδομένα επαλήθευσης και αν βρεθεί μικρότερο από όσο έχει οριστεί τότε σταματά η διαδικασία. Όμως ορίζουμε και ένα αριθμό επαναλήψεων ώστε ακόμη και αν το όριο του μέσου τετραγωνικού σφάλματος να μην έχει επιτευχθεί η διαδικασία να σταματά. Παράλληλα υπάρχει ένα ανώτατο επιτρεπόμενο όριο του πλήθους των εποχών, ώστε να μην οδηγηθούμε σε μια ατέρμονη διαδικασία. Με αυτόν τον τρόπο, όχι μόνο αποφεύγουμε το ενδεχόμενο απομνημόνευσης των δεδομένων της εκπαίδευσης, αλλά ταυτόχρονα καθιστούμε τη διαδικασία της εκπαίδευσης λιγότερο χρονοβόρα. Στην εφαρμογή το όριο του MSE επιλέχθηκε να είναι ίσο με 0,001 ώστε να έχουμε καλύτερα αποτελέσματα.

Παρακάτω φαίνεται το διάγραμμα που δείχνει πως μεταβάλλεται το μέσο τετραγωνικό σφάλμα μετά από την εκπαίδευση του δικτύου:



**μ 6.5** Μέσο τετραγωνικό σφάλμα συναρτήσει αριθμού επαναλήψεων

Παρατηρούμε ότι το μέσο τετραγωνικό σφάλμα, των δεδομένων εκπαίδευσης αρχικά μειώνεται απότομα και στη συνέχεια με αργότερους ρυθμούς. Μετά από κάποιο σημείο, υπάρχει ελάχιστη πτώση στο τετραγωνικό σφάλμα και αυτό σημαίνει ότι η διαδικασία δεν βελτιώνεται και άλλο όποτε και πρέπει να σταματήσει.


Στην συγκεκριμένη περίπτωση ορίσαμε ένα πολύ μικρό ποσοστό σφάλματος ώστε να είναι πιο ακριβή τα αποτελέσματα. Δεχτήκαμε τιμή σφάλματος  $MSE=0,001$  το οποίο ικανοποιείται μετά από την 12 επανάληψη της εκμάθησης.

## 6.2.8

### μ

Μετά την εκμάθηση του νευρωνικού η διαδικασία δημιουργίας αυτού έχει ολοκληρωθεί. Μπορούμε πλέον με κάθε στοιχείο εισόδου να λάβουμε τις αντίστοιχες τιμές εξόδου. Όμως πρέπει να ελέγξουμε κατά πόσον το νευρωνικό μας δίκτυο βγάζει σωστά αποτελέσματα. Ο έλεγχος λοιπόν είναι το επόμενο και πιο σημαντικό βήμα της λειτουργίας του νευρωνικού και γίνεται με την βοήθεια τόσο του αρχείου εκμάθησης που περιέχει οπός αναφέραμε 2000 δεδομένα όσο και με ενός αλλού ανεξάρτητου αρχείου έλεγχου 50 δεδομένων.


Στο γράφημα που ακολουθεί βλέπουμε την διάφορα που έχουν τα δεδομένα εξόδου όπως προκύπτουν από το νευρωνικό δίκτυο από τα δεδομένα που υπολογίσαμε με την μέθοδο Z-bus για την 14 έξοδο του προβλήματος μας. Η επιλογή αυτή είναι ενδεικτική. Σαν δεδομένα παίρνουμε το αρχείο εκμάθησης.



μ 6.6. Διαφορά αναμενόμενων-υπολογισμένων τιμών.



Το αντίστοιχο διάγραμμα για τα δεδομένα του αρχείου έλεγχου είναι :




**μ 6.6.** Διαφορά αναμενόμενων-υπολογισμένων τιμών-αρχείο έλεγχου.

Παρατηρούμε ότι η διάφορα είναι πολύ μικρή που δείχνει σωστή λειτουργία του νευρωνικού . Επίσης μεγάλη σημασία έχει και η τυχαιοτητα της διακύμανσης κάτι που δείχνει ότι το δίκτυο δεν έχει υπερδιαμορφωθεί ώστε να βγάζει τα ίδια αποτελέσματα ανεξάρτητα άπατα δεδομένα εισόδου.


Ένας δείκτης για την αξιολόγηση του νευρωνικού μας είναι αυτός που μας δείχνει για κάθε ποσοστό του σφάλματος πόσες τιμές εξόδου είναι κάτω από το όριο αυτό . Πρόκειται για την συνάρτηση αθροιστικής πιθανότητας . Τα αντίστοιχα διαγράμματα για τις εξόδους του ANN μας φαινονται στο παρακάτω σχήμα. Αυτό το μέγεθος είναι το πιο σημαντικό γιατί μας δίνει συνοπτικά την επιτυχία του ANN. Μπορούμε να επιλέξουμε το ποσοστό σφάλματος που επιθυμούμε και να ελέγξουμε την επιτυχία του νευρωνικού μας .Αλλά και αντίστροφα μπορούμε ανάλογα με την επιτυχία που επιθυμούμε να δούμε το εύρος σφάλματος που θα έχουμε. Για την γενικότητα του θέματος παρουσιάζονται τα διαγράμματα και για τις 14 εξόδους του δικτύου όποτε ελέγχουμε και ποια έξοδο αποκλίνει πιο πολύ από τα σωστά μεγέθη.

Αρχικά για τις 6 πρώτες μεταβλητές εξόδου :




**μ 6.7.** Απόδοση –εύρος τιμών 1-6 εξόδου.

Για τις επόμενες 6 μεταβλητές εξόδου :



**μ 6.7.** Απόδοση –εύρος τιμών 7-12 εξόδου.


Για τις 2 τελευταίες :




**μ 6.7.** Απόδοση –εύρος τιμών 13-14 εξόδου.

Από τα διαγράμματα παρατηρούμε αυτό που αναμέναμε. Όσο αυξάνεται το ποσοστό εύρους που κινούνται οι τιμές τόσο πιο υψηλό είναι το ποσοστό επιτυχίας. Βλέπουμε ότι για υψηλό σφάλμα (> 5%) η επιτυχία της εξόδου είναι 100%. Και για τις περισσότερες μεταβλητές όμως η σωστή τιμή της εξόδου επιτυγχάνεται σε τιμές μικρού σφάλματος. Εξάιρεση αποτελεί η μεταβλητή 4 όπου για χαμηλές τιμές σφάλματος η επιτυχία των αποτελεσμάτων δεν είναι υψηλή. Ενδεικτικά για ποσοστό σφάλματος 3% το ποσοστό επιτυχημένων αποτελεσμάτων είναι 85,8% .


Για την ολοκλήρωση του έλεγχου πρέπει να μελετηθεί και το αρχείο δεδομένων έλεγχου αφού τα παραπάνω διαγράμματα αφορούσαν τα δεδομένα εκμάθησης. Τα αντίστοιχα διαγράμματα είναι πλέον :



**μ 6.8.** Απόδοση –εύρος τιμών 1-6 εξόδου-αρχείο έλεγχου.



**μ 6.8.** Απόδοση –εύρος τιμών 7-12 εξόδου-αρχείο έλεγchu.



**μ 6.8.** Απόδοση –εύρος τιμών 13-14 εξόδου-αρχείο έλεγchu.

Σε όλα τα διαγράμματα η οριζόντια στήλη είναι το ποσοστό σφάλματος και ο κατακόρυφος το ποσοστό επιτυχίας των δεδομένων εξόδου.

Τα αποτελέσματα είναι χειρότερα από ότι με τα δεδομένα εκμάθησης όμως είναι εξίσου ικανοποιητικά. Σε χαμηλά σφάλματα υπάρχει μεγαλύτερη απόκλιση όμως σε λίγο μεγαλύτερα περιθώρια σφάλματος η επιτυχία φτάνει το 100 %. Όπως και στα

δεδομένα εκμάθησης ,την μεγαλύτερη απόκλιση από τις πραγματικές τιμές τις έχει η 4<sup>Η</sup> έξοδος του ANN.

Παρακάτω σε ένα συνοπτικό πίνακα παρουσιάζεται για κάθε έξοδο το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) και ο αριθμός των δεδομένων με σφάλμα άνω του 5%. Η αριθμητική διατύπωση είναι απαραίτητη για την πλήρη αποτύπωση της αξιολόγησης του νευρωνικού.

|    | PE     | μ | μ | μ    | μ 5% |
|----|--------|---|---|------|------|
| 1  | 0,763  |   |   | 2000 |      |
| 2  | 0,0887 |   |   | 2000 |      |
| 3  | 0,0242 |   |   | 1998 |      |
| 4  | 0,0014 |   |   | 1859 |      |
| 5  | 0,0151 |   |   | 1996 |      |
| 6  | 0,0074 |   |   | 1998 |      |
| 7  | 0,0002 |   |   | 2000 |      |
| 8  | 0,0006 |   |   | 2000 |      |
| 9  | 0,0019 |   |   | 2000 |      |
| 10 | 0,0005 |   |   | 2000 |      |
| 11 | 0,0002 |   |   | 2000 |      |
| 12 | 0,0002 |   |   | 2000 |      |
| 13 | 0,0005 |   |   | 2000 |      |
| 14 | 0,0006 |   |   | 2000 |      |

### 6.3 Απόδοση νευρωνικού δικτύου

Το MAPE ορίζεται από τη σχέση:

$$MAPE = \frac{1}{N} \sum_{i=1}^N |t_p - o_p|$$

όπου N :το πλήθος των δεδομένων (εδώ 2000).

$t_p$  : Οι έξοδοι του νευρωνικού.

$o_p$  : Οι πραγματικές τιμές εξόδου.

### 6.3

Από τη παραπάνω μελέτη στο νευρωνικό δίκτυο βλέπουμε ότι τα αποτελ έσματα για την κατανομή των απωλειών στον 2<sup>Ο</sup> ζυγό(4<sup>Η</sup> έξοδο) δεν ήταν τα επιθυμητά. Η απόκλιση από τις αναμενόμενες τιμές είναι λίγο μεγαλύτερη από τις άλλες αποκλίσεις τόσο για το αρχείο με τα δεδομένα εκπαίδευσης όσο και για το αρχείο με τα δεδομένα έλεγchu. Αυτό οφείλεται στο γεγονός των πολλών εξόδων του δικτύου όποτε είναι δύσκολη η εκπαίδευση του δικτύου ώστε να προκύπτουν επιθυμητά αποτελέσματα και για τις 14 εξόδους ταυτόχρονα. Μάλιστα φαίνεται ότι το πρόβλημα το έχει η


έξοδος όπου οι τιμές τις μεταβάλλονται σε μεγαλύτερο βαθμό με βάση τα δεδομένα εισόδου που έχουμε επιλέξει.

Για την περίπτωση αυτή όπου έχουμε ταχεία μεταβολή των δεδομένων επιλέγουμε να απομονώσουμε τα δεδομένα εξόδου του 2<sup>0</sup> ζυγού και με βάση τα ίδια δεδομένα εισόδου να δημιουργήσουμε ένα νέο νευρωνικό με μόνο όμως μια έξοδο πλέον. Προφανώς την ίδια λογική θα μπορούσαμε να την είχαμε εφαρμόσει εξαρχής. Να είχαμε αναπτύξει 14 διαφορετικά νευρωνικά με τα ίδια δεδομένα εισόδων και ξεχωριστή έξοδο. Μάλιστα θα περιμέναμε καλύτερα αποτελέσματα ποιοτικά. Όμως αυτό θα απαιτούσε πολύ χρόνο στην εκτέλεση, μεγάλη ικανότητα επεξεργασίας από το υπολογιστικό μας σύστημα και πολλαπλάσιο χώρο αποθήκευσης των νευρωνικών μας. Από την στιγμή κιόλας που τα αποτελέσματα είναι απολύτως ικανοποιητικά με την χρήση ενός και μόνο νευρωνικού δικτύου η λύση που προτείνεται εδώ είναι χρήσιμη μόνο για ακραίες περιπτώσεις όπως αυτή που θα μελετήσουμε στη συνέχεια.

### 6.3.1

Για τα δεδομένα εισόδου-εξόδου την επεξεργασία αυτών και την διαχείριση των ακραίων τιμών ισχύουν όσα ακριβώς αναφέραμε και στη παραπάνω μελέτη. Για την επιλογή του αριθμού των επιπέδων και των αριθμό των νευρώνων σε κάθε επίπεδο πάλι πρέπει να κάνουμε τις επαναλήψεις ώστε να βρούμε τον κατάλληλο συνδυασμό. Το νευρωνικό μας είναι περιορισμένο σε έκταση με μόνο μια έξοδο και 5 εισόδους οπότε ένα μόνο επίπεδο αρκεί για την υλοποίηση του. Για τον αριθμό των νευρώνων στο επίπεδο αυτό παίρνουμε πάλι την πειραματική διαδικασία που ακολουθήθηκε παραπάνω.

Με βάση πάλι το μέσο τον αριθμό επιτυχημένων στοιχείων εξόδου έχουμε :




**μ 6.9** Επιλογή νευρώνων –ειδική περίπτωση.

Οι διαφορές στις τιμές είναι πολύ μικρή οπότε επιλέγουμε τυχαία την τιμή των 7 νευρώνων στο κρυφό επίπεδο.

### 6.3.2

Όσον αφορά τις τιμές των αρχείων εκπαίδευσης (training data) και έλεγχου (testing data) παίρνουμε τα ίδια. Για την επιλογή της μεθόδου εκπαίδευσης ξανά επιλέγουμε από τις δυνατές μεθόδους πάλι την `trainlm` αφού απαιτεί μικρό αριθμό επαναλήψεων για την έξοδο των αποτελεσμάτων. Ο χρόνος που απαιτείται για την εκπαίδευση του νευρωνικού με την μέθοδο αυτή είναι 3 sec. Η καμπύλη του MSE είναι:




μ 6.10 Μέσο τετραγωνικό σφάλμα-αριθμός επαναλήψεων ειδικής περίπτωσης .

Η μορφή της καμπύλης του mse είναι η αναμενόμενη με γρήγορη πτώση στην αρχή και αργή στο τέλος. Ο αριθμός των επαναλήψεων που απαιτούνται είναι 34.

### 6.3.3

μ


Μετά την εκπαίδευση του δικτύου σειρά έχει η αξιολόγηση των εξόδων. Κατ' αντιστοιχία με την παραπάνω διαδικασία αρχικά σχεδιάζουμε την διαφορά των αποτελεσμάτων από το νευρωνικό και των εξόδων που έχουμε ως δεδομένα. Με βάση τις διαφορές σχεδιάζεται το διάγραμμα εύρους σφάλματος – επιτυχίας δεδομένων για τα στοιχεία του ζυγού 2. Αρχικά με βάση το αρχείο εκμάθησης έχουμε το διάγραμμα:



**μ 6.11.** Απόδοση –εύρος τιμών ειδική περίπτωση.

Βλέπουμε ότι το ποσοστό επιτυχίας είναι από την αρχή πολύ υψηλό. Όποτε το σφάλμα έχει ελαχιστοποιηθεί και η ακρίβεια των αποτελεσμάτων είναι μεγάλη. Το ανεξάρτητο δίκτυο μας βοήθα να πάρουμε ορθότερα αποτελέσματα.

Το αντίστοιχο διάγραμμα σχεδιάζεται και για το αρχείο έλεγχου :



**μ 6.11.** Απόδοση –εύρος τιμών ειδική περίπτωση –αρχείο έλεγχου.



Ενώ στην αρχή και για μικρό εύρος σφάλματος η βελτίωση του αλγόριθμου δεν είναι εμφανής παρατηρείται ότι για μεγαλύτερο εύρος σφάλματος ( $> 4\%$ ) η επιτυχία των αποτελεσμάτων είναι υψηλότερη από την γενικότερη εφαρμογή που προηγήθηκε. Η επιτυχία των εξόδων είναι  $100\%$ .

Υπολογίζουμε και το MAPE που είναι ίσο με  $3.0152e^{-4}$  μικρότερο από την αντίστοιχη τιμή που υπολογίστηκε παραπάνω κάτι που δείχνει την βελτίωση των αποτελεσμάτων.

Οριστικοποιήθηκε η μελέτη για τα νευρικά δίκτυα. Το επόμενο στάδιο είναι η μελέτη της εφαρμογής με την πολύ σύγχρονη μεθοδολογία της νευρο ασαφούς λογικής. Πριν όμως την εφαρμογή προηγείται μια θεωρητική αναφορά.

## 6.4

### 6.4.1

Η βασική δομή του τύπου fis που μελετήσαμε ως εδώ είναι ένα πρότυπο που χαρτογραφεί τα χαρακτηριστικά εισόδου στις συναρτήσεις συμμετοχής εισόδου, τις συναρτήσεις στους κανόνες, κανόνες σε ένα σύνολο χαρακτηριστικών εξόδου, τα χαρακτηριστικά εξόδου στις συναρτήσεις συμμετοχής εξόδου, και αυτές σε μια single-valued έξοδο ή μια απόφαση. Έχουμε εξετάσει μόνο συναρτήσεις συμμετοχής που επιλέχθηκαν αυθαίρετα και γενικά οι δράσεις σε όλα τα βήματα είναι προκαθορισμένες.


Έστω ότι θέλουμε να εφαρμόσουμε τις ιδιότητες των ασαφών συνόλων σε ένα σύστημα για το οποίο έχουμε ήδη μια συλλογή των εισόδου-εξόδου στοιχείων που θα επιθυμούσαμε να χρησιμοποιήσουμε για τη διαμόρφωση, την πρότυπη -ακολουθία, ή κάποια παρόμοια περίπτωση. Δεν χρειάζεται να έχουμε απαραίτητως μια προκαθορισμένη πρότυπη δομή στα χαρακτηριστικά των μεταβλητών στο σύστημά μας.

Σε μερικές καταστάσεις διαμόρφωσης, δεν μπορούμε να διακρίνουμε τις ιδιότητες που πρέπει να έχουν οι συναρτήσεις συμμετοχής απλά παρακολουθώντας τα δεδομένα. Αντί λοιπόν να ρυθμίζουμε εμείς αυτές τις συναρτήσεις, αυτές ρυθμίζονται με τέτοια τρόπο ώστε να ακολουθούν τα δεδομένα εισόδων -εξόδων.

Πλέον αναφερόμαστε στα νευρο-ασαφή συστήματα όπου όπως φαίνεται είναι συνδυασμός των fis και των νευρωνικών δικτύων. Η δομική μονάδα των συστημάτων αυτών είναι οι ασαφείς νευρώνες.

### 6.4.2

Οι ασαφείς νευρώνες έχουν τη μορφή που φαίνεται στο παρακάτω σχήμα:



**μ 6.12** Μορφή ασαφούς νευρώνα

με  $x_1, x_2, \dots, x_m$  οι είσοδοι του νευρώνα.

$w_1, w_2, \dots, w_m$  τα βάρη των συνάψεων.

$f$  η συνάρτηση συμμετοχής του νευρώνα

$a$  η συνάρτηση ενεργοποίησης του νευρώνα.

$y$  η έξοδος του νευρώνα.

Οι ασαφείς νευρώνες διακρίνονται σε νευρώνες συμμετοχής και σε λειτουργικούς νευρώνες. Παρακάτω γίνεται αναφορά στα χαρακτηριστικά κάθε κατηγορίας ασαφών νευρώνων.

#### 6.4.2. μμ

Οι συνηθέστερες μορφές συναρτήσεων συμμετοχής είναι η τριγωνική, η γκαουσιανή, η τραπεζοειδής, η κανονική κοκ. Οι παραπάνω συναρτήσεις συμμετοχής μπορούν να υλοποιηθούν με τη χρήση ενός νευρώνα. Η συνάρτηση συμμετοχής μπορεί να υλοποιηθεί θεωρώντας ότι ο νευρώνας δέχεται ως είσοδο το  $x$  και δίνει έξοδο  $A(x)$  απαιτώντας η συνάρτηση συμμετοχής του να έχει τη μορφή  $A$ . Αν δηλαδή υποθέσουμε ότι η συνάρτηση συμμετοχής είναι η κανονική, τότε για να υλοποιηθεί πρέπει η συνάρτηση ενεργοποίησης να είναι :

$$a(u) = \exp\left(-\frac{(u-m)^2}{\sigma^2}\right)$$

Όπου  $m$  το κέντρο της συνάρτησης συμμετοχής και  $\sigma$  το εύρος της.

#### 6.4.2.

Με τον ίδιο τρόπο μπορούν να υλοποιηθούν οι βασικές πράξεις των ασαφών συνόλων. Οι πράξεις αυτές στηρίζονται σε λειτουργίες όπως η  $\tau$ -νόρμα ή  $\sigma$ -νόρμα, το ασαφές συμπλήρωμα κλπ. Οι παραπάνω λειτουργίες μπορούν να αντικαταστήσουν τη συνάρτηση ενεργοποίησης του νευρώνα αν θεωρήσουμε ότι οι είσοδοι δεν αθροίζονται πολλαπλασιασμένοι με βάρη όπως στους κλασσικούς νευρώνες. Για να μπορούμε όμως να εφαρμόσουμε τους αλγόριθμους μάθησης (πχ τον backpropagation αλγόριθμος αντίστροφης διάδοσης) θα πρέπει οι λειτουργίες να είναι παραγωγίσιμες.

Για την υλοποίηση των ασαφών λειτουργιών μπορούμε να επεκτείνουμε την έννοια της συνάρτησης μεταφοράς του νευρώνα. Στην περίπτωση αυτή ο νευρώνας δεν υλοποιεί το αναλυτικό γινόμενο της εισόδου με το διάνυσμα των βαρών αλλά την πράξη της συγκεκριμένης ασαφούς λειτουργίας θεωρώντας ότι όλα τα βάρη είναι 1. Ως συνάρτηση συμμετοχής λαμβάνεται η :

$$a(u) = \begin{cases} 1, & u > 1 \\ u, & 0 \leq u \leq 1 \\ 0, & u < 0 \end{cases}$$

#### 6.4.2.

Παραπάνω αναφερθήκαμε στη σύνθεση των ασαφών σχέσεων. Η πράξη της σύνθεσης αποτελεί μια γενίκευση της πράξης του αναλυτικού γινομένου των διανυσμάτων και υλοποιείται από τη συνάρτηση μεταφοράς  $f$  των νευρώνων. Η μορφή του νευρώνα είναι η ίδια και ορίζεται από τις εξισώσεις:


$$f = \bigcup_{i \in Nm} (x_i, w_i)$$

$$y = a(u)$$

όπου  $\bigcup$  είναι μια  $\sigma$ -νόρμα και  $t$  είναι μια  $\tau$ -νόρμα. Ως συνάρτηση ενεργοποίησης θεωρείται η συνάρτηση αναρρίχησης. Παρατηρούμε ότι η  $\sigma$  ο συνθετικός νευρώνας είναι μια γενίκευση του κλασσικού νευρώνα, αφού η πράξη της φραγμένης άθροισης, η οποία εξασφαλίζεται από τη συνάρτηση ενεργοποίησης είναι μια ειδική περίπτωση της φραγμένης ένωσης, ενώ το γινόμενο είναι μια ειδική περίπτωση της ασαφούς τομής.

### 6.4.3 ANFIS (Adaptive Neuro-Fuzzy Inference System)

Στην παράγραφο αυτή θα ασχοληθούμε με τον τρόπο με τον οποίο μπορούμε να κατασκευάσουμε ένα νευρο-ασαφές σύστημα, το οποίο προσαρμόζει τα βάρη του έτσι ώστε να αναπαριστά ένα άγνωστο σύστημα από ένα σύνολο δεδομένων. Συγκεκριμένα θα εστιάσουμε στο anfis, το οποίο είναι ένα νευροασαφές δίκτυο που προτάθηκε από τον Jang το 1992, και το οποίο θα χρησιμοποιήσουμε για την πρόβλεψη των απωλειών ενέργειας στο δίκτυο. Το δίκτυο αυτό στηρίζεται στην πολύ-υποθετική προσεγγιστική συλλογιστική και στην εξαγωγή συμπεράσματος που προτείνεται από τους Sugeno-Takagi. Η δομή του anfis φαίνεται στο παρακάτω διάγραμμα:



μ 6.13 Μορφή ANFIS.

Η μορφή του κανόνα  $j$  που αναπαριστά το δίκτυο είναι η εξής:

ΑΝ  $x_1$  ΕΙΝΑΙ  $A_1^{(j)}$  ΚΑΙ  $x_2$  ΕΙΝΑΙ  $A_2^{(j)}$  ΚΑΙ...ΚΑΙ  $x_d$  ΕΙΝΑΙ  $A_d^{(j)}$  ΤΟΤΕ:

$$y = f_j(x_1, x_2, \dots, x_d) = c_o^j + c_1^j x_1 + c_2^j x_2 + \dots + c_d^j x_d$$

Ας θεωρήσουμε ένα παράδειγμα συστήματος που αποτελείται από δύο εισόδους  $x_1$  και  $x_2$  και 2 κανόνες:

#### ΚΑΝΟΝΑΣ 1

ΑΝ  $x_1$  ΕΙΝΑΙ  $A_1^{(1)}$  ΚΑΙ  $x_2$  ΕΙΝΑΙ  $A_2^{(1)}$  ΤΟΤΕ:

$$y = f_1(x_1, x_2) = c_o^1 + c_1^1 x_1 + c_2^1 x_2$$

## ΚΑΝΟΝΑΣ 2

ΑΝ  $x_1$  ΕΙΝΑΙ  $A_1^{(2)}$  ΚΑΙ  $x_2$  ΕΙΝΑΙ  $A_2^{(2)}$  ΤΟΤΕ:

$$y = f_2(x_1, x_2) = c_0^2 + c_1^2 x_1 + c_2^2 x_2$$

Όταν η είσοδος του συστήματος είναι  $[x_1, x_2]$  τότε η έξοδος του θα δίδεται από τη σχέση:

$$y = \frac{r_1 f_1 + r_2 f_2}{r_1 + r_2} = r_1' f_1 + r_2' f_2$$

Όπου  $r_1, r_2$  είναι οι βαθμοί συσχέτισης των εισόδων με τις υποθέσεις των κανόνων. Το δίκτυο αποτελείται από 6 επίπεδα. Παρακάτω αναλύονται οι λειτουργίες και τα χαρακτηριστικά κάθε επιπέδου.

### Επίπεδο 1

Κάθε κόμβος του επιπέδου αυτού περνάει τις εισόδους στο επόμενο επίπεδο.

### Επίπεδο 2

Το δεύτερο επίπεδο αποτελείται από νευρώνες συμμετοχής. Σε κάθε κόμβο αναπαριστάται μια συνάρτηση συμμετοχής ενός ασαφούς συνόλου που ορίζεται στο πεδίο ορισμού κάθε εισόδου. Οι νευρώνες αυτού του επιπέδου διαχωρίζονται σε υποκατηγορίες κάθε μία από τις οποίες απεικονίζει την ασαφή διαμέριση του πεδίου ορισμού της αντίστοιχης εισόδου. Στην περίπτωση του προηγούμενου παραδείγματος έχουμε δύο υποκατηγορίες νευρώνων συμμετοχής που αναπαριστούν τα ασαφή υποσύνολα  $A_1^{(1)}, A_2^{(1)}, A_1^{(2)}, A_2^{(2)}$ . Αν οι συναρτήσεις συμμετοχής έχουν τη μορφή καμπάνας τότε :

$$A_i^j = \exp\left\{-\left[\frac{x_i - m_i^j}{\sigma_i^j}\right]^2\right\}^{b_i^j}$$

όπου  $m_i^j, \sigma_i^j, b_i^j$  οι παράμετροι των συναρτήσεων συμμετοχής που πρέπει να καθοριστούν κατά τη διάρκεια της μάθησης. Αυτές οι παράμετροι ονομάζονται παράμετροι υποθέσεων. Για να μπορούν να χρησιμοποιηθούν κλασσικοί αλγόριθμοι μάθησης θα πρέπει οι συναρτήσεις συμμετοχής που χρησιμοποιούνται να είναι συνεχείς και κατά διαστήματα παραγωγίσιμες.

### Επίπεδο 3

Οι νευρώνες που συνιστούν αυτό το επίπεδο είναι λειτουργικοί νευρώνες που υλοποιούν την πράξη της  $\tau$ -νόρμας. Κάθε νευρώνας αντιστοιχεί σε έναν κανόνα. Οι εισόδοι των νευρώνων αυτών είναι οι τιμές των συναρτήσεων συμμετοχής των υποθέσεων του κανόνα, που προέρχονται από τις εξόδους του επιπέδου 2. Η έξοδος κάθε νευρώνα του επιπέδου 3 είναι ο βαθμός ενεργοποίησης του κανόνα.

### Επίπεδο 4

Το επίπεδο αυτό περιέχει τον ίδιο αριθμό νευρώνων με το προηγούμενο και υπολογίζει τους κανονικοποιημένους βαθμούς ενεργοποίησης των κανόνων.

### Επίπεδο 5

Κάθε νευρώνας  $j$  του επιπέδου αυτού υπολογίζει το συμπέρασμα του  $j$  κανόνα. Το επίπεδο αυτό έχει 2 κόμβους και 3 παραμέτρους για κάθε κόμβο. Οι παράμετροι αυτοί ονομάζονται παράμετροι συμπερασμάτων.

### Επίπεδο 6

Στο επίπεδο αυτό υπάρχει ένας μόνο νευρώνας ο οποίος αθροίζει χωρίς βάρη τις εισόδους και δίδει το τελικό αποτέλεσμα στην έξοδο.

## 6.5

### 6.5.1


Το δεύτερο μοντέλο υπολογισμού των απωλειών των ζυγών έχει δομή παρόμοια με αυτή του πρώτου. Η κύρια διαφορά τους έγκειται στο ότι η μονάδα του δεύτερου υπολογισμού δεν είναι τεχνητά νευρωνικά δίκτυα αλλά νευροασαφή δίκτυα τύπου ANFIS. Οι εισόδοι του δεύτερου μοντέλου είναι όπως ακριβώς αυτές του πρώτου. Συγκεκριμένα παίρνουμε 6 δεδομένα εισόδου μέσα σε ένα περιορισμένο εύρος τιμών. Οι επιλογές είναι οι άεργες και ενεργές ισχύς των φορτίων και οι ενεργές ισχύς των γεννητριών.

Επίσης σημειώνουμε ότι οι εισόδοι και οι επιθυμητές έξοδοι(targets) των νευροασαφών δικτύων δε χρειάζεται να κλιμακωθούν και να κανονικοποιηθούν , αφού οι συναρτήσεις συμμετοχής προσαρμόζουν το πεδίο ορισμού τους στο εύρος αυτών των εισόδων. Όμως εδώ δεν παραλείπουμε το βήμα αυτό για να φανεί η μεγάλη ομοιότητα στις δυο μεθόδους αλλά και για να τις κρίνουμε με βάση την ίδια αλληλουχία επεξεργασίας των δεδομένων. Όποτε και εδώ κανονικοποιούμε τα δεδομένα με την βοήθεια της συνάρτησης επεξεργασίας `premnmx` όπου όπως είδαμε στα νευρωνικά δίκτυα οι τιμές δεδομένων κανονικοποιούνται ανάμεσα στο διάστημα  $[-1,1]$ .

Όσο αφορά στη διαχείριση των ακραίων σημείων , αυτά αφαιρούνται με τον τρόπο που εξηγήσαμε στην παράγραφο όπου και εδώ η ομοιότητα με τα νευρωνικά δίκτυα είναι εμφανής .Συγκεκριμένα παίρνουμε το ιστόγραμμα των δεδομένων εισόδου και ανάλογα με τη μορφή αυτού καθορίζουμε το όριο των τιμών που δεχόμαστε και απορρίπτουμε τις υπόλοιπες.

Είδαμε λοιπόν ότι όσον αφορά τα δεδομένα εισόδου οι αλλαγές είναι απειροελάχιστες. Εκεί που διαφέρουν τα ANFIS από τα νευρωνικά είναι στην δομή τους . Αποτελούνται και αυτά από νευρώνες που είναι σε ένα κρυφό επίπεδο . Μεγάλη σημασία παίζει η επιλογή της συνάρτησης συμμετοχής των νευροασαφών που εδώ ορίζεται η `rimf`.

Το διάγραμμα αυτής δίνεται στη συνέχεια :



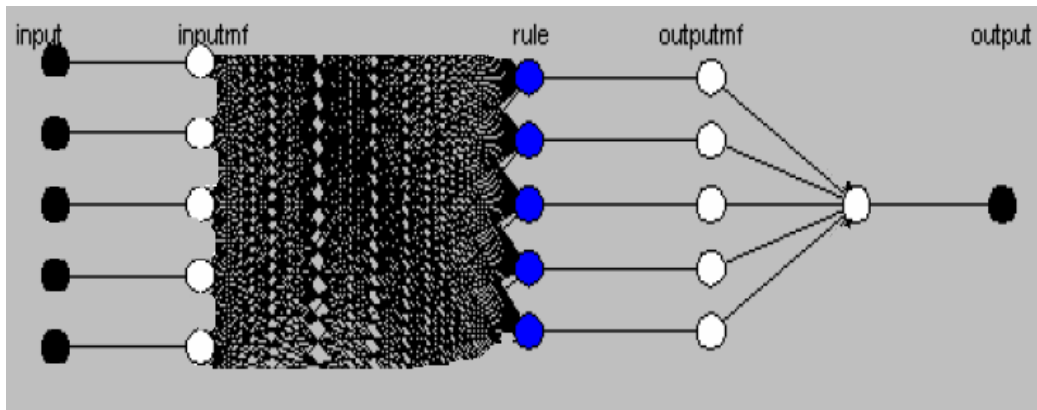
**μ 6.14** Συνάρτηση συμμετοχής .

Επίσης σε αντίθεση με τα νευρωνικά ορίζεται και ο αριθμός των συναρτήσεων συμμετοχής ανά είσοδο που συμβολίζεται με *mfs*. Το αρχείο αυτό επιλέχθηκε ίσο με :

`mfs=[2 2 2 2 2];`

Η μεγάλη διάφορα όμως είναι ότι με τα ANFIS μπορούμε να έχουμε μόνο μια έξοδο και όχι ένα δίκτυο με πολλές εξόδους όπως είχαμε στα ANN. Όποτε η μορφή τους είναι σαν την ιδιαίτερη περίπτωση των νευρωνικών. Πρέπει να αναπτύξουμε 14 διαφορετικά ANFIS ,κάθε ένα και για την διαφορετική έξοδο του συστήματος. Γι'αυτό και ο χρόνος εκτέλεσης της διαδικασίας είναι μεγαλύτερος από ότι στο ANN. Όμως το θετικό στοιχείο είναι ότι ανάλογα με την τιμή τις εξόδου κάθε δίκτυο αναπτύσσεται ξεχωριστά με τις ιδιαιτερότητες του όποτε αναμένουμε καλύτερα και πιο ακριβή αποτελέσματα.

Κατά αντιστοιχία παρουσιάζουμε την μορφή που παίρνει το AN FIS δίκτυο μας όπου και φαινονται οι διαφορες με το ANN.



**μ 6.15** ANFIS εφαρμογής .

Το προφανές στη διαγραμματική απεικονίσει είναι η μια έξοδος του δικτύου η οποία προέρχεται μετά από τις εντολές –κανόνες οι οποίες ορίζονται όπως αναφέρθηκαν στα ασαφή σύνολα..


Η εκπαίδευση των νευροασαφών δικτύων γίνεται με μια υβριδική μέθοδο που είναι συνδυασμός του αλγορίθμου backpropagation και της μεθόδου των ελαχίστων τετραγώνων.

## 6.5.2 ANFIS

Όπως είδαμε οι ομοιότητες στις δυο μεθόδους είναι πολλές παρόλο που στην τεχνική της εξαγωγής των αποτελεσμάτων (μορφή του δικτύου) διαφέρουν αρκετά. Η διάφορα αυτή αποτυπώνεται και στην έξοδο των αποτελεσμάτων . Για την σύγκριση των δυο μεθόδων επιλέγουμε το ίδιο μέτρο. Συγκεκριμένα υπολογίζουμε τις σωστές εκτιμήσεις των αποτελεσμάτων σε συνδυασμό με το σφάλμα. Για κάθε δεδομένο εύρος σφάλματος υπολογίζουμε τον αριθμό των σωστών προβλέψεων.




Αρχικά παρουσιάζουμε για την έξοδο 4 (ζυγός 2) την διάφορα των υπολογισμένων από τις αναμενόμενες τιμές για όλα τα στοιχεία του συνόλου εκπαίδευσης κατά αντιστοιχία με το διάγραμμα στα νευρωνικά :



**μ 6.16.** Διάφορα αναμενόμενων –υπολογισμένων τιμών ANFIS

Το αντίστοιχο διάγραμμα για την ίδια έξοδο και τα δεδομένα έλεγχου είναι :




**μ 6.16.** Διαφορά αναμενόμενων –υπολογισμένων τιμών ANFIS-testdata .

Παρατηρούμε ότι η διάφορα και για τα δυο αρχεία δεδομένων είναι πολύ μικρή κάτι που είναι το επιθυμητό αφού δείχνει σωστή εκτίμηση των αποτελεσμάτων.


Κατόπιν παρουσιάζονται διαγραμματικά οι υπολογισμοί εύρους σφάλματος - αριθμός σωστών προβλέψεων που μας βοήθα στην σωστή αξιολόγηση του ANFIS.

Για τις πρώτες 6 εξόδους έχουμε:




**μ 6.17.** Απόδοση-Εύρος τιμών 1-6 εξόδου ANFIS

Για τις επόμενες 8 μεταβλητές εξόδου έχουμε τα αντίστοιχα διαγράμματα :



**μ 6.17.** Απόδοση-Εύρος τιμών 6-14 εξόδου ANFIS

Από τα παραπάνω διαγράμματα και με βάση το αρχείο εκπαίδευσης για την αξιολόγηση του ANFIS βλέπουμε ότι τα αποτελέσματα είναι απόλυτα ακριβή. Για τιμές μικρού εύρους σφάλματος η εκτίμηση αγγίζει το 100% για όλες τις τιμές εξόδου κάτι που δείχνει την ορθή και αποτελεσματική λειτουργία του νευροασαφούς δικτύου αφού γίνεται σωστή εκτίμηση των κατανεμημένων απωλειών. Όμως για αποφυγή φαινομένων υπερπροσαρμογής με βάση το αρχείο εκπαίδευσης παρουσιάζονται και τα αποτελέσματα με βάση το αρχείο έλεγχου :



**μ 6.18** Απόδοση-Εύρος τιμών 1-14 εξόδου ANFIS ,testdata .

Βλέπουμε ότι και για το αρχείο έλεγχου τα αποτελέσματα είναι ακριβή ακόμη και για μικρό ποσοστό εύρους σφάλματος . Όπως και στα νευρωνικά το μεγαλύτερο σφάλμα παρουσιάζεται στην 4<sup>η</sup> έξοδο του δικτύου όμως πλέον η απόκλιση είναι πολύ μικρή κάτι που δείχνει την βελτίωση των αποτελεσμάτων με την χρήση ANFIS .

Εκτός από τα διαγραμματικά στοιχεία όπου δείχνουν την επιτυχημένη λειτουργία των ANFIS παρουσιάζουμε στον πίνακα και τα αριθμητικά αποτελέσματα. Συγκεκριμένα γίνεται υπολογισμός του MAPE από τον τύπο που είδαμε στα νευρωνικά δίκτυα και ταυτόχρονα υπολογίζεται ο αριθμός των σωστών δεδομένων με ένα εύρος σφάλματος 5%. Ως αρχείο δεδομένων για τους υπολογισμούς αυτούς λαμβάνεται το αρχείο εκμάθησης :

|    | PE     | μ | μ | μ    | μ 5% |
|----|--------|---|---|------|------|
| 1  | 0,0129 |   |   | 2000 |      |
| 2  | 0,0045 |   |   | 2000 |      |
| 3  | 0,0024 |   |   | 2000 |      |
| 4  | 0,0004 |   |   | 1990 |      |
| 5  | 0,0025 |   |   | 2000 |      |
| 6  | 0,0012 |   |   | 2000 |      |
| 7  | 0,0000 |   |   | 2000 |      |
| 8  | 0,0002 |   |   | 2000 |      |
| 9  | 0,0001 |   |   | 2000 |      |
| 10 | 0,0001 |   |   | 2000 |      |
| 11 | 0,0001 |   |   | 2000 |      |
| 12 | 0,0000 |   |   | 2000 |      |
| 13 | 0,0000 |   |   | 2000 |      |
| 14 | 0,0000 |   |   | 2000 |      |

#### 6.4 Απόδοση ANFIS

Από τις τιμές του πίνακα παρατηρούμε ότι τα μεγέθη MAPE αλλά και ο αριθμός των σωστών εκτιμήσεων είναι καλύτερα από ότι με την χρήση ANN αφού οι αποκλίσεις είναι μικρότερες.

## ΣΥΜΠΕΡΑΣΜΑΤΑ

Βασικές προϋποθέσεις για την καλή και αξιόπιστη λειτουργία ενός συστήματος ηλεκτρικής ενέργειας είναι να παρέχει ηλεκτρική ενέργεια οπουδήποτε και οποιαδήποτε στιγμή υπάρχει ζήτηση, με τις ελάχιστες δυνατές απωλειες μεταφοράς που και καταστρέφουν το δίκτυο και είναι στην ουσία απώλεια χρημάτων .

Για την εξασφάλιση της σωστής σχεδίασης και λειτουργίας των δικτύων, είναι απαραίτητο να γίνονται συνεχείς μελέτες. Η πιο απλή από αυτές είναι η ανάλυση ροής φορτίου που μας δίνει την κατανομή τάσεων και φορτίων σε ένα δίκτυο. Η δημοφιλέστερη μέθοδος είναι η Newton-Raphson που μελετήθηκε στην εργασία . Όμως η απλή κατανομή δεν είναι επαρκής για την καλύτερη λειτουργία του δικτύου . Γι'αυτο και αναπτύσσεται η βέλτιστη ροή φορτίου ,ανάλογα με την παράμετρο που θέλουμε να βελτιστοποιήσουμε . Άλλες φορές ενδιαφερόμαστε για την οικονομικότερη λειτουργία του δικτύου, άλλες φορές για τον περιορισμό των εκπομπών στο περιβάλλον. Στην εφαρμογή μας το ενδιαφέρον εστιάστηκε στην ελαχιστοποίηση των απωλειών .

Έχουν αναπτυχθεί πολλές τεχνικές για την επίλυση προβλημάτων με περιορισμούς όπως είναι αυτό που αναφέρθηκε. Αρχικά η επιστήμη εστίασε σε ντετερμινιστικές εφόδου όπως είναι η μέθοδος Newton ,η μέθοδος τετραγωνικού προγραμματισμού ή η μέθοδος εσωτερικό σημείου(interior point) η οποία και μελετήθηκε με την βοήθεια της Matlab. Όμως αργότερα και με την εξέλιξη της επιστήμης και την ανάπτυξη της τεχνητής νοημοσύνης , άρχισαν να εφαρμόζονται νέες τεχνικές για την επίλυση των σύνθετων μη γραμμικών προβλημάτων. Μια από αυτές τις μεθόδους είναι και αυτή του διαφορικού εξελικτικού αλγόριθμου ( differential evolutionary algorithm) που δίνει καλύτερα αποτελέσματα στο πρόβλημα.

Όμως η βέλτιστη ροή φορτίου σχετίζεται κυρίως με οικονομικές εφαρμογές. Επειδή η ελαχιστοποίηση απωλειών οφείλεται κυρίως στην εγκατάσταση πυκνωτών εγχύσεως ισχύος στο δίκτυο , μας ενδιαφέρει η εγκατάσταση τέτοιων πυκνωτών που θα οδηγήσουν και στην μείωση απωλειών αλλά και κατ επέκταση στην εξοικονόμηση χρημάτων. Επειδή αυτό το οικονομικό πρόβλημα μελετάται σε βάθος χρόνου (όποτε τα διάφορα μεγέθη φορτίου-τάσης δεν είναι σταθερά) και είναι σύνθετο ως προς την δομή του(σημασία έχει και η θέση και το μέγεθος των πυκνωτών) η επίλυση βασίζεται σε εφαρμογές τεχνητής νοημοσύνης . Έχουν εφαρμοστεί διάφορες μεθόδους για την επίλυση του optimal capacitor placement προβλήματος όπως είναι οι γενετικοί αλγόριθμοι, particle swarm optimization, Tabu search, simulated annealing , ant colony κ.α. Εμείς ασχοληθήκαμε με τις δυο πρώτες.

Εκτός όμως από την ελαχιστοποίηση σπουδαίο ρόλο παίζει και η κατανομή των απωλειών μεταφοράς στους ζυγούς του δικτύου. Μάλιστα το ζήτημα αυτό αποκτά μεγαλύτερη σημασία στις μέρες μας όπου αναπτύσσονται τα διανεμημένα συστήματα μεταφοράς και παραγωγής όποτε οι τριβές μεταξύ των παραγωγών και των καταναλωτών για την χρέωση των απωλειών πρέπει εξ αρχής να εξαλειφθούν. Έχουν αναπτυχθεί πολλές μεθόδους όπως είναι οι pro rata, Z-bus και marginal loss allocation που παρουσιάζουν παραπλήσια αποτελέσματα. Είναι υπευθυνότητα όλων των συμμετεχόντων στο δίκτυο για να αποφασίσουν τη μεθοδολογία που θα ακολουθήσουν.

Επειδή τα συστήματα ηλεκτρικής ενέργειας δεν είναι στατικά αλλά αντίθετα τα δεδομένα τάσεως και ισχύος μεταβάλλονται συνεχώς, πρέπει συνεχώς να υπολογίζονται και οι μεταβολές στις άλλες παραμέτρους. Στην εφαρμογή μας τέτοιες παράμετροι είναι οι πυκνωτές που πρέπει να εγκατασταθούν στο πρόβλημα ελαχιστοποίησης και η κατανομή των απωλειών στους ζυγούς. Για να αποφευχθεί η ανάγκη συνεχούς εκτέλεσης των ίδιων αλγόριθμων για μεγάλο αριθμό επαναλήψεων (αφού τα δεδομένα μεταβάλλονται συνεχώς) εισάγονται στα προβλήματα αυτά η τεχνολογία των νευρωνικών δικτύων (artificial neural networks). Με την εκμάθηση των ANN σε κάθε πρόβλημα έχουμε τις ορθές λύσεις χωρίς να απαιτείται η εκτέλεση των αλγόριθμων κάθε φορά. Σαν συνέχεια των νευρωνικών δικτύων έχουν αναπτυχθεί και τα νεύρο ασαφή δίκτυα που προσφέρουν ακόμη καλύτερα αποτελέσματα.

Η εργασία αυτή μελέτησε σε ένα βαθμό τα προβλήματα που αφορούν τις απωλειες μεταφοράς κυρίως με χρήση τεχνητής νοημοσύνης. Μπορεί να αποτελέσει την βάση για περαιτέρω μελέτη. Σήμερα οι τεχνικές Α.Ι. είναι παρά πολλές. Άλλες μέθοδοι θα μπορούσαν να εφαρμοστούν στα προβλήματα ελαχιστοποίησης ώστε να βρεθούν ακόμη πιο βελτιωμένες λύσεις. Ακόμη η ιδέα των νευρωνικών για την κατανομή των απωλειών θα μπορούσε να υλοποιηθεί σε ένα software πρόγραμμα το οποίο στην καθημερινή ζωή να δέχεται και άλλες παραμέτρους (κόστος ενέργειας κ.α.) και να παρέχει κάθε φορά την χρέωση του κάθε ζυγού που οφείλεται στις απωλειες μεταφοράς.

# ΕΦΑΡΜΟΓΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΣΤΗΝ ΕΝΕΡΓΕΙΑ

## .1

Το επίκεντρο της εργασίας ήταν η εφαρμογή των μεθόδων της τεχνητής νοημοσύνης (artificial intelligence) σε εφαρμογές του τομέα της ενέργειας και πιο συγκεκριμένα στο πρόβλημα της ελαχιστοποίησης των απωλειών στις γραμμές μεταφοράς και της κατανομής των απωλειών αυτών στους ζυγούς. Η μελέτη έδειξε ότι η εφαρμογή προηγμένων τεχνικών βοήθα στην επίλυση πολυσύνθετων προβλημάτων που η επίλυση τους με ντετερμινιστικές μεθόδους είναι πολύπλοκη τόσο σε εκτέλεση όσο και στον χρόνο που απαιτείται για την έξοδο των αποτελεσμάτων.

Από όλες τις τεχνικές ΑΙ που χρησιμοποιήθηκαν δόθηκε ιδιαίτερη έμφαση σε αυτή των νευρωνικών δικτύων (ANN). Πρόκειται για μεθοδολογία που διευκολύνει σε περιπτώσεις πολλών διαφορετικών καταστάσεων. Και ο κλάδος της ενέργειας όπου σε ένα δίκτυο έχουμε συνεχή μεταβολή των καταστάσεων εισόδου η χρησιμότητα των νευρωνικών αποδεικνύεται μεγάλη. Γι αυτό και η εξάπλωση των νευρωνικών σε πολλές ενεργειακές εφαρμογές είναι εμφανής.

Λόγω της σπουδαιότητας των νευρωνικών δικτύων σαν μεθοδολογία παρουσιάζεται μια ακόμη χρήση αυτής της τεχνικής σε μια εξίσου σπουδαία μελέτη του κλάδου της ενέργειας, αυτή της πιθανοτικής ροής φορτίου. Πριν όμως μελετηθεί η περίπτωση των νευρωνικών δικτύων πρέπει να αναφερθούμε στο πρόβλημα της πιθανοτικής ροής.

## .2

Η πιθανοτική ροή φορτίου μπορεί να οριστεί ως μία μέθοδος επίλυσης προβλημάτων ροής φορτίου που λαμβάνει υπόψη την αβεβαιότητα και τη στατιστική φύση των δεδομένων μεγεθών, δηλαδή των φορτίων και της παραγωγής, και υπολογίζει τα άγνωστα μεγέθη ως τυχαίες μεταβλητές με μία μέση τιμή, τυπική απόκλιση και συνάρτηση πυκνότητας πιθανότητας. Είναι ένας τρόπος υπολογισμού όλων των πιθανών καταστάσεων του συστήματος, που αντιστοιχούν σε όλες τις δυνατές στατιστικές μεταβολές των φορτίων και της παραγωγής μέσω μίας μόνο ανάλυσης ροής φορτίου.

Έχουν διατυπωθεί κατά καιρούς πολλές διαφορετικές μορφές της πιθανοτικής μεθόδου. Οι περισσότερες στηρίζονται στην απλοποίηση και γραμμικοποίηση των

αρχικών εξισώσεων ροής φορτίου, ή στην υπόθεση ότι οι τυχαίες μεταβλητές που υπολογίζονται ακολουθούν κανονική κατανομή. Έχει αποδειχθεί ότι η υπόθεση της κανονικής κατανομής των αγνώστων μεγεθών μπορεί να οδηγήσει σε λανθασμένα συμπεράσματα. Αντίθετα, με εφαρμογή της μεθόδου Monte Carlo που συνίσταται στην ανάλυση και αξιολόγηση μεγάλου πλήθους ροών φορτίου (μέχρι και 20.000 περιπτώσεις), έχει διαπιστωθεί η ικανοποιητική ακρίβεια της πιθανοτικής ροής φορτίου που βασίζεται στη γραμμικοποίηση των εξισώσεων γύρω από την αναμενόμενη τιμή.

Όμως ο στόχος της μελέτης δεν είναι η εμβάθυνση στην ιστορία και τις τεχνικές επίλυσης του προβλήματος της πιθανοτικής ροής φορτίου. Παρουσιάζεται βέβαια αναλυτικά μια μέθοδος όπου μας βοηθά στην κατανόηση του προ βλήματος αλλά κυρίως μας παρέχει τα δεδομένα εκπαίδευσης για το νευρωνικό δίκτυο. Παρόλα αυτά επισημαίνονται οι πρακτικές εφαρμογές της πιθανοτικής ροής που την καθιστούν χρήσιμη:

A) Η μορφή των συναρτήσεων πυκνότητας πιθανότητας που προσδιορίζονται απ ό μία πιθανοτική ροή φορτίου παρέχει της ακόλουθες πληροφορίες :

- i. Ποια είναι η πιο πιθανή τιμή ροής φορτίου σε μία γραμμή ή τάσεως σε ένα ζυγό PQ. Η τιμή αυτή μπορεί να διαφέρει από την αναμενόμενη τιμή λόγω της μη κανονικής μορφής της συνάρτησης πυκνότητας πιθανότητας.
- ii. Ποια είναι η πιθανότητα να ξεπεράσει η ροή μιας γραμμής το όριο αντοχής της ή η πιθανότητα να κυμαίνεται η τιμή της σε κάποιο διάστημα γύρω από μία ορισμένη τιμή.
- iii. Ποια είναι η πιθανότητα να μην ικανοποιούνται οι περιορισμοί της τάσεως σε κάποιο ζυγό.
- iv. Ποια είναι η πρακτικά δυνατή έκταση τιμών των τάσεων ή της ροής ισχύος ώστε να γίνει κατάλληλη επιλογή του αριθμού, της ικανότητας και της τοπολογίας των γραμμών ενός συστήματος.
- v. Ποιο ποσοστό από όλες τις δυνατές τιμές της ροής σε κάποια γραμμή βρίσκεται στην οικονομικά επιθυμητή περιοχή τιμών.

B) Ο προσδιορισμός της συνάρτησης πυκνότητας πιθανότητας του ισοζυγίου της ισχύος στο σύστημα επιτυγχάνεται αφού είναι γνωστές όλες οι συναρτήσεις πυκνότητας πιθανότητας της παραγωγής και των φορτίων. Το ισοζύγιο ισχύος είναι ανεξάρτητο από τις παραμέτρους των στοιχείων του δικτύου και την τοπολογία. Από τη γραφική παράσταση αυτής της συνάρτησης εξάγεται η πιθανότητα να υπάρχει πλεόνασμα ή έλλειμμα ισχύος στο σύστημα με αποτέλεσμα την ποσοτική εκτίμηση της ικανότητας του συστήματος να καλύψει τη συνολική ζήτηση. Η πληροφορία αυτή μπορεί να φανεί χρήσιμη για τον προσδιορισμό του αριθμού και της ικανότητας των εφεδρειών που θα χρησιμοποιηθούν.



Γ) Για να επιτευχθεί ο υπολογισμός των αγνώστων μεγεθών στην πιθανοτική ροή φορτίου απαιτείται πρώτα η εξαγωγή ενός διανύσματος συντελεστών ευαισθησίας που καθορίζει πόσο επηρεάζεται το συγκεκριμένο μέγεθος από τη μεταβολή της πραγματικής ή άεργου εγχύσεως σε κάθε ζυγό ξεχωριστά. Οι συντελεστές αυτοί μπορούν να χρησιμοποιηθούν σε ανάλυση της ευαισθησίας του συστήματος ή στην επιλογή του καταλληλότερου χειρισμού των μεταβλητών ελέγχου και διαταραχής για την επαναφορά του συστήματος στα προκαθορισμένα όρια ασφαλείας.

### .3

Από όσες μεθόδους έχουν αναφερθεί στην βιβλιογραφία για την εξεύρεση της πιθανοτικής ροής, χρησιμοποιούμε αυτή που περιγράφηκε από τους Amit Jain και Co στη . Από τις εξισώσεις ροής φορτίου παίρνοντας τις σειρές Taylor έχουμε:

$$\Delta y = J \Delta x + \varepsilon$$

όπου

$\varepsilon$  : το διάνυσμα σφάλματος της τυχαίας μεταβλητής .

$x$  : το διάνυσμα κατάστασης.

$y$  : οι ποσότητες δεδομένων που αντιπροσωπεύουν την μέση τιμή του εύρους των πιθανών τιμών που μπορούν να πάρουν τα δεδομένα, με βάση κάποιες στατιστικές διαδικασίες που λαμβάνονται είτε από δική μας κρίση είτε από μεθόδους πρόβλεψης δεδομένων (forecasting data).

Το σφάλμα  $\varepsilon$  ανάμεσα στο  $y$  και στο  $f(x)$  μπορεί να περιγράψει σαν μια τυχαία μεταβλητή που έχει κάποια μέση τιμή και διακύμανση που περιγράφουν τον τρόπο που το  $\varepsilon$  μεταβάλλεται. Το σφάλμα έχει κατά ακόλουθα στατιστικά χαρακτηριστικά :

1. Η αναμενόμενη τιμή του σφάλματος είναι,  $E(\varepsilon)=0$ .
2. Η  $\varepsilon$  είναι Γκαουσιανη.
3. Η αναμενόμενη τιμή της  $\varepsilon \varepsilon'$  είναι,  $E(\varepsilon \varepsilon') = V$  όπου το  $V$  είναι ένας διαγώνιος πίνακας με τις διακυμάνσεις των δεδομένων,  $\sigma^2$ .

Στη стоχαστική ροή φορτίου που μελετάται, επιλέγουμε ως διάνυσμα  $y$  τις ποσότητες ενεργού και άεργου ισχύος στους ζυγούς κατανάλωσης PQ. Η επιλογή αυτή έγινε με βάση το σκεπτικό ότι τα μεγέθη αυτά μεταβάλλονται συνεχώς και ανάλογα με το είδος του φορτίου στους ζυγούς. Αυτό που ζητάτε αρχικά είναι η

εύρεση της μέσης τιμής και της διακύμανσης του μεγέθους  $x$ , που περιλαμβάνει τα μέτρα και τις γωνίες των ζυγών PQ. Αυτά ορίζουν το διάνυσμα κατάστασης. Όλες οι άλλες ποσότητες προκύπτουν από την σχέση:

$$z = h(x) \quad (\text{Π.1})$$

Μετά την γραμμικοποίηση της σειράς Taylor λαμβάνουμε την έκφραση:

$$\Delta z = K \Delta x \quad (\text{Π.2})$$

Η καλύτερη εκτίμηση του  $x$  ονομάζεται  $\hat{x}$  και η καλύτερη εκτίμηση για το  $z$  είναι κατά αντιστοιχία  $\hat{z}$ . Οι εκτιμήσεις αυτές προκύπτουν από τις σχέσεις:

$$\begin{aligned} \hat{x} &= J^{-1} \Delta y + x_o \quad (\text{Π.3}) \\ \hat{z} &= K \Delta \hat{x} + z_o \end{aligned}$$

Για την απλότητα της μελέτης δεχόμαστε ότι οι συναρτήσεις πυκνότητας πιθανότητας όλων των μεγεθών εισόδου είναι κανονικές κατανομές. Όποτε δεν μας ενδιαφέρει ο υπολογισμός εκ νέου της συνάρτησης πυκνότητας πιθανότητας των εξόδων αφού και αυτή είναι κανονική κατανομή. Το μόνο που χρειάζεται για την ολοκλήρωση της μελέτης είναι ο υπολογισμός των διακυμάνσεων, ώστε να υπολογιστεί το όριο μέσα στο οποίο κινούνται τα μεγέθη. Τα όρια υπολογίζονται αντίστοιχα:

$$\begin{aligned} \sigma_x^2 &= \text{diag}\{(J^T V^{-1} J)^{-1}\} \quad (\text{Π.4}) \\ \sigma_z^2 &= \text{diag}\{K(J^T V^{-1} J)^{-1} K^T\} \end{aligned}$$

Μετά τον υπολογισμό των διακυμάνσεων και με βάση τη θεωρία για την κανονική κατανομή γνωρίζουμε ότι τα όρια των μεγεθών είναι αντίστοιχα:

$$\begin{aligned} x_i &= \hat{x} \pm 3\sigma_x \quad (\text{Π.5}) \\ z_i &= \hat{z} \pm 3\sigma_z \end{aligned}$$

Για την ροή φορτίου που μετράται το διάνυσμα  $z$  μπορεί να περιλαμβάνει διάφορα μεγέθη ανάλογα με την μελέτη, όπως είναι η απώλειες γραμμών μεταφοράς κ.α. Εδώ επιλέγουμε για μια πιο γρήγορη προσέγγιση να περιλάβουμε στο  $z$  την πραγματική και άεργο ισχύ του ζυγού αναφοράς (slack bus) που μεταβάλλεται συνεχώς με την μεταβολή των άλλων φορτίων στους ζυγούς.

Από τις παραπάνω μεταβλητές που χρησιμοποιήθηκαν πρέπει ακόμη να επισημάνουμε ότι αντιπροσωπεύουν:


J : Η Ιακωβιανή των εξισώσεων ροών φορτίων.

K : Η Ιακωβιανή των ποσοτήτων εξόδων ως προς τις μεταβλητές κατάστασης  $x$ .

Πιο ακριβή περιγραφή των σχέσεων γίνεται στην συγκεκριμένη εφαρμογή που μελετάται.

#### .4 CASE STUDY

Μελετάται το πρόβλημα της πιθανοτικής ροής φορτίου σε ένα δίκτυο 5 ζυγών που φαίνεται στο παρακάτω σχήμα :



μ .1 Δίκτυο 5 ζυγών

Το δίκτυο αποτελείται από ένα ζυγό slack bus και 4 ζυγούς φορτίου. Τα στοιχεία των ζυγών δίνονται στον πίνακα :

| Bus | Voltage |      | Generation |        | Load |        |
|-----|---------|------|------------|--------|------|--------|
|     | Mag.    | Ang. | Act.       | React. | Act. | React. |
| 1   | 1.061   | 0.0  | 0.00       | 0.00   | 0.00 | 0.00   |
| 2   | 1.047   | 0.0  | 0.00       | 0.00   | 0.20 | 0.10   |
| 3   | 1.000   | 0.0  | 0.00       | 0.00   | 0.45 | 0.15   |
| 4   | 1.000   | 0.0  | 0.00       | 0.00   | 0.60 | 0.10   |
| 5   | 1.000   | 0.0  | 0.00       | 0.00   | 0.40 | 0.10   |

μ .2 Στοιχεία ζυγών 5 ζυγών

Τα δεδομένα των ζυγών φορτίου αποτελούν και την κατάσταση εισόδου του διανύσματος  $y$  και οι αντίστοιχες τιμές θεωρούνται οι μέσες τιμές των συναρτήσεων κανονικής κατανομής της κάθε μεταβλητής . Ορίζουμε επιπλέον και την διακύμανση του κάθε μεγέθους εισόδου. Λαμβάνονται τα παρακάτω όρια :

|       | Low Limit ( p.u) | Upper Limit ( p.u.) |
|-------|------------------|---------------------|
| Pd(2) | 0,18             | 0,22                |
| Qd(2) | 0,08             | 0,12                |
| Pd(3) | 0,40             | 0,50                |
| Qd(3) | 0,12             | 0,18                |
| Pd(4) | 0,55             | 0,65                |
| Qd(4) | 0,08             | 0,12                |
| Pd(5) | 0,36             | 0,44                |
| Qd(5) | 0,08             | 0,12                |

### .1 Όρια ισχύος στο δίκτυο

Μετά την εύρεση των ορίων των εισόδων μπορούμε να ορίσουμε τον πίνακα διακύμανσης V .Είναι:

$$V = \begin{pmatrix} 0.0000435 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0.0002750 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.0002750 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.0001760 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.0000435 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.0001000 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.0000435 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.0000435 \end{pmatrix} \text{ σε α.μ. τιμές ισχύος .}$$

Για την ολοκλήρωση της περιγραφής των δεδομένων εισόδου αναγράφονται και τα χαρακτηριστικά των γραμμών του δικτύου :

| Busbar No. | Resistance | Reactance | Y/2   |
|------------|------------|-----------|-------|
| 1-2        | 0.020      | 0.060     | 0.030 |
| 1-3        | 0.080      | 0.240     | 0.025 |
| 2-3        | 0.060      | 0.180     | 0.020 |
| 2-4        | 0.040      | 0.120     | 0.015 |
| 2-5        | 0.060      | 0.180     | 0.020 |
| 3-5        | 0.010      | 0.030     | 0.010 |
| 4-5        | 0.080      | 0.240     | 0.025 |

### μ .3 Στοιχεία γραμμών 5 ζυγών

Αρχικά εκτελούμε μια ροή φορτίου με την μέθοδο Newton-Raphson με στόχο να λάβουμε τις αρχικές συνθήκες των διανυσμάτων για τις τιμές εισόδου που περιγράφονται στον πίνακα. Έτσι είναι :

$$x_o = [-3.62 \ -5.65 \ -7.05 \ -6.03 \ 1.023 \ 1.003 \ 0.994 \ 1.000]$$

Οι πρώτες 4 μεταβλητές αντιστοιχούν στις γωνίες των ζυγών 2-5 και οι επόμενες 4 στις αντίστοιχες τάσεις α.μ.

Επίσης :

$$z_o = [171.44 \quad 34.28]$$

όπου είναι τα στοιχεία ενεργού και άεργου ισχύος για τον ζυγό 1.

Μετά τον ορισμό των αρχικών συνθηκών προχωράμε στην εξεύρεση των προσεγγίσεων. Αρχικά για την εξεύρεση των  $\hat{x}$  υπολογίζουμε το διάνυσμα

$$\Delta y = y - y_o \quad (\text{Π.6})$$

με  $y$  τα στοιχεία ισχύος της κάθε χρονικής στιγμής και  $y_o$  το διάνυσμα με τις καταστάσεις του πίνακα μέσων τιμών. Για να συνδέσουμε τις ισχύς με τις γωνίες και τις τάσεις παίρνουμε τον αντίστροφο Ιακωβίνο πίνακα  $J^{-1}$  όπου μας δίνει τη σχέση :

$$\begin{vmatrix} \Delta P \\ \Delta Q \end{vmatrix} \Rightarrow \begin{vmatrix} \Delta \delta \\ \Delta V \end{vmatrix} \quad (\text{Π.7})$$

όποτε και λαμβάνουμε τελικά

$$\begin{aligned} \delta_i &= \delta_o + \Delta \delta \quad (\text{Π.8}) \\ V_i &= V_o + \Delta V \end{aligned}$$

Μετά την εκτίμηση των τάσεων και των γωνιών των ζυγών 2-5 πρέπει να υπολογιστεί και η διακύμανση. Αυτή υπολογίζεται πάλι με την βοήθεια της Ιακωβιανη για την σύνδεση των μεγεθών διακύμανσης σε μονάδες ισχύος σε αυτές των μονάδων τάσεων και γωνιών. Λαμβάνουμε :

$$\sigma_x^2 = \text{diag} \{ \text{inv}(J) * V * \text{inv}(J^T) \}. \quad (\text{Π.9})$$

Κατόπιν προχωράμε στην μελέτη για την εύρεση των στοιχείων  $z$  που εδώ είναι οι τιμές ενεργού και άεργου ισχύος του ζυγού 1. Βρίσκουμε μια σχέση που συνδέει τα στοιχεία  $P_1$  και  $Q_1$  με τις γωνίες και τις τάσεις των ζυγών 2-5 αφού αυτά αποτελούν τα στοιχεία του  $x$ . Οι σχέσεις είναι αυτές οι ακόλουθες :

$$\begin{aligned}
J1_{1j} &= \frac{\partial P_1}{\partial \delta_j} = V_1 V_j y_{1j} \sin(\theta_{1j} + \delta_1 - \delta_j) \\
J2_{1j} &= \frac{\partial P_1}{\partial V_j} = V_1 y_{1j} \cos(\theta_{1j} + \delta_1 - \delta_j) \\
J3_{1j} &= \frac{\partial Q_1}{\partial \delta_j} = -V_1 V_j y_{1j} \cos(\theta_{1j} + \delta_1 - \delta_j) \\
J4_{1j} &= \frac{\partial Q_1}{\partial V_j} = V_1 y_{1j} \sin(\theta_{1j} + \delta_1 - \delta_j)
\end{aligned}$$

με τις σχέσεις αυτές έχουμε την διασύνδεση :

$$\begin{vmatrix} \Delta \delta \\ \Delta V \end{vmatrix} \Rightarrow \begin{vmatrix} \Delta P_1 \\ \Delta Q_1 \end{vmatrix}$$

Τα στοιχεία  $\Delta \delta, \Delta V$  προκύπτουν από την διάφορα των διανυσμάτων  $\Delta x = \hat{x} - x_o$  με  $\hat{x}$  την εκτίμηση που προέκυψε στο πρώτο βήμα της μεθοδολογίας .

Έτσι λαμβάνουμε τελικά :

$$\begin{aligned}
P_i &= P_o + \Delta P_1 \quad (\text{Π.10}) \\
Q_i &= Q_o + \Delta Q_1
\end{aligned}$$

Για την ολοκλήρωση της διαδικασίας υπολογισμού πρέπει να βρούμε την διακύμανση των εκτιμώμενων τιμών  $P_1, Q_1$  . Αυτό γίνεται από τη σχέση :

$$\sigma_z^2 = \text{diag} \{ K * \sigma_x^2 * K^T \} \quad (\text{Π.11})$$

όπου  $K$  είναι ο πίνακας διασύνδεσης των γονέων και τάσεων με τις ενεργές και άεργες ισχύς όποτε είναι ο πίνακας των παραπάνω σχέσεων :

$$K = \begin{vmatrix} J1_{1j} & J2_{1j} \\ J3_{1j} & J4_{1j} \end{vmatrix} \quad (\text{Π.11})$$

Από την μελέτη αυτή προκύπτει ότι έχουμε ένα σύστημα που σαν είσοδο λαμβάνει 8 εισόδους

$$P_2, Q_2, P_3, Q_3, P_4, Q_4, P_5, Q_5$$

και έχουμε στην έξοδο 20 εξόδους :

$$P_{1L}, P_{1U}, Q_{1L}, Q_{1U}, \delta_{2L}, \delta_{2U}, V_{2L}, V_{2U}, \delta_{3L}, \delta_{3U},$$

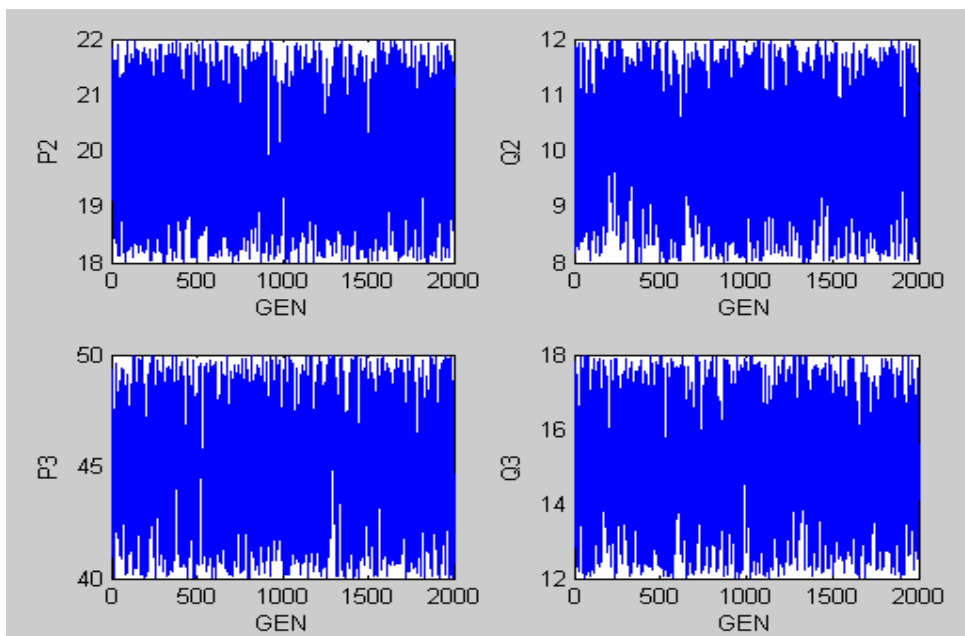
$$V_{3L}, V_{3U}, \delta_{4L}, \delta_{4U}, V_{4L}, V_{4U}, \delta_{5L}, \delta_{5U}, V_{5L}, V_{5U}$$

Για κάθε δεδομένη μεταβολή του φορτίου, έχουμε τα αντίστοιχα όρια που μπορούν να λάβουν τα στοιχεία εξόδου.

## .5

Όπως αναφέρθηκε και στην προηγούμενη παράγραφο, όταν μας δίνονται τα στοιχεία εισόδου (ενεργές και άεργες ισχύς των φορτίων) τότε ακολουθούμε την αλληλουχία βημάτων που αναφέρθηκαν μέχρι την έξοδο των αποτελεσμάτων. Επειδή οι μεταβολές στα φορτία είναι συνεχείς αναζητείται ένας τρόπος πιο γρήγορος και πιο 'ελαφρύς' στην εξεύρεση των λύσεων. Επιλέγεται η μέθοδος των νευρωνικών δικτύων για την προσομοίωση του προβλήματος. Σαν είσοδο του νευρωνικού δικτύου επιλέγουμε τις 8 μεταβλητές που αναφέρθηκαν παραπάνω ενώ σαν έξοδο τις αντίστοιχες 20 εξόδους. Σκοπός είναι με δεδομένα τα στοιχεία εισόδου να λαμβάνουμε από το νευρωνικό δίκτυο τα ίδια αποτελέσματα πιθανοτικής ροής με αυτά που θα λαμβάναμε από τον ντετερμινιστικό αλγόριθμο.

Πρέπει αρχικά να καθορίσουμε τα δεδομένα εκπαίδευσης του δικτύου. Τα όρια των μεγεθών είναι αυτά που ορίστηκαν παραπάνω. Για την εκπαίδευση εκτελούμε τον ντετερμινιστικό αλγόριθμο που περιγράψαμε και παίρνουμε 2000 διαφορετικές περιπτώσεις. Αυτές αποτελούν το αρχείο εκπαίδευσης. Σαν δεδομένα εισόδου παίρνουμε τέτοιες ποσότητες ώστε να προσομοιώνουν τις χρονοσειρές του φορτίου. Η μορφή των καμπυλών 4 εισόδων παρουσιάζεται στο σχήμα για να φανεί η ποικιλότητα και η τυχαioτητα στα δεδομένα εισόδου:



μ .4 Είσοδοι νευρωνικού δικτύου

Ορίζουμε ακόμη τη μορφή του νευρωνικού. Επλέγεται η παρουσία ενός και μόνο κρυφού στρώματος (layer) αφού δεν είναι πολύ σύνθετο το πρόβλημα με τους 5 ζυγούς. Επίσης μετά από διαδοχικές επαναλήψεις για τον αριθμό των νευρώνων στο κρυφό επίπεδο επιλέγουμε την ύπαρξη 12 νευρώνων. Προφανώς στο πρώτο επίπεδο επιλέγουμε 8 νευρώνες- εισόδους και στο τρίτο επίπεδο 20 νευρώνες –εξόδους.


Τα δεδομένα αρχικά επεξεργάζονται με την διαδικασία της matlab `premnmx` που αναφέραμε και σε προηγούμενες εφαρμογές ώστε να επιτύχουμε την σύγκλιση των τιμών στο όριο [-1,1] και έτσι να ικανοποιούνται και τα όρια της συνάρτησης συμμετοχής : `tansig`. Ως συνάρτηση εκπαίδευσης λαμβάνουμε την απλή συνάρτηση `traindxdx` χρησιμοποιώντας και μια βοηθητική συνάρτηση εκμάθησης. Οι παράμετροι κατά την διαδικασία της εκπαίδευσης του νευρωνικού φαίνονται παρακάτω :

```

trainParam.show = 20;      % Show MSE after 20 epochs
trainParam.lr = 0.1;      % learning rate =0.1
trainParam.mc = 0.8;      % momentum constant =0.8
trainParam.epochs = 1000; % training epochs =1000
trainParam.goal = 0.001;  % Error goal =0.001

```

Αφού ορίσαμε όλες τις παραμέτρους του νευρωνικού προχωράμε στην εκμάθηση του νευρωνικού όπου η καμπύλη του mse μεταβάλλεται με βάση το σχήμα :



**μ .5** Μέσο τετραγωνικό σφάλμα- αριθμός επαναλήψεων.




Η διαδικασία τερματίζεται λόγω της ολοκλήρωσης του αριθμού των ρυθμισμένων επαναλήψεων.

## .6

Μετά τη λειτουργία του νευρωνικού ελέγχουμε την αξιοπιστία και τον τρόπο που μπορούμε να εκμεταλλευτούμε τα αποτελέσματα που εξέρχονται από αυτό. Για το σκοπό αυτό χρησιμοποιούμε εκτός από το αρχείο δεδομένων Train Data και ένα ανεξάρτητο αρχείο TestData ώστε να αποφεύγονται τα φαινόμενα της υπερπροσαρμογής που μπορούν να δώσουν αναληθή στοιχεία για την επάρκεια του ANN.

Αρχικά ελέγχοντας το αρχείο εκμάθησης και λαμβάνοντας ένα εύρος σφάλματος 2% που είναι πολύ μικρό ,υπολογίζουμε με 100% επιτυχία τα αναμενόμενα όρια λειτουργίας για τις 18 πρώτες μεταβλητές όπως αυτά προκύπτουν και απτήν πιθανοτικής ροή φορτίου. Οποτε μπορούμε να εκτιμήσουμε σωστά το μεγαλύτερο πλήθος από της μεταβλητές εξόδου. Για τις δυο τελευταίες εξόδους και παρόλο που τα αποτελέσματα για το αρχείο εκμάθησης είναι πολύ υψηλό(97% επιτυχία ) , για το αρχείο έλεγχου τα αποτελέσματα δεν είναι ικανοποιητικά κάτι που σημαίνει ότι τα αποτελέσματα είναι προϊών υπερπροσαρμογής .

Όμως για την αποτελεσματικότητα των νευρωνικών απαιτείται σωστά αποτελέσματα για όλες τις εξόδους . Για το σκοπό αυτό αναπτύσσουμε ένα ξεχωριστό νευρωνικό δίκτυο. Σαν αρχείο εισόδου δεχόμαστε τα ίδια δεδομένα αλλά σαν έξοδο παίρνουμε μόνο τα δυο μεγέθη ,  $Q_{IL}, Q_{IU}$  . Σαν αρχείο εκμάθησης και έλεγχου χρησιμοποιούμε και αυτό του πρώτου νευρωνικού. Αυτό που αλλάζει είναι ο αριθμός των νευρώνων στο κρυφό επίπεδο που επιλέγονται 4 και φυσικός ο αριθμός νευρώνων-εξόδου που είναι πλέον 2. Ακόμη μια αλλαγή που υπόκειται στον αλγόριθμος είναι η μέθοδος εκμάθησης όπου επιλέγεται η *Levenberg-Marquardt backpropagation* όπου παίρνουμε και την καμπύλη του μέσου τετραγωνικού σφάλματος :



μ .6 Μέσο τετραγωνικό σφάλμα- αριθμός επαναλήψεων-ειδική περίπτωση.

Η βελτίωση σε σχέση με το πρώτο νευρωνικό για τις δυο αυτές εξόδους είναι μεγάλη όμως και πάλι δεν έχουμε ακριβή εκτίμηση των αποτελεσμάτων. Γι αυτό και αυξάνουμε τα όρια εύρους τιμών. Λαμβάνοντας εύρος σφάλματος 6% τότε το ποσοστό επιτυχίας για τα δεδομένα των αρχείο TrainData είναι 100% και για τις δυο εξόδους τιμών. Όμως για το αρχείο TestData όσον αφορά τη μεταβλητή  $Q_{IL}$  η επιτυχία είναι 90% ενώ για την μεταβλητή  $Q_{IU}$  η επιτυχία είναι 100%. Πρέπει δε να επισημάνουμε ότι αυξάνοντας το εύρος τιμών στο 7% τότε η επιτυχία της πρόβλεψης είναι 100%.

## .7

Από τα αποτελέσματα που προέκυψαν από την μελέτη της πιθανοτικής ροής φορτίου με την βοήθεια νευρωνικών οδηγούμαστε στο συμπέρασμα ότι η χρησιμότητα τους είναι επαρκής και ικανοποιητική. Ειδικά επειδή μιλάμε και για πιθανοτικής ροή, τα αποτελέσματα που προκύπτουν με τα διαστήματα τιμών είναι ικανοποιητικά. Ειδικά για το μέγεθος των τιμών εξόδου, η ακρίβεια στις τιμές είναι πολύ καλή. Από πρακτικής χρήσεως η εφαρμογή νευρωνικών ενδείκνυται για την επίλυση προβλημάτων πιθανοτικής ροής φορτίου. Τώρα για την εξακρίβωση των τιμών όπως προκύπτουν από ένα ντετερμινιστικό αλγόριθμο και από ένα νευρωνικό, θα παρατηρηθεί μια μικρή διάφορα μέσα στα όρια του σφάλματος, αλλά μια τέτοια εφαρμογή είναι πολύ θεωρητικοί και χωρίς καμία πρακτική σημασία..

## BIBΛΙΟΓΡΑΦΙΑ

- [1] Κ. Βουρνάς, Γ. Κονταξής, “ Εισαγωγή στα Συστήματα Ηλεκτρικής Ενέργειας”, Εκδόσεις Ε.Μ.Π, Αθήνα 2001.
- [2] Κ. Παπαδιάς, “Ανάλυση Συστήματος Ηλεκτρικής Ενέργειας – Μόνιμη κατάσταση Λειτουργίας (Τόμος 1)”, Εκδόσεις Ε.Μ.Π, Αθήνα 1985
- [3] K.S.Pandya, S.K.Joshi, “A SURVEY OF OPTIMAL POWER FLOW METHODS”, 2005 - 2008 JATIT.
- [4] P. M. De Oliveira-De Jesús, “Cost Loss Allocation in Distribution Networks with High Penetration of Distributed Renewable Generation – A Comparative Study”, Instituto de Engenharia de Sistemas e Computadores.
- [5] N. Chowdhury ,A.Bhuiya, “COUNTER -FLOW IN A DEREGULATED POWER SYSTEM NETWORK AND IT’S EFFECT ON TRANSMISSION LOSS ALLOCATION”, University of Saskatchewan.
- [6] Enrico Carpaneto,“ Computational aspects of the marginal loss allocation methods for distribution systems with distributed generation”, IEEE MELECON 2006.
- [7] Francisco D. Galiana, “Allocation of Transmission Losses to Bilateral Contracts in a Competitive Environment ”, IEEE TRANSACTIONS ON POWER SYSTEMS, VOL. 15. NO. I, FEBRUARY 2000 .
- [8] A. J. Conejo, J. M. Arroyo, “Transmission Loss Allocation: A Comparison of Different Practical Algorithms ” , IEEE TRANSACTIONS ON POWER SYSTEMS, VOL. 17, NO. 3, AUGUST 2002 .
- [9] R.S. Salgadoa, C.F. Moyanoa, A.D.R. Medeiros , “Reviewing strategies for active power transmission loss allocation in power pools”, Electrical Power and Energy Systems 26 (2004) 81–90.
- [10] Arkadi S. Nemirovski,Michael J. Todd “Interior-point methods for optimization”, Cambridge University Press, 2008 .
- [11] Rezaul Haque “TRANSMISSION LOSS ALLOCATION USING ARTIFICIAL NEURAL NETWORKS”University of Saskatchewan.
- [12] V. S. C. Lim, T. K. Saha ,J. D. F. McDonald, “Comparative Effectiveness of Loss Allocation Methods for providing Signals to affect Market Operation ”
- [13] MARGARET H. WRIGHT “THE INTERIOR-POINT REVOLUTION IN OPTIMIZATION: HISTORY, RECENT DEVELOPMENTS, AND LASTING CONSEQUENCES”, BULLETIN OF THE AMERICAN MATHEMATICAL SOCIETY.

- [14] S. Abdelkader, “Transmission loss allocation in a deregulated electrical energy market”, *Electric Power Systems Research* 76 (2006) 962–967.
- [15] Armando M. Leite da Silva, João Guilherme de Carvalho Costa “Transmission Loss Allocation: Part I-Single Energy Market”, *IEEE TRANSACTIONS ON POWER SYSTEMS*, VOL. 18, NO. 4, NOVEMBER 2003 .
- [16] Antonio J. Conejo, Francisco D. Galiana, Ivana Kockar , “Z-Bus Loss Allocation ”, *IEEE TRANSACTIONS ON POWER SYSTEMS*, VOL. 16, NO. 1, FEBRUARY 2001.
- [17] Francisco D. Galiana, Antonio J. Conejo ,Ivana Kockar “Incremental Transmission Loss Allocation Under Pool Dispatch”, *IEEE TRANSACTIONS ON POWER SYSTEMS*, VOL. 17, NO. 1, FEBRUARY 2002 .
- [18] E.A. Belati, G.R.M. da Costa ,“Transmission loss allocation based on optimal power flow and sensitivity analysis”, *Electrical Power and Energy Systems* 30 (2008) 291–295.
- [19] Haykin S., “Neural Networks” , 2nd Edition, Prentice Hall, 1999 .
- [20] Ι. Βλαχάβας, Π. Κεφαλας, Ν. Βασιλειάδης, Ι. Ρεφανιδής, Φ. Κοκκοράς, Η. Σακελλαρίου ,“ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ”.
- [21] Fuzzy Logic Toolbox, Users Guide, Mathworks INC.
- [22] Neural network Toolbox, Users Guide, Mathworks INC .
- [23] Κωνσταντίνος Διαμανταράς , “ Εργαστηριακές ασκήσεις νευρωνικών δικτύων και σύντομο εγχειρίδιο matlab” ,Τμήμα Πληροφορικής – Αριστοτέλειο Θεσσαλονίκης .
- [24] Παπαδάκης Στέλιος, Αδαμίδης Παναγιώτης, “ Ασαφή σύνολα” , Θεσσαλονίκη, Μάιος 2004.
- [25] G. W. Chang, “A Fuzzy Approach for Placement of Capacitors with Considering Harmonic Distortions”, *The 14th International Conference on Intelligent System Applications to Power Systems, ISAP 2007* .
- [26] D. Das ,“Optimal placement of capacitors in radial distribution system using a Fuzzy-GA method”, *Electrical Power and Energy Systems* 30 (2008) 361–367.
- [27] S.K. Bhattacharya , S.K. Goswami , “A new fuzzy based solution of the capacitor placement problem in radial distribution system” , *Expert Systems with Applications* 36 (2009) 4207–4212.
- [28] Baran, M.E. and Wu, F.F., (1989a), “Optimal capacitor placement on radial distribution systems”, *IEEE Transactions on Power Delivery* 4(1), pp.725-734.

- [29] Baran, M.E. and Wu, F.F., (1989b), “Optimal sizing of capacitors placed on a radial distribution systems”, IEEE Transactions on Power Delivery 4(1), pp. 735-743.
- [30] C. T. Su and C. C. Tasi, “A new fuzzy reasoning approach to optimum capacitor allocation for primary distribution systems,” Proc. 1996 IEEE on Industrial Technology Conf., pp. 237–241,1996.
- [31] Ali Hasan Yasin Al-Mohammad, “Optimal Capacitor Placement in Distribution Systems using Heuristics Techniques”.
- [32] Biswarup Das , Pradeep Kumar Verma . “Artificial neural network-based optimal capacitor switching in a distribution system” , Electric Power Systems Research 60 (2001) 55–62.
- [33] K. Ellithy,A. Al-Hinai,A. Moosa, “OPTIMAL SHUNT CAPACITORS ALLOCATION IN DISTRIBUTION NETWORKS USING GENETIC ALGORITHM- PRACTICAL CASE STUDY”International Journal of Innovations in Energy Systems and Power, Vol. 3, no. 1 (April 2008) .
- [34] P.V. Prasad, S. Sivanagaraju,N.Sreenivasulu , “A FUZZY-GENETIC ALGORITHM FOR OPTIMAL CAPACITOR PLACEMENT IN RADIAL DISTRIBUTION SYSTEMS” ,2006-2007 Asian Research Publishing Network
- [35] M. Damodar Reddy and V. C. Veera Reddy “CAPACITOR PLACEMENT USING FUZZY AND PARTICLE SWARM OPTIMIZATION METHOD FOR MAXIMUM ANNUAL SAVINGS” , 2006-2008 Asian Research Publishing Network.
- [36] Tamer Mohamed KHALIL ,Hosam K.M. YOUSSEF, M.M. ABDEL AZIZ, “OPTIMAL CAPACITOR PLACEMENT ON RADIAL DISTRIBUTION FEEDERS IN PRESENCE OF NONLINEAR LOADS USING BINARY PARTICLE SWARM OPTIMIZATION” , 19th International Conference on Electricity Distribution.
- [37] Dulce F. Pires, C. Henggeler Antunes, A. Gomes Martins, “A Tabu Search Multiobjective Approach to Capacitor Allocation in Radial Distribution Systems” , 4th Metaheuristics International Conference .
- [38] Branko D. Stojanović, Miloš S. Nedeljković . “Solving the Problem of General Capacitor Placement in Radial Distribution Systems with Laterals Using Simulated Annealing” , Scientific Technical Review, Vol.LIV, No.3 -4,2004.
- [39] Ευστρατιος Γεωργουλος ,Σπυριδων Λυκοθανασης “ Εισαγωγή στους γενετικούς αλγόριθμους ”,Πάτρα 1999.
- [40] Π. Σ. Α. ΓΕΩΡΓΙΑΚΗΣ, “Εφαρμογή Γενετικών Αλγορίθμων στην Παραγωγή Ηλεκτρικής Ενέργειας”.

- [41] M. Varadarajan, K.S. Swarup, “ Differential evolutionary algorithm for optimal reactive power dispatch” Electrical Power and Energy Systems 30 (2008) 435-441.
- [42] Ivo Chaves Da Silva , “ A Heuristic Constructive Algorithm For Capacitor Placement on Distribution Systems”,IEEE TRANSACTIONS ON POWER SYSTEMS VOL.23 NO.4.
- [43] Jong-Young Park, “Optimal capacitor allocation in a distribution system considering operation costs”,IEEE TRANSACTIONS ON POWER SYSTEMS VOL.24 NO.1.
- [44] Amit Jain and Co, “Stochastic load flow analysis using artificial neural networks”, IEEE 2006
- [45] Optimization Toolbox, Users Guide, Mathworks INC.

Ενδεικτικά παρουσιάζεται ένα από τα πολλά προγράμματα Matlab που αναπτύχθηκε και πιο συγκεκριμένα αυτό των νευρωνικών για την κατανομή απωλειών στους ζυγούς :

```

%Creation of the target matrices
for i=1:1:7
    TestDataTargets(:,i)=ARXEIO1(:,i+5);
    TrainDataTargets(:,i)=ARXEIO2(:,i+5);
end

for i=1:1:9

    TestDataTargets(:,i+7)=ARXEIO3(:,i);
    TrainDataTargets(:,i+7)=ARXEIO4(:,i);
end

%Creation of the input matrixes (i.e removing Targets)
for i=1:1:5
    TestData(:,i)=ARXEIO1(:,i);
    TrainData(:,i)=ARXEIO2(:,i);
end

*****
% Data Preprocessing
*
%*****

%Removing binary values
TrainDataTargets(:,10)=[ ];
TestDataTargets(:,10)=[ ];

TrainDataTargets(:,9)=[ ];
TestDataTargets(:,9)=[ ];

*****
% Data Normalization
*
%*****

%Preprocessing of TrainData TrainDataTargets TestData and
TestDataTargets
%using premnmx [-1 1]
[pn,minp,maxp,tn,mint,maxt] = premnmx(TrainData',TrainDataTargets');
pn=pn';
tn=tn';

[pnT,minpT,maxpT,tnT,mintT,maxtT] =
premnmx(TestData',TestDataTargets');
pnT=pnT';
tnT=tnT';

```

```

*****
% Create a feed-forward backpropagation network.
*
*****

% Creation of the maximum and minimum values of all inputs
% Inputs are normalized to [-1 1] so
OnesVec = -1*ones(5,1);
OnesVec2 = ones(5,1);
PR = [OnesVec OnesVec2];

net = newff(PR,[5 12 14],{'tansig' 'tansig'
'tansig'},'trainlm','learnhd','mse');
    % PR - Rx2 matrix of min and max values for 1500 input elements
    % [5 12 14] - hidden layer with 12 neurons 1stLayer 5 neurons
2ndLayer and output layer of 14 outputs
    % {'tansig' 'tansig' 'tansig'} - transfer function for hidden and
output layer
    % 'trainlm' - network training function
    % 'learnhgd' - Backprop weight/bias learning function
    % 'mse' - Performance function, default

net.layers{1}.initFcn = 'initnw';
net.layers{2}.initFcn = 'initnw';
net.layers{3}.initFcn = 'initnw';
    % INITNW - Initializes a layer's weights and biases according to
the
    % Nguyen-Widrow initialization algorithm. This algorithm chooses
values
    % in order to distribute the active region of each neuron in the
layer
    % evenly across the layer's input space.

net.inputWeights{1,1}.initFcn='rands';
net.biases{1,1}.initFcn = 'rands';
net.biases{2,1}.initFcn = 'rands';
net.biases{3,1}.initFcn = 'rands';
    % RANDES - Symmetric random weight/bias initialization function

net=init(net);
    % INIT(NET)- returns neural network NET with weight and bias
values
    % updated according to the network initialization function,
indicated
    % by NET.initFcn, and the parameter values, indicated by
NET.initParam.

%*****
% Parameter Initialization
*
%*****

net.trainParam.show = 20;          % Show MSE after 20 epochs
net.trainParam.lr = 0.1;          % learning rate =0.1
net.trainParam.mc = 0.8;          % momentum constant =0.8
net.trainParam.epochs = 1000;    % training epochs =1000
net.trainParam.goal = 0.001;     % Error goal =0.01

```



```

%*****
% Train in batch mode, no early stopping
%*****
net = train(net,pn',tn');

%*****
% Simulate the network using the train data
%*****

%Evaluation of net's output
y1 = sim(net,pn');
gtp=y1';

%Postprocessing
for i=1:1:14
    NetResTrData(:,i)=postmmx(gtp(:,i),mint(i),maxt(i));
end

figure
%Plotting the nets output
subplot(2,2,1);
bar(NetResTrData(:,1));
%Plotting the desired result
subplot(2,2,2);
bar(TrainDataTargets(:,1));
%Plotting the nets output and the desired result on the same graph
subplot(2,2,3);
plot(NetResTrData(:,1));
hold on
plot(TrainDataTargets(:,1), 'red');
%Plotting the nets output and the desired result difference
figure
plot(abs(NetResTrData(:,i)-TrainDataTargets(:,i)));

for i=1:1:14
    forever=0;
    for j=1:1:2000
        if(abs(NetResTrData(j,i)-
TrainDataTargets(j,i))/TrainDataTargets(j,i)<0.03)
            forever=forever+1;
        end
    end
    total(i)=forever;
end
%*****
% Simulate the network using the test data
*
%*****

%Evaluation of net's output
y2 = sim(net,pnT');
gtp=y2';

```

```

%Postprocessing
for i=1:1:14
    NetResTestData1(:,i)=postmmx(gtp(:,i),mintT(i),maxtT(i));
end

figure
%Plotting the nets output
subplot(2,2,1);
bar(NetResTestData1(:,1));
%Plotting the desired result
subplot(2,2,2);
bar(TestDataTargets(:,1));
%Plotting the nets output and the desired result on the same graph
subplot(2,2,3);
plot(NetResTestData1(:,i));
hold on
plot(TestDataTargets, 'red');
%Plotting the nets output and the desired result difference
figure
plot(abs(NetResTestData1(:,i)-TestDataTargets(:,i)));

for i=1:1:14
    forever=0;
    for j=1:1:50
if(abs(NetResTestData1(j,i) -
TestDataTargets(j,i))/TestDataTargets(j,i)<0.03)
        forever=forever+1;
end
end
total1(i)=forever;
end

```