

46563

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**İ.C. YÜKSEKÖĞRETİM KURULU  
DOKÜMANTASYON MERKEZİ**

**GÜÇ SİSTEMİ GÖZETİMİNDE YAPAY NÖRAL DEVRE İLE  
STOKASTİK İŞARET İŞLEME**

**DOKTORA TEZİ**

**Y . Müh. Serhat ŞEKER**

**Tezin Enstitüye Verildiği Tarih : 21 Aralık 1994**

**Tezin Savunulduğu Tarih : 9 Mart 1995**

**Tez Danışmanı : Prof. Dr. Özer ÇİFTÇİOĞLU**

**Diğer Jüri Üyeleri : Prof. Dr. Vural ALTIN**

**: Doç. Dr. Aydoğan ÖZDEMİR**

**MART 1995**

## ÖNSÖZ

Bu çalışmayı yapabilmem için bana olanak sağlayıp, önderliğini hiç bir zaman esirgemeyen, çalışmamın devamı süresince gösterdiği çok yakın ilgi ve yardımlarından dolayı sayın hocam Prof. Dr. ÖZER ÇİFTÇİOĞLU 'na,

Çalışmamın her döneminde yakın ilgisini gördüğüm ve Hollanda 'daki çalışmalarında her türlü olanağı sağlayan, kıymetli görüşlerinden faydalandığım, gerçek dost, örnek kişi ; Hollanda Enerji Araştırma Merkezi (ECN)-Nükleer Çalışma Birimi, İşaret Analizi Grup Başkanı sayın ERDİNÇ TÜRKCAN 'a,

Ayrıca bu çalışmayı gerçekleştirebilmem için beni destekleyen NUFFIC (Yüksek Öğretimde Uluslararası İşbirliği, Hollanda Organizasyonu), ECN ve İ.T.Ü. Elektrik Mühendisliği Bölümü 'ne teşekkür ederim.

İstanbul, 1994

Serhat Şeker

## İÇİNDEKİLER

|                                                                                                                                          |      |
|------------------------------------------------------------------------------------------------------------------------------------------|------|
| NOTASYON LİSTESİ.....                                                                                                                    | iv   |
| ÖZET.....                                                                                                                                | viii |
| SUMMARY.....                                                                                                                             | ix   |
| BÖLÜM 1. GİRİŞ.....                                                                                                                      | 1    |
| BÖLÜM 2. DOĞRUSAL STOKASTİK İŞARET<br>MODELLEMESİ VE KAFES YAPISI.....                                                                   | 5    |
| 2.1. Özbağılaşım (AR) Modelleme.....                                                                                                     | 5    |
| 2.2. Kafes Modelleme.....                                                                                                                | 8    |
| 2.3. Öngörü Süzgecinin Kafes Yapı ile Gerçeklenmesi.....                                                                                 | 16   |
| BÖLÜM 3. YAPAY NÖRAL DEVRENİN KISA ANLATIMI.....                                                                                         | 22   |
| BÖLÜM 4. YAPAY NÖRAL DEVRE İLE STOKASTİK<br>İŞARET İŞLEME.....                                                                           | 27   |
| BÖLÜM 5. GÜÇ SİSTEMİ GÖZETİMİNDE YAPAY NÖRAL<br>DEVRE İLE STOKASTİK İŞARET İŞLEME VE ARIZA<br>SAPTAMASI ÜZERİNE BENZETİM ÇALIŞMASI ..... | 36   |
| BÖLÜM 6. GERÇEK GÜÇ SİSTEMİNDE İŞARET<br>MODELLEMESİ VE ARIZA SAPTAMASI.....                                                             | 57   |
| SONUÇLAR.....                                                                                                                            | 73   |
| KAYNAKLAR.....                                                                                                                           | 75   |
| EK-A .....                                                                                                                               | 78   |
| EK-B.....                                                                                                                                | 82   |
| ÖZGEÇMİŞ.....                                                                                                                            | 84   |

## NOTASYON LİSTESİ

|                               |                                                                                                                                       |
|-------------------------------|---------------------------------------------------------------------------------------------------------------------------------------|
| $L$                           | : Nöral devre giriş tabakası eleman sayısı                                                                                            |
| $M$                           | : Nöral devre saklı tabaka eleman sayısı                                                                                              |
| $N$                           | : Nöral devre çıkış tabakası eleman sayısı                                                                                            |
| $y_n'$                        | : Bir rastlantı sürecinden alınan $y_n$ işaretinin sonlu sayıda örnekten oluşan zaman serisi şeklindeki modelinin $n$ anındaki değeri |
| $y_n$                         | : Bir rastlantı sürecinden alınan $y_n$ işaretinin $n$ anındaki değeri                                                                |
| $y_{n-i}$                     | : $y_n$ işaretinin kendinden önceki değerleri                                                                                         |
| $a_i$                         | : Özbağlısımlı modele ilişkin katsayılar                                                                                              |
| $p$                           | : Model mertebesi                                                                                                                     |
| $e_p$                         | : İşaretin gerçek ve kestirilmiş değeri arasındaki hata                                                                               |
| $e_p(n)$                      | : Beyaz gürültü süreci                                                                                                                |
| $E$                           | : Ortalama değer işlemcisi veya matematiksel beklenti                                                                                 |
| $R_{yy}(i)$                   | : $i=1, 2, \dots, p$ için özilişki fonksiyonları                                                                                      |
| $\sigma_p^2 \ \sigma_{p+1}^2$ | : $p$ . ve $p+1$ . mertebeden iki özbağlısımlı modelin varyansları                                                                    |
| $g_{p+1}$                     | : $p+1$ . mertebeden kafes modele ilişkin yansıma katsayısı                                                                           |
| $e_p^+(n)$                    | : $p$ . mertebeden ileriye doğru öngörü hatası                                                                                        |
| $E_p^+$                       | : $z$ -tanım bölgesinde, $p$ . mertebeden ileriye doğru öngörü hatası                                                                 |
| $e_p^-(n)$                    | : $p$ . mertebeden geriye doğru öngörü hatası                                                                                         |
| $E_p^-$                       | : $z$ -tanım bölgesinde, $p$ . mertebeden geriye doğru öngörü hatası                                                                  |
| $e_{p+1}^+(n)$                | : $p+1$ . mertebeden ileriye doğru öngörü hatası                                                                                      |
| $E_{p+1}^+$                   | : $z$ -tanım bölgesinde, $p+1$ . mertebeden ileriye doğru öngörü hatası                                                               |

- $e_{p+1}^-(n)$  : p+1. mertebeden geriye doğru öngörü hatası
- $E_{p+1}^-$  : z-tanım bölgesinde, p+1. mertebeden geriye doğru öngörü hatası
- $\underline{e}^-(n)$  : Bütün mertebeler için oluşturulan geriye doğru öngörü hataları vektörü
- $\underline{y}(n)$  :  $y_n$  işaretinin, p. mertebeye kadar kendi ve kendinden önceki değerlerinden oluşmuş vektör.
- $\underline{A}$  : Bütün mertebeler için oluşturulan geriye doğru öngörü hatalarının, özbağlaşım katsayılarını içeren katsayı matrisi
- $y_{n+1}$  :  $y_n$  işaretinin p. mertebeye kadar, kendinden önceki değerlerinden oluşmuş bir adım ileri öngörü süzgeci
- $a_{p,i}$  : Bir adım ileri öngörü süzgecindeki katsayılar
- $\underline{a}_p^T$  : Bir adım ileri öngörü süzgecindeki katsayılar matrisinin transpozesi
- $\underline{K}$  : Geriye doğru öngörü hatalarından oluşturulan bir adım ileri öngörü süzgecinin katsayılar vektörü
- $\underline{K}^T$  : Geriye doğru öngörü hatalarından oluşturulan bir adım ileri öngörü süzgecinin katsayılar vektörünün transpozesi
- $y_{jp}^N, F_j$  : p. örüntü için nöral devrenin çıkış tabakasının j. işleme elemanının, sigmoid fonksiyonu çıkışı
- $w_{ij}^N$  : Nöral devrenin çıkış tabakası işleme elemanlarının ağırlık katsayıları
- $\theta_j$  : Nöral devrede j. işleme elemanına ilişkin ek terim
- $e_{p+1}(n+1)$  : Kafes yapı kalıntı hatası
- $\varepsilon_{p+1}(n+1)$  : Nöral devre kalıntı hatası
- $s(\cdot), F_j$  : Sigmoid fonksiyonu
- o.y.f. : Olasılık yoğunluk fonksiyonu
- $d_j$  : Nöral devrenin, j. çıkış elemanındaki istenen çıkış (hedef değer)

|              |                                                                                  |
|--------------|----------------------------------------------------------------------------------|
| $\delta_j$   | : Nöral devrenin j. çıkış elemanında karesel hatadaki değişim                    |
| $f_g(.)$     | : Giriş olasılık yoğunluk fonksiyonu                                             |
| $f_c(.)$     | : Çıkış olasılık yoğunluk fonksiyonu                                             |
| PWR          | : Basınçlı Su Reaktörü (Pressurized Water Reactor)                               |
| $\mu_x$      | : Giriş olasılık yoğunluk fonksiyonunun ortalama değeri                          |
| $m^*$        | : Doğru denkleminin eğimi                                                        |
| $n^*$        | : Doğru denkleminin sabit terimi                                                 |
| $\sigma_x^2$ | : Giriş olasılık yoğunluk fonksiyonuna ilişkin varyans                           |
| $\sigma_y^2$ | : Çıkış olasılık yoğunluk fonksiyonuna ilişkin varyans                           |
| $\mu_y$      | : Çıkış olasılık yoğunluk fonksiyonunun ortalama değeri                          |
| ms           | : Mili saniye                                                                    |
| k            | : Kullanılan verilerin blok sayısı, Bozucu etkinin kazanç değeri                 |
| c            | : Kurtosis (Basıklık)                                                            |
| s            | : Skewness (Çarpıklık)                                                           |
| a            | : Birinci mertebe özbağımlı süreçten üretilen bozucu etki katsayısı              |
| $\sigma_w^2$ | : Beyaz gürültü varyansı                                                         |
| $\sigma_b^2$ | : Bozucu etki varyansı                                                           |
| $\eta$       | : Nöral devrenin ağırlık katsayılarını güncellemede kullanılan yakınsama çarpanı |
| $\nabla_k$   | : k. adımdaki gradyent işlemcisi                                                 |
| $\Delta$     | : Sonlu fark simgesi                                                             |
| $P_i$        | : X rastlantı değişkeninin $x_i$ değerini alma olasılığı                         |
| $F(x_i)$     | : Olasılık dağılım fonksiyonu                                                    |

- $m_k$  : k. mertebeden moment
- $m_1$  : Birinci mertebeden moment , aritmetik ortalama
- $\mu_k$  : k. mertebeden merkezi moment
- $\mu_2$  : 2. mertebeden merkezi moment, (varyans)
- $\mu_3$  : 3. mertebeden merkezi moment
- $\mu_4$  : 4. mertebeden merkezi moment



## ÖZET

Sistem dinamiğindeki değişimleri belirleme problemi son yıllarda dikkate değer bir gelişme göstermektedir. Nedeninin çeşitli olmasına rağmen, ilgili uygulamanın doğasına bağlı olan bu durum, özellikle güç santrallerinde işletim güvenliği ile yakından ilgilidir. Basit olarak problem, sistem dinamiği ve herhangi bir durağan olmayan davranış tarafından belirlenen işletim durumunu, zaman içerisinde tam olarak belirlemeyi içermektedir.

Kararlı bir süreçte, süreç değişkenleri nominal değerleri civarında değişimler gösterirler. Bu değişimler gürültü olarak isimlendirilirler ve sistem dinamiği hakkında önemli bir bilgi içerirler. Gürültünün sahip olduğu istatistiksel özellikler bakımından sistem dinamiğindeki herhangi bir değişim, gürültüye yansır ve gürültüye yapılan bu ilave katkı, istatistiksel özelliklerde ortaya çıkan bir değişiklik olarak, çeşitli işaret işleme yöntemleri aracılığı ile kolayca belirlenebilir. Bununla ilgili oldukça genel bir yaklaşım, beyaz gürültü tarafından sürülen sonlu mertebede, ayrık zamanlı doğrusal bir sistemin çıkış süreci ile ilgili olan işaret modellemesidir. Genel olarak böyle süreçler özbağlımlı (AR) süreçler olarak isimlendirilir ve sonlu impuls cevaplı (FIR) süzgeç olarak veriyi işleyen, bir doğrusal öngörücü (linear predictor) şeklinde ifade edilebilirler. Böyle süzgeçler, kafes yapı olarak isimlendirilen özel bir yapıda, zincirleme gecikme elemanları kullanılarak gerçekleştirilebilirler.

Sistem dinamiğindeki değişimler ise kafes yapıdaki ileriye doğru kalıntılarla birlikte geriye doğru kalıntılar şeklindeki işaretin model parametrelerinin, çeşitli işaret işleme yöntemleriyle incelenmesiyle saptanabilir. Bu çalışmada ilgilenilen işaret işleme yöntemi olarak, bir çok konuda uygulama alanı bulabilen nöral devrelerden yararlanılmıştır. Bilindiği gibi kafes yapının doğrusal bir yapı olmasına karşın nöral devre doğrusal olmayan bir yapıya sahiptir. Ancak, nöral devrenin doğrusal çalışmaya zorlanmasıyla ve her iki devrenin de aynı kaynaktan beslenmesi nedeniyle bu iki yapının ürettikleri çıkışlar bakımından, aralarında bir ilişki (korelasyon) söz konusudur. Bu durumda hem benzetim (simülasyon) verisi, hem de Hollanda 'da Borssele-PWR nükleer güç santralının elektrik gücü verisi üzerinde yapılan, arıza belirleme incelemelerinde yapay olarak üretilen arıza, çeşitli özellikleri ile saptanmasına rağmen, bu iki yaklaşımın birbirlerine göre kesin bir üstünlüğü sözkonusu olmamaktadır. Ancak, nöral devre girişine ilave bir giriş olarak, AR-öngörü süzgecinin kafes yapı gerçekleştirilmesindeki çıkışın verilmesi ile nöral devre, artık aynı kaynaktan beslenen bir devre olmayıp kafes yapıdan elde edilen çıkıştan bağımsız bir çıkış vermektedir. Dolayısıyla sözü edilen bu iki çıkış birbirlerinden bağımsız hale gelmektedir. Bu durumda arıza belirlemesine ilişkin incelemelerde kalıntı varyansları bakımından arızayı saptamadaki duyarlılık önemli ölçüde artmaktadır ve konuya önemli bir katkı getirmektedir. Ayrıca sistemi algoritmik modelleme ve arızayı her güç seviyesinde belirleme gibi bazı özellikler de, kullanılan yöntemin sağladığı diğer önemli olanaklar arasındadır.

## SUMMARY

### STOCHASTIC SIGNAL PROCESSING WITH NEURAL NETWORK IN POWER PLANT MONITORING

The problem of detecting changes in system dynamics has been receiving growing attention in the last decade. Although the reason for this can vary, the case being dependent on the nature of application of concern, in particular, in a power plant the case is closely related to the plant's operational safety. This is simply because the operational status is determined by the system dynamics and any non-stationary behavior has to be assessed correctly in order to be able to take appropriate action in time. In a steady-state course of a process the process variables fluctuate around their nominal values. These fluctuations are termed as noise and they contain substantial information about the system dynamics. As the noise has its individual statistical characteristics, any change in the system dynamics is reflected in the noise and this additional contribution to noise is relatively easily identified by means of advanced signal processing methods exploiting the modification of the statistical properties. For this, a rather common approach is the signal modelling which concerns the process which is an output of a finite-order discrete time linear system driven by white noise. Such processes are called autoregressive (AR) as a general name and they can be represented in the form of a linear predictor which is actually a finite impulse response (FIR) filter acting on the data. If a signal which is obtained from a random process is modelled by a time series, the error between real and modelled signals can be presented by

$$e_p(n) = y_n - y'_n$$

Here,  $y'$  is the signal modelled by a time series and given by

$$y'_n = - \sum_{i=1}^p a_i y_{n-i}$$

so that

$$e_p(n) = y_n + \sum_{i=1}^p a_i y_{n-i}$$

In this formulation, the  $e_p$  is white noise processes. By arranging the last equation we obtain an AR process of the form

$$y_n = -\sum_{i=1}^p a_i y_{n-i} + e_p(n)$$

which presents a one-step-ahead prediction filter. Such filters can be realized in different ways such as direct realization known as tapped delay form, a particular form of which is called lattice (ladder) structure. This structure is presented by means of

$$e_{p+1}^+(n) = e_p^+(n) - g_{p+1} e_p^-(n-1)$$

$$e_{p+1}^-(n) = e_p^-(n-1) - g_{p+1} e_p^+(n)$$

in the time domain. Here,  $g_{p+1}$  is called as the reflection coefficient and it can be expressed in terms of the forward and backward residuals by

$$g_{p+1} = \frac{E[e_p^+(n) e_p^-(n-1)]}{E[e_p^-(n-1)^2]} = \frac{E[e_p^+(n) e_p^-(n-1)]}{E[e_p^+(n)^2]}$$

The initialization at  $p = 0$  is performed by :

$$e_0^+(n) = e_0^-(n) = y(n).$$

The lattice structure of the prediction error filter based on the recursion above is shown in Figure 1.




Figure 1 One stage of a lattice structure.

where  $e_p^+$  are forward residual and  $e_p^-$  are backward residuals. Here both  $e_i^+$  and  $e_i^-$  ( $i=1, 2, \dots, p$ ) are white noise processes. Lattice realization of signal modelling has several desirable features the case being dependent on the specific application. Among these features mention may be made of its individual structure, which is

suitable for adaptive filtering since the recursive solution of the least squares estimators naturally produces a lattice filter structure. It orthogonalizes the input signal stage-by-stage, so that it provides very fast convergence. As a filter, it has special parameters as filter coefficients with magnitude less than unity providing an easy means for checking the stability of a filter.

Studies on the lattice filtering theory took place extensively in literature in the last decade and a number of applications concerning adaptive techniques together with estimation filter parameters. However due to the stability problems encountered during the adaptive process, least squares solution in a recursive manner is the most suitable approach to be performed due to fast convergence properties. Although the lattice realization of FIR-Wiener filter treated in literature, it seems no adaptive identification of the lattice parameters in form of an autoregressive process is reported in literature, as this approach is performed in this work. The schematic representation of this filter is given below.




Figure 2 Lattice realization of the prediction error filter.

The detection of changes in system dynamics can be enhanced by further processing of the identified signal modelling parameters which are known to be backward residuals together with one-step-ahead prediction. The further processing involved can be performed effectively by means of the neural networks (NN) technology which is an emerging technology and found application in a number of application areas. Among these the engineering disciplines can be mentioned in the first place.

A neural network is in the form of a set of  $N$  elementary processing units which are divided into groups where each group is considered to be a subset. Each unit receives at its input, signals from the preceding subset units or from the external information sources at the input. The processing units with their input-output connections form a layered neural network structures as shown in Figure 3.




Figure 3 A layered neural network.  
 $L$  : Number of input nodes.  
 $M$  : Number of hidden layer nodes.  
 $N$  : Number of output nodes.

The weighted sum is compared with a threshold and the output is applied to a logistic function for an eventual non-linear transformation of the input signal. In this way the neural network structure can be seen as a model of a system and determination of the model parameters becomes the main concern.

In order to determine the model parameters, the information from the actual system under investigation is accumulated and thereafter the accumulated information is processed by means of the NN structure. This particular process is termed as "training" where the applied input information is in compact form termed as "patterns". The output of the NN structure is compared with the corresponding information provided and the weights of the connections between the nodes are so determined that the difference between the output and the provided information subject to comparison is minimum. Although the training of the network is stochastic in nature, the network itself for stochastic signals received relatively less attention.

In this research, noise analysis studies with neural networks are aimed. For this first the statistical properties of neural network for gaussian inputs is investigated. In general terms, stochastic signals at the input of the network are used to obtain an algorithmic multivariate stochastic signal modelling. In particular however, lattice modelling, of a stochastic signal is performed to obtain backward residual noise sources which are uncorrelated among themselves. These are applied together with an additional input to the network to obtain an algorithmic one -step ahead prediction model which is used for signal detection of early failure in plant monitoring. The additional input is the one-step ahead prediction from the linear FIR-Wiener filter which is highly correlated with its non-linear counterpart obtain from the neural network. Hence, the additional input provides the information to the network so that the difference between the signal and the network's one-step-ahead prediction is minimized far beyond of that obtained by linear prediction. The system of lattice structure coupled to a feedforward neural network is investigated with measured signals from an actual power plant. The structure of lattice filter connected to neural network used in this study is performed as shown below.




Figure 4 The structure of lattice filter connected to neural network.

After an adaptive signal processing phase, the lattice modelling of the signal is carried out. Thus, the backward residuals having been obtained, the neural network with single output is trained where the output in operation after training is devised to be at "zero level" for normal operation.

The orthogonality of the backward residuals provides a fast convergence required in the training with the stochastic patterns. In the case of failure reflected in the signal subjected to analysis, a stressed outcome at the network's output is produced as that information is new to the network and therefore is not consistent with the stored statistical information meant for duly estimation in normal operation.

The above description of the signal modelling realized by coupling a lattice structure with a neural network indicate the enhanced change detection in system dynamics due to the nonlinearity of the neural network. Namely, the linear signal modelling is forced to be modified to non-linear signal modelling where the correlation between the linear and the non-linear models is greatly reduced by an appropriate choice of the algorithmic model of the neural network. Hence the signal-to-noise ratio where signal is the reflection of the change of system dynamics into the correlation and noise is the minimized correlation as obtained using neural network, is greatly improved as required particularly in early fault detection and diagnosis applications. The utilization of feedforward neural network with noise signals for failure detection in process systems is demonstrated and verifications with the actual plant data with simulated failures on, are presented.



## BÖLÜM 1

### GİRİŞ


Sistem dinamiğindeki değişimleri belirleme problemi son yıllarda dikkate değer bir gelişme göstermektedir [1-7]. Nedeninin çeşitli olmasına rağmen, ilgili uygulamanın doğasına bağlı olan bu durum, özellikle güç santrallerinde işletim güvenliği ile yakından ilgilidir. Basit olarak problem, sistem dinamiği ve herhangi bir durağan olmayan davranış tarafından belirlenen işletim durumunu, zaman içerisinde tam olarak belirleme olmaktadır.

Kararlı bir süreçte, süreç değişkenleri nominal değerleri civarında değişimler gösterirler. Bu değişimler gürültü (noise) olarak isimlendirilirler ve sistem dinamiği hakkında önemli bir bilgi (enformasyon) içerirler. Gürültünün sahip olduğu istatistiksel özellikler bakımından ise sistem dinamiğindeki herhangi bir değişim, gürültüye yansır ve gürültüye yapılan bu ilave katkı, istatistiksel özelliklerde ortaya çıkan bir değişiklik olarak, çeşitli işaret işleme yöntemleri aracılığı ile kolayca belirlenebilir. Bununla ilgili oldukça genel bir yaklaşım, beyaz gürültü tarafından sürülen sonlu mertebede, ayrık zamanlı doğrusal (lineer) bir sistemin çıkış süreci ile ilgili olan işaret modellemesidir. Genel olarak böyle süreçler özbağımlı (AR) süreçler olarak isimlendirilir ve gerçekte sonlu impuls cevaplı (FIR) süzgeç olarak veriyi kullanan, bir doğrusal öngörücü (linear predictor) şeklinde ifade edilebilirler. Böyle süzgeçler, kafes yapı olarak isimlendirilen özel bir şekilde, zincirleme gecikme elemanları kullanılarak farklı şekillerde gerçekleştirilebilirler.

İşaret modellemenin kafes yapı gerçekleştirilmesi, uygulamaya bağlı olarak istenilen bir kaç özelliğe sahiptir. En küçük kareler kestiricilerinin yinelemeli çözümleri, kafes süzgeç yapısını ürettiğinden dolayı, sözü edilen bu özellikler arasında uyarlamalı süzgeçlemeye uygun bir yapı oluşturma sayılabilir. Bu durumda hızlı yakınsama sağlansın diye giriş işareti adım adım dikleştirilir. Kafes yapıdaki süzgeç kararlılığı ise büyüklüğü "1" den küçük olan süzgeç katsayıları gibi bazı özel büyüklükler (parametreler) tarafından sağlanır.

Kafes süzgeç kuramı üzerine yapılan çalışmalar, konuya ilişkin yapılan diğer çalışmalar arasında geniş olarak yer almıştır ve süzgeç parametrelerinin kestirimi ile birlikte uyarlamalı tekniklerle de ilgili olarak, bir çok uygulamaya ilişkin duyurularda bulunulmuştur [8-17]. Ancak uyarlamalı süreç sırasında karşılaşılan kararlılık problemleriyle ilgili olarak, yinelemeli anlamında en küçük kareler çözümü, hızlı yakınsama özelliğine sahip olması bakımından en uygun yaklaşımdır. Bu durumda ilk olarak, kafes yapı gerçekleştirilmesi için FIR-Wiener yaklaşımı ile kafes yapısını oluşturma, hemen akla gelebilecek bir ele alış şeklidir. FIR-Wiener süzgecinin kafes yapı gerçekleştirilmesi, konuya ilişkin yapılan çalışmalar arasında yer almış olmasına rağmen, özbağlaşımlı süreç yaklaşımı ile kafes yapı parametrelerinin uyarlamalı olarak belirlenmesi yer almamış görünmektedir.

Sistem dinamiğindeki değişimlerin saptanması, kafes yapıdaki ileriye doğru kalıntılarla birlikte geriye doğru kalıntılar şeklindeki işaretin model parametrelerinin, daha başka yöntemlerle işlenmesiyle daha da duyarlı hale getirilebilir. İlgilenilen bu işaret işleme yöntemi, bir çok alanda uygulanabilen nöral devre teknolojisi yardımıyla etkin olarak yerine getirilebilir [18-20]. Ayrıca güç sistemlerindeki uygulamalar da yapılmış bulunmaktadır [21-24]. Bir nöral devre, gruplara bölünmüş  $N$  tane işleme elemanından oluşmuş bir küme şeklindedir. Girişteki her bir eleman dış bilgi kaynağından gelen işareti alır. Giriş-çıkış bağlantıları arasındaki elemanlardan oluşmuş bir nöral devre ise Şekil 1-1 'de gösterildiği gibi tabakalı nöral devreyi oluşturur.



Şekil 1-1 Tabakalı nöral devre.

$L$  : Giriş tabakası, eleman sayısı.

$M$  : Saklı tabaka, eleman sayısı.

$N$  : Çıkış tabakası, eleman sayısı.

Burada ağırlıklı toplam bir eşik değeri ile karşılaştırılır ve çıkış değeri olarak, giriş işaretinin doğrusal olmayan dönüşümünü verecek şekilde bir lojistik fonksiyona uygulanır. Bu şekildeki nöral devre yapısı bir sistem modeli olarak görülebilir ve buradan model parametrelerinin belirlenmesi sağlanabilir. Model parametrelerini belirlemek için, ilgilenilen gerçek sistemden gelen bilgi biriktirilir ve daha sonra biriktirilmiş bu bilgi nöral devre aracılığı ile işlenir. Bu özel süreç, nöral devrenin "eğitim" süreci olarak isimlendirilir. Burada uygulanan giriş bilgisi de "örüntü" olarak isimlendirilen toplu bir yapıyı içerir. Nöral devre yapısının çıkışı, bilinen uygun bir bilgi ile karşılaştırılır ve çıkış bilgisi ile önceden bilinen bilgi arasındaki fark en küçük yapılacak şekilde, işleme elemanları (düğüm) arasındaki bağlantı ağırlıkları belirlenir.

Nöral devre ile kafes yapısı birleştirilerek gerçekleştirilen işaret modellemesinin yukarıda verilen betimlemesi, nöral devrenin doğrusal olmayan yapısından dolayı sistem dinamiğindeki değişimi daha duyarlı bir şekilde belirler. Yani doğrusal işaret modelleme, nöral devrenin algoritmik modelinin yaklaşık seçimi ile öngörü hatasının büyük ölçüde azaltıldığı, doğrusal olmayan işaret modellemeye zorlanmış olur. Böylece sistem dinamiğindeki değişimi yansıtan büyüklük olarak, işaretin kendisi ve gürültü olarak isimlendirilen, nöral devre aracılığı ile en küçük (minimize) yapılmış öngörü hatasının gözönüne alınmasıyla oluşturulan işaret-gürültü oranı; tanı uygulamaları ve özellikle gereksinim duyulan erken arıza belirlemelerinde, oldukça büyük bir değerde olur.

Bu çalışma aşağıdaki gibi düzenlenmiştir :

Birinci bölümde konunun genel çerçevesinde problem ortaya konularak, bununla ilgili beklenen sonuçlardan söz edilmiştir. İkinci bölümde özbağlısımlı (AR) model ve kafes modelleme tanıtılarak öngörü süzgecinin kafes yapı ile gerçekleşmesi sağlanmıştır. Üçüncü bölümde ise yapay nöral devrenin kısa anlatımı yapılarak buradaki temel kavramlar verilmiştir. Dördüncü bölümde de yapay nöral devre ile stokastik işaret işleme konusu ele alınarak, nöral devrenin giriş tabakasına gaussian olasılık yoğunluk fonksiyonları şeklinde stokastik işaretler uygulanırsa, nöral devrenin eğitiminin, işaretin istatistiksel özelliklerini öğrenmesi bakımından, nasıl önem kazanacağı vurgulanmıştır. Bu amaçla ikinci bölümde verilen öngörü süzgecinin kafes yapı gerçekleştirmesindeki, geriye doğru öngörü hataları, gaussian rastlantı değişkenleri olarak kabul edilerek, nöral ağ giriş tabakasına stokastik işaretler olarak uygulanmıştır. Ayrıca nöral devrenin bir işleme elemanı ele alınarak, girişe verilen olasılık yoğunluk fonksiyonlarının, doğrusal olmayan dönüşüm sonucunda alacağı durumlar da, ayrıntılı

olarak incelenmiştir. Beşinci bölümde de güç sistemi gözetiminde yapay nöral devre ile stokastik işaret işleme ve arıza belirlenmesi üzerine benzetim (simülasyon) çalışması yapılarak, nöral devrenin uygun seçilen yapısı ile benzetim (simülasyon) programı çıkış veri dosyaları oluşturularak, bu veri dosyalarına ilişkin olarak arızanın olduğu ve olmadığı durumlar incelenmiştir. Altıncı bölümde ise önceki bölümün gerçek veri bakımından uygulamasını gerçeklemek üzere, Hollanda' da Borssele-PWR Nükleer Güç Santralının elektrik gücü verisi kullanılarak, güç sisteminde işaret modellemesi ve arıza belirlenmesi, çeşitli istatistiksel özellikler açısından incelenerek, bilinen yöntemlere göre çok daha duyarlı sonuçlar elde edilmiştir. Sonuç bölümünde ise konuya getirilen katkı bakımından, arıza belirleme çalışmasının, sistem dinamiğindeki küçük değişimlere bile ne kadar duyarlı olduğu vurgulandıktan sonra, yöntemin her güç seviyesinde kolay ve etkin olarak kullanılabileceği gösterilmiştir.



## BÖLÜM 2

### DOĞRUSAL STOKASTİK İŞARET MODELLEMESİ VE KAFES YAPISI

#### 2.1. Özbağlısımlı (AR) Modelleme

Bir rastlantı sürecinden alınan  $y$  işareti, sonlu sayıda örnekten oluşan zaman serisi şeklinde modellenirse işaretin  $n$  anındaki değeri  $y'_n$ , işaretin daha önceki değerleri cinsinden aşağıdaki model bağıntısıyla verilir.

$$y'_n = - \sum_{i=1}^p a_i y_{n-i}$$

Burada  $n$  örneklenmiş işarete zamanı;  $p$  model mertebesi olarak modelde söz konusu olan örnek sayısını;  $a_i$  modele ilişkin sabitleri göstermektedir. Buna göre  $y'_n$ , işaretin gerçek değerinin kestirilmiş değeri olup, gerçek değer ile kestirilmiş değer arasındaki hata,

$$e_p(n) = y_n - y'_n$$

veya

$$e_p(n) = y_n + \sum_{i=1}^p a_i y_{n-i} \quad (2.1)$$

olacaktır. Buradaki  $y_n$ , rastlantı sürecinden alınan işaret olup  $e_p(n)$  de bir beyaz rastlantı süreci olacaktır. Böylece (2.1) denkleminin,

$$y_n = - \sum_{i=1}^p a_i y_{n-i} + e_p(n) \quad (2.2)$$

şeklinde yazılmasıyla özbağlısımlı model tanımlanmış olur. Bu son ifadede  $e_p(n)$  için,

$$E\{e_p(n)e_p(j)\} = \begin{cases} \sigma_p^2 & n=j \\ 0 & n \neq j \end{cases}$$

olup, beyaz gürültü adını alır.

(2.2) denkleminde AR-katsayıları olarak isimlendirilen  $a_i$  sabitlerini bulmak için, bu denklemin her iki yanı  $y_n$  ile çarpılarak ortalaması alınır,

$$E\{y_n y_n\} = -\sum_{i=1}^p a_i E\{y_{n-i} y_n\} + E\{e_p(n) y_n\}$$

ve

$$R_{yy}(0) = -\sum_{i=1}^p a_i R_{yy}(i) + \sigma_p^2 \quad (2.3)$$

elde edilir.

Yine benzer şekilde, (2.2) denklemini  $y_{n-1}, y_{n-2}, \dots$ lerle çarpıp ortalamaları alınır,  $R(.)$  özilişki fonksiyonunun çift fonksiyon olduğunu da göz önünde bulundurarak,

$$R_{yy}(1) = -\sum_{i=1}^p a_i R_{yy}(i-1)$$

$$R_{yy}(2) = -\sum_{i=1}^p a_i R_{yy}(i-2) \quad (2.4)$$

·  
·  
·  
·  
·

$$R_{yy}(p) = -\sum_{i=1}^p a_i R_{yy}(i-p)$$

denklem takımı elde edilir.

(2.3) ve (2.4) denklemleri matris şeklinde düzenlenirse,  $\alpha_0 \triangleq 1$  tanımı ile,

$$\begin{bmatrix} R_{yy}(0) & R_{yy}(1) & \dots & \dots & R_{yy}(p) \\ R_{yy}(1) & R_{yy}(0) & \dots & \dots & R_{yy}(p-1) \\ \vdots & \vdots & \ddots & & \vdots \\ \vdots & \vdots & & \ddots & \vdots \\ R_{yy}(p) & R_{yy}(p-1) & \dots & \dots & R_{yy}(0) \end{bmatrix} \begin{bmatrix} 1 \\ a_1 \\ \vdots \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} \sigma_p^2 \\ 0 \\ \vdots \\ \vdots \\ 0 \end{bmatrix} \quad (2.5)$$

olup, tüm bilinmeyenleri çözmek için (2.5) matris denklemi

$$\begin{bmatrix} -\sigma_p^2 & R_{yy}(1) & \dots & \dots & R_{yy}(p) \\ 0 & R_{yy}(0) & \dots & \dots & R_{yy}(p-1) \\ \vdots & \vdots & \ddots & & \vdots \\ \vdots & \vdots & & \ddots & \vdots \\ 0 & R_{yy}(p-1) & \dots & \dots & R_{yy}(0) \end{bmatrix} \begin{bmatrix} 1 \\ a_1 \\ \vdots \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} -R_{yy}(0) \\ -R_{yy}(1) \\ \vdots \\ \vdots \\ -R_{yy}(p) \end{bmatrix}$$

şeklinde yazıldıktan sonra yeniden düzenlenirse


$$\begin{bmatrix} -1 & R_{yy}(1) & \dots & \dots & R_{yy}(p) \\ 0 & R_{yy}(0) & \dots & \dots & R_{yy}(p-1) \\ \vdots & \vdots & \ddots & & \vdots \\ \vdots & \vdots & & \ddots & \vdots \\ 0 & R_{yy}(p-1) & \dots & \dots & R_{yy}(0) \end{bmatrix} \begin{bmatrix} \sigma_p^2 \\ a_1 \\ \vdots \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} -R_{yy}(0) \\ -R_{yy}(1) \\ \vdots \\ \vdots \\ -R_{yy}(p) \end{bmatrix} \quad (2.6)$$

elde edilir.

(2.6) ile verilen matris denklemine "YULE-WALKER" denklemi denir. Buradan özbağlaşım (AR) katsayıları çözüldükten sonra, özbağlaşım (AR) modeli aşağıdaki gibi ifade edilir.

$$y_n = -\sum_{i=1}^p a_i (z^{-i} y_n) + e_p(n) \quad (2.7)$$

AR-modele ilişkin şekil ise aşağıdaki gibi oluşturulur.



Şekil 2-1 AR-Model.

## 2.2. Kafes Modelleme

Özbağlımlı (AR) modelden kafes yapı algoritmasını türetmek için aşağıdaki gibi  $p$  ve  $p+1$  mertebelerine sahip iki özbağlımlı süreç gözönüne alınsın.

$$y_n = -\sum_{i=1}^p a_i y_{n-i} + e_p(n) \quad (2.8)$$

$$y_n = -\sum_{i=1}^{p+1} a'_i y_{n-i} + e_{p+1}(n) \quad (2.9)$$

Bu iki denklemin her iki yanı  $y_n$  ile çarpılıp ortalaması alınırsa, o zaman özilişki

fonksiyonlarını  $R_{yy}(\cdot)$  yerine, aşağıdaki gibi  $R(\cdot)$  ile göstererek,

$$R(0) = -\sum_{i=1}^p a_i R(i) + \sigma_p^2 \quad (2.10)$$

$$R(0) = -\sum_{i=1}^p a_i' R(i) - a_{p+1}' R(p+1) + \sigma_{p+1}^2 \quad (2.11)$$

elde edilir. Eğer (2.11) denkleminin (2.10) denklemini çıkartılırsa,

$$\sigma_p^2 - \sigma_{p+1}^2 = -\sum_{i=1}^p (a_i' - a_i) R(i) - a_{p+1}' R(p+1) \quad (2.12)$$

olur. Burada,

$$g_{p+1} = \frac{\sum_{i=0}^p a_i R(p+1-i)}{\sum_{i=0}^p a_i R(i)} = \frac{\sum_{i=0}^p a_i R(p+1-i)}{\sigma_p^2} \quad (2.13)$$

tanımını kullanarak,

$$g_{p+1} \sigma_p^2 = \sum_{i=0}^p a_i R(p+1-i)$$

ve toplam indisini  $i=1$  den başlatarak,

$$g_{p+1} \sigma_p^2 = \sum_{i=1}^p a_i R(p+1-i) + a_0 R(p+1)$$

şeklinde yazıp,  $a_0=1$  değerinin kullanılması ile

$$g_{p+1} \sigma_p^2 = \sum_{i=1}^p a_i R(p+1-i) + R(p+1) \quad (2.14)$$

elde edilir. Bu son denklemin sağ tarafını (2.12) denkleminin sağ tarafına benzetmek için aşağıdaki gibi yazılırsa,

$$g_{p+1} \sigma_p^2 = \sum_{i=1}^p a_{p+1-i} R(i) + R(p+1) \quad (2.15)$$

olur.

$a'_i$  ve  $a_i$  ler arasındaki ilişkiyi  $g_{p+1}$  cinsinden ifade etmek için (2.15) denkleminin  $g_{p+1}$  ile çarpılmasıyla

$$g_{p+1}^2 \sigma_p^2 = \sum_{i=1}^p g_{p+1} a_{p+1-i} R(i) + R(p+1) \quad (2.16)$$

ve  $\sigma_{p+1}^2 = \sigma_p^2(1 - g_{p+1}^2)$  olsun diye, (2.16) ile (2.12) denklemlerinin taraf tarafa eşitlenmesiyle, sağ taraflarının eşitliğinden

$$-\sum_{i=1}^p (a'_i - a_i) R(i) - a'_{p+1} R(p+1) = \sum_{i=1}^p g_{p+1} a_{p+1-i} R(i) + g_{p+1} R(p+1)$$

veya

$$\sum_{i=1}^p \left[ -(a'_i - a_i) \right] R(i) + \left[ -a'_{p+1} \right] R(p+1) = \sum_{i=1}^p \left[ g_{p+1} a_{p+1-i} \right] R(i) + \left[ g_{p+1} \right] R(p+1)$$

elde edilir. Bu son bağıntıda ise katsayıların eşitliği gözönüne alınırsa,

$$-(a'_i - a_i) = g_{p+1} a_{p+1-i} \quad (2.17-a)$$

$$-(a'_{p+1}) = g_{p+1} \quad (2.17-b)$$

olur.

Böylece, (2.17-a) ve (2.17-b) denklemlerinin düzenlenmesiyle,

$$a'_i = a_i - g_{p+1} a_{p+1-i} \quad (2.18-a)$$

$$a'_{p+1} = -g_{p+1} \quad (2.18-b)$$

elde edilir.

Bu denklemler " Levinson Yineleme " bağıntısı olup,  $g_{p+1}$  katsayısı yansımaya katsayısı olarak bilinir. Ayrıca, (2.16) ve (2.12) denklemlerinin sol taraflarının eşitliğini kullanarak,  $\sigma_p^2$  ve  $\sigma_{p+1}^2$  kalıntı varyansları da, yansımaya katsayıları aracılığı ile,

$$\sigma_p^2 - \sigma_{p+1}^2 = g_{p+1}^2 \sigma_p^2 \quad p=0, 1, 2, \dots \quad (2.19)$$

$$\sigma_{p+1}^2 = \sigma_p^2 - g_{p+1}^2 \sigma_p^2$$

veya

$$\sigma_{p+1}^2 = \sigma_p^2 (1 - g_{p+1}^2) \quad p=0, 1, 2, \dots \quad (2.20)$$

şeklinde ilişkilendirir.

Burada  $\sigma_0^2$ , modellenmemiş verinin varyansıdır.  $\sigma_p^2$  ve  $\sigma_{p+1}^2$  nin her ikisi de pozitif olduğundan, (2.20) bağıntısına göre  $(1 - g_{p+1}^2)$  çarpanının da pozitif ve birden küçük olması gerekliliği ortaya çıkar. Bu çarpan  $p$ . yerine  $(p+1)$ . mertebeden bir öngörü süzgeci kullanılarak elde edilen, öngörüdeki düzeltemeyi gösterir. Buradan görülen diğer önemli bir nokta ise  $g_{p+1}$  in büyüklüğünün "1" den küçük olmasıdır.

Levinson yinelemesi  $z$ -tanım bölgesinde aşağıdaki gibi ifade edilebilir.

$$A'(z) = A(z) - g_{p+1} z^{-(p+1)} A(z^{-1}) \quad (2.21)$$

Burada,

$$A(z) = 1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_p z^{-p} \quad (2.22)$$

olup, (2.21) denklemi vektörel olarak

$$\begin{bmatrix} 1 \\ a'_1 \\ a'_2 \\ \vdots \\ a'_p \\ a'_{p+1} \end{bmatrix} = \begin{bmatrix} 1 \\ a_1 \\ a_2 \\ \vdots \\ a_p \\ 0 \end{bmatrix} - g_{p+1} \begin{bmatrix} 0 \\ a_p \\ a_{p-1} \\ \vdots \\ \vdots \\ 1 \end{bmatrix} \quad (2.23)$$

Aşağıdaki gibi,

$$A'(z) = z^{-p} A(z^{-1}) \quad (2.24)$$

ters polinom eşitliğini kullanarak, (2.21) denklemi,

$$A'(z) = A(z) - g_{p+1} z^{-1} A'(z)$$

veya mertebeleri de belirterek,

$$A_{p+1}(z) = A_p(z) - g_{p+1} z^{-1} A_p'(z) \quad (2.25)$$

olur. Böylece, bu son ifade (2.24) denklemi yardımıyla

$$A_{p+1}(z) = A_p(z) - g_{p+1} z^{-1} (z^{-p} A_p(z^{-1}))$$

veya

$$A_{p+1}(z) = A_p(z) - g_{p+1} z^{-(p+1)} A_p(z^{-1})$$

şeklinde yazılıp her iki yanının  $z^{p+1}$  ile çarpılması sonucunda,

$$z^{p+1} A_{p+1}(z) = z^{p+1} A_p(z) - g_{p+1} A_p(z^{-1})$$

denkleminde  $z=z^{-1}$  yazarak,

$$z^{-(p+1)} A_{p+1}(z^{-1}) = z^{-(p+1)} A_p(z^{-1}) - g_{p+1} A_p(z)$$

elde edilir.

Burada bu eşitliğin sol tarafını (2.24) ifadesine benzer şekilde

$$A_{p+1}'(z) = z^{-(p+1)} A_{p+1}(z^{-1})$$

ile tanımlayarak ve

$$A_{p+1}'(z) = z^{-1} z^{-p} A_p(z^{-1}) - g_{p+1} A_p(z)$$

şeklinde verilen bu son denklemde (2.24) eşitliğini tekrar kullanarak,

$$A_{p+1}^r(z) = z^{-1} A_p^r(z) - g_{p+1} A_p(z) \quad (2.26)$$

sonucuna varılır.

(2.25) ve (2.26) denklemleri matris şeklinde yazılırsa,

$$\begin{bmatrix} A_{p+1}(z) \\ A_{p+1}^r(z) \end{bmatrix} = \begin{bmatrix} 1 & -g_{p+1} z^{-1} \\ -g_{p+1} & z^{-1} \end{bmatrix} \begin{bmatrix} A_p(z) \\ A_p^r(z) \end{bmatrix} \quad (2.27)$$

elde edilir.

Matris şeklinde "Levinson Yinelemesi" olarak isimlendirilen (2.27) denklemi hata öngörü süzgeçlerinin kafes yapı gerçekleştirilmesinin temelini oluşturur.

Denklem (2.8) den yararlanarak,

$$e_p^+(n) = \sum_{i=0}^p a_i y_{n-i} \quad (2.28)$$

ve z-tanım bölgesinde

$$E_p^+(z) = A_p(z)Y(z) \quad (2.29)$$

yazılabilir.

Burada üst indis "+" işareti ileriye doğru hata öngörü dizisini gösterir. Böylece geriye doğru hata öngörü dizisini tanımlamak da mümkün olup, ters hata süzgeci olarak aşağıdaki gibi tanımlanabilir.

$$E_p^-(z) = A_p^r(z)Y(z) \quad (2.30)$$

$$e_p^-(n) = \sum_{i=0}^p a_i y_{n-p+i} \quad (2.31)$$

Ortalama-karesel geriye doğru öngörü hatası, ileriye doğru öngöründen elde edilen hata gibi aynı AR-katsayıları için minimum olacağından,

$$E_p^+ = E_p^- \quad (2.32)$$

olup, bu nedenle ileriye ve geriye doğru hata öngörü dizileri bakımından (2.27) matris denkleminin eşdeğerliliği aşağıdaki gibi gösterilebilir.

$$\begin{bmatrix} E_{p+1}^+(z) \\ E_{p+1}^-(z) \end{bmatrix} = \begin{bmatrix} 1 & -g_{p+1} z^{-1} \\ -g_{p+1} & z^{-1} \end{bmatrix} \begin{bmatrix} E_p^+(z) \\ E_p^-(z) \end{bmatrix} \quad (2.33)$$

Ayrıca, zaman tanım bölgesinde de,

$$e_{p+1}^+(n) = e_p^+(n) - g_{p+1} e_p^-(n-1) \quad (2.34)$$

$$e_{p+1}^-(n) = e_p^-(n-1) - g_{p+1} e_p^+(n) \quad (2.35)$$

olarak yazılabilir. (2.29) ve (2.32) denklemleri  $p=0$  için birlikte gözönüne alınırsa,


$$E_0^+ = E_0^- = A_0(z)Y(z) \quad (2.36)$$

veya zaman tanım bölgesinde

$$e_0^+(n) = e_0^-(n) = y(n) \quad (2.37)$$

olur.

Böylece, (2.34) ve (2.35) denklemlerinin şematik gösterimi ile kafes yapının en basit şekli aşağıdaki gibi oluşturulur.



Şekil 2-2 Kafes yapının en basit şekli.

Eğer (2.31) denklemi bütün p-model mertebeleri bakımından daha açık olarak yazılmak istenirse,

$$e_p^-(n) = \sum_{i=0}^p a_{p,i} y_{n-p+i}$$

olur.

Burada AR-katsayılarındaki birinci indis model mertebesini belirtmekte olup,  $\forall p$  için  $a_{p,0} = 1$  olmak üzere,

$$e_0^- = a_{0,0} y_n = y_n$$

$$e_1^- = a_{1,0} y_{n-1} + a_{1,1} y_n = a_{1,1} y_n + y_{n-1}$$

$$e_2^- = a_{2,0} y_{n-2} + a_{2,1} y_{n-1} + a_{2,2} y_n = a_{2,2} y_n + a_{2,1} y_{n-1} + y_{n-2}$$

$$\vdots$$

$$e_p^- = a_{p,0} y_{n-p} + a_{p,1} y_{n-p+1} + \dots + a_{p,p} y_n = a_{p,p} y_n + \dots + y_{n-p}$$

denklemleri matris şekline getirilerek,

$$\begin{bmatrix} e_0^-(n) \\ e_1^-(n) \\ \vdots \\ e_p^-(n) \end{bmatrix} = \begin{bmatrix} 1 & 0 & \dots & \dots & 0 \\ a_{1,1} & 1 & \dots & \dots & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ a_{p,p} & a_{p,p-1} & \dots & \dots & 1 \end{bmatrix} \begin{bmatrix} y_n \\ y_{n-1} \\ \vdots \\ y_{n-p} \end{bmatrix} \quad (2.38)$$

elde edilir. Kısaca,

$$\underline{e}^-(n) = \underline{A} \underline{y}(n) \quad (2.39)$$

şeklinde yazılabilir.

### 2.3. Öngörü Süzgecinin Kafes Yapı ile Gerçeklenmesi

Özbağlaşım (AR) katsayılarının "Yule-Walker" denklemleri yardımıyla belirlenmesinden sonra, aşağıdaki gibi bir adım ileri öngörü süzgeci gözönüne alınırsa,

$$y_{n+1} = \sum_{i=0}^p a_{p,i} y_{n-i} \quad (2.40)$$

olur. Bunun matris şeklinde yazılışı

$$y_{n+1} = \underline{a}_p^T \underline{y}(n) \quad (2.41)$$

olup, (2.39) denklemini yeniden yazarak,

$$\underline{e}^-(n) = \underline{A} \underline{y}(n)$$

ve buradan  $\underline{y}(n)$  nin çözülmesi sonucunda,

$$\underline{y}(n) = \underline{A}^{-1} \underline{e}^-(n) \quad (2.42)$$

elde edilir. (2.42) eşitliği, (2.41) de yerine yazılırsa,

$$y_{n+1} = \underline{a}_p^T \underline{A}^{-1} \underline{e}^-(n) \quad (2.43)$$

bulunur. Eğer,

$$\underline{K} = \underline{a}_p \underline{A}^{-T} \quad (2.44)$$

olacak şekilde bir K vektörü tanımlanırsa öngörü süzgeci bu yeni büyüklükler cinsinden

$$y_{n+1} = \underline{K}^T \underline{e}^-(n) = \sum_{i=0}^p K_i e_i^-(n) \quad (2.45)$$



Böylece  $i=0, 1, \dots, p$  için  $K_i$  katsayıları bulunmak istenirse, önce aşağıdaki gibi (2.41) denklemini gözönüne alarak,

$$y_{n+1} = \underline{a}_p^T y(n),$$

bunun her iki yanını  $\underline{y}_n^T$  ile çarpıp, ortalamasının alınması ile

$$E\{y_{n+1} \underline{y}_n^T\} = \underline{a}_p^T E\{\underline{y}_n \underline{y}_n^T\} \quad (2.47)$$

olur. Sonra, buradan  $\underline{a}_p^T$  vektörü çözülürse,

$$\underline{a}_p^T = E\{y_{n+1} \underline{y}_n^T\} \left[ E\{\underline{y}_n \underline{y}_n^T\} \right]^{-1} \quad (2.48)$$

elde edilir. (2.44) denklemini aşağıdaki gibi sıra değişimi (transpoze) şeklinde yazarak,

$$\underline{K}^T = \underline{a}_p^T \underline{A}^{-1} \quad (2.49)$$

ve (2.48) eşitliğini bu son denklemde yerleştirerek,

$$\underline{K}^T = E\{y_{n+1} \underline{y}_n^T\} \left[ E\{\underline{y}_n \underline{y}_n^T\} \right]^{-1} \underline{A}^{-1} \quad (2.50)$$

bulunur. (2.42) bağıntısını (2.50) de yazarak,

$$\begin{aligned} \underline{K}^T &= \left[ E\{y_{n+1} (\underline{A}^{-1} \underline{e}^-(n))^T\} \right] \left[ E\{(\underline{A}^{-1} \underline{e}^-(n)) (\underline{A}^{-1} \underline{e}^-(n))^T\} \right]^{-1} \underline{A}^{-1} \\ \underline{K}^T &= \underline{A}^{-T} \left[ E\{y_{n+1} (\underline{e}^-(n))^T\} \right] \underline{A} \underline{A}^T \left[ E\{\underline{e}^-(n) (\underline{e}^-(n))^T\} \right]^{-1} \underline{A}^{-1} \end{aligned}$$

ve buradan gerekli kısaltmaların yapılması ile,

$$\underline{K}^T = \left[ E \left\{ y_{n+1} (\underline{e}^-(n))^T \right\} \right] \left[ E \left\{ \underline{e}^-(n) (\underline{e}^-(n))^T \right\} \right]^{-1} \quad (2.51)$$

elde edilir. (2.51) eşitliğinin aşağıdaki gibi yazılmasıyla ise,

$$\underline{K}^T = \frac{E \left\{ y_{n+1} (\underline{e}^-(n))^T \right\}}{E \left\{ \underline{e}^-(n) (\underline{e}^-(n))^T \right\}} \quad 0 \leq i \leq p, \quad (2.52)$$

$$\underline{K}^T = \left( \frac{E \left\{ y_{n+1} e_0(n) \right\}}{\sigma_0^2}, \frac{E \left\{ y_{n+1} e_1(n) \right\}}{\sigma_1^2}, \dots, \frac{E \left\{ y_{n+1} e_p(n) \right\}}{\sigma_p^2} \right) \quad (2.53)$$

elde edilir.

Eğer (2.38) matris denklemindeki satırlar gözönüne alınırsa,

$$e_0^-(n) = y_n$$

$$e_1^-(n) = a_{1,1} y_n + y_{n-1}$$

$$e_2^-(n) = a_{2,2} y_n + a_{2,1} y_{n-1} + y_{n-2}$$

$$\vdots$$

$$e_p^-(n) = a_{p,p} y_n + a_{p,p-1} y_{n-1} + \dots + y_{n-p}$$

(2.54)

olup, (2.54) eşitliklerinin (2.53) eşitliğinde kullanılması ile,

$$\underline{K}^T = \left( \frac{E \left\{ y_{n+1} y_n \right\}}{\sigma_0^2}, \frac{E \left\{ y_{n+1} (a_{1,1} y_n + y_{n-1}) \right\}}{\sigma_1^2}, \dots, \frac{E \left\{ y_{n+1} (a_{p,p} y_n + a_{p,p-1} y_{n-1} + \dots + y_{n-p}) \right\}}{\sigma_p^2} \right)$$

(2.55)

şeklinde yazılabilir ve ilişki fonksiyonları cinsinden yeniden düzenleyerek,

$$\underline{K}^T = \left( \frac{R(1)}{\sigma_0^2}, \frac{a_{1,1} R(1) + R(2)}{\sigma_1^2}, \dots, \frac{a_{p,p} R(1) + a_{p,p-1} R(2) + \dots + R(p+1)}{\sigma_p^2} \right) \quad (2.56)$$

sonucuna varılır.

Eğer (2.13) denklemiyle (2.56) ile verilen eşitlikteki elemanların karşılaştırması yapılırsa,  $0 \leq i \leq p$  için  $K_i$  elemanlarının "Yansıma katsayıları" denilen  $g_{i+1}$  katsayılarına eşit olduğu görülür. O zaman, yansıma katsayıları da aşağıdaki gibi yazılabilir.


$$\begin{aligned} g_1 &= \frac{R(1)}{\sigma_0^2} = K_0 \\ g_2 &= K_1 \\ &\vdots \\ g_{p+1} &= K_p \end{aligned} \quad (2.57)$$

veya kısaca,

$$\underline{g}^T = \left( \frac{E\{y_{n+1} e_0^-(n)\}}{\sigma_0^2}, \frac{E\{y_{n+1} e_1^-(n)\}}{\sigma_1^2}, \dots, \frac{E\{y_{n+1} e_p^-(n)\}}{\sigma_p^2} \right) \quad (2.58)$$

olur.

Bu varılan sonuca göre Şekil 2-3 'ün yansıma katsayılarına göre yeniden düzenlenmesi ile Şekil 2-4 'deki gibi öngörü süzgecinin kafes yapı gerçekleşmesi tamamlanmış olur.




Şekil 2-4 Öngörü süzgecinin kafes yapı gerçekleştirilmesi.

## BÖLÜM 3


### YAPAY NÖRAL DEVRENİN KISA ANLATIMI

Yapay nöral devreler, insan beyninin sinir sistemine ilişkin yapısından esinlenerek gerçekleştirilen modeller olup, gerçek sinir sisteminde nöron denilen sinir hücrelerinden, yapay nöral devrelerde işleme elemanı olarak söz edilir. O zaman bir yapay nöral devre, tabakalar halinde düzenlenmiş olan ve çok sayıdaki bağlantıyı içeren, işleme elemanları topluluğu olarak gözönüne alınabilir. Bir işleme elemanı ise Şekil 3-1 'de gösterildiği gibi çok girişli, tek çıkışlı bir eleman olarak verilebilir.




Şekil 3-1 Nöral devre işleme elemanı.


Buradan görülebileceği gibi, işleme elemanının, her bir giriş yolu üzerinde ağırlık katsayıları denilen uyarlamalı bağlantı katsayıları bulunur. Bu şekildeki işleme elemanı basit bir toplamla, ağırlıklı girişleri birleştirerek doğrusal olmayan bir fonksiyondan geçirir. Doğrusal olmayan fonksiyon olarak, ya ikili çıkış durumuna ilişkin bir eşik fonksiyonu ya da sürekli bir fonksiyon olarak sigmoid fonksiyonu kullanılabilir. Bu fonksiyonlar aşağıda gösterildiği şekillerde olabilirler.



(a) : Rampa Fonksiyonu



(b) : Basamak Fonksiyonu




(c) : Sigmoid Fonksiyonu

Şekil 3-2 Çeşitli doğrusal olmayan fonksiyonlar.

Eşik fonksiyonları veya aktivasyon fonksiyonları da denilen bu doğrusal olmayan fonksiyonlar işleme elemanlarının çıkışını, belli bir aralığa betimler. Bu fonksiyonların içerisinde en çok kullanılanı ise sigmoid fonksiyonudur.

Bir işleme elemanının çıkışı, bağlantı ağırlıkları aracılığı ile diğer elemanların girişlerine yine bu uyarlamalı katsayılarla çarpılarak dağıtılır. Bu şekilde bir işleme elemanı, diğer elemanlardan gelen değiştirilmiş aktivasyon değerlerini birleştirici rol oynar. Bu anlamda, bir yapay nöral devre, giriş ve çıkışı arasında bir dizi şeklinde oluşturulan tabakalar içerisinde gruplandırılmış, bir çok işleme elemanını içerir. Böylece, yukarıda sözü geçen bağlantılar ise birbirini izleyen tabakalar arasında kurulmuş olur. Giriş ve çıkış tabakaları, sırasıyla bilgiyi alan ve dışarıya ileten tabakalar olup, bu ikisi arasında kalan diğer tabakalar ise saklı tabakalar olarak isimlendirilir. Bu şekildeki bir nöral devre, tümüyle paralel dağıtılmış bir yapıyı içerir.

Nöral devrenin giriş ve çıkış işaretleri (vektörleri) özdeş ise buna "auto-associative" nöral devre denilip, giriş ve çıkışın farklı olması durumunda "hetero-associative" devre denir. Bu şekilde tabakalar halinde düzenlenmiş ileriye doğru beslemeli bir nöral devre, aşağıdaki gibi Şekil 3-3 ile verilebilir.



Şekil 3-3 İleriye doğru beslemeli nöral devre.

Böylece Şekil 3-3 ile verilen bir nöral devrede,  $p$ . örüntü için çıkış tabakasındaki  $j$ . işleme elemanının çıkışı

$$y_{jp} = f\left(\sum_i w_{ij} x_{ip} + \theta_j\right) \quad (3.1)$$

olup,  $f(\cdot)$  aktivasyon fonksiyonunun sigmoid fonksiyonu olması durumunda

$$y_{jp} = \frac{1}{1 + \exp\left[-\left(\sum_i w_{ij} x_{ip} + \theta_j\right)\right]} \quad (3.2)$$

dir.


Burada  $w_{ij}$  çıkış tabakasının  $j$ . işleme elemanı ile saklı tabaka elemanları arasındaki bağlantı katsayıları olup,  $x_{ip}$  bir önceki tabakadan gelen giriş büyüklükleridir.  $\theta_j$  de,

$$x_{0,p} \hat{=} 1$$

ve

$$w_{0j} \hat{=} \theta_j \quad (3.3)$$

olmak üzere, çıkış tabakasındaki  $j$ . işleme elemanına ilişkin ek terimdir. Bu çerçevede, Şekil 3-1 'deki işleme elemanı, (3.2) eşitliğini gerçeklemek üzere Şekil 3-4 'deki gibi, daha açık olarak, yeniden oluşturulabilir.



Şekil 3-4 Çıkış tabakasındaki  $j$ . işleme elemanı.


Bir nöral devre modeli geliřtirmede önemli iki alıřma durumundan biri "Öğrenme" diğeri ise "geri ağırma" dır. Öğrenme, nöral devre giriřine uygulanan iřarete cevap olarak, ıkıř tabakasının ürettiğı deęer ile istenen ıkıř büyüklüğü arasındaki farkı en küçük yapacak řekilde, tabakalar arasındaki ağırlık katsayılarını uyarlamalı olarak deęiřtiren bir süreçtir. Burada sözü geen istenen ıkıř büyüklüğü, önceden belirlenmiř bir büyüklük olarak, devreye bir öğretici aracılığı ile öğretildiğı için bu tip nöral devrelerin öğrenmesine "Denetimli Öğrenme " denir. Eđer istenilen ıkıř verilmemiřse, bu tip öğrenmeye de "Denetimsiz Öğrenme" denir. Öğrenme süreci ise yine bir kurala göre gerekleřtirilip, "Öğrenme Kuralı " denilen bu kural, giriř örüntüsüne cevap olarak, baęlantı ağırlıklarının nasıl deęiřtirileceğini tanımlar. Öğrenme genel olarak, tüm örüntülerin bir ok kez tekrar edilmesini gerektirir. Bu řekilde nöral devrenin "Eđitim" süreci de tamamlanarak giriř-ıkıř iftleri arasındaki iliřkiyi öğrenmesi saęlanır. Nöral devrenin diğeri durumu "Geri ağırma" ise eđitimini tamamlamıř bir nöral devre için, giriře uygulanan giriř örüntüsünün cevabını ıkıř tabakasında elde etmek üzere, bilginin giriř-ıkıř arasındaki yayılıřdır. Eđer, řekil 3-3 de verilen ileriye doęru beslemeli bir nöral devrede olduğı gibi, tabakalar arasında veya aynı tabaka içersindeki iřleme elemanları arasında bir geri besleme yoksa, bu durumda geri ağırma süreci, giriř tabakasından ıkıř tabakasına doęru ilerliyen bir yol izleyecektir.

Nöral devrenin öğrenmesine iliřkin en uygun yöntemlerden biri, "Geriye Yayılım" algoritması olarak bilinir. Bu algoritma ise Ek-A da verilmiřtir.

## BÖLÜM 4

### YAPAY NÖRAL DEVRE İLE STOKASTİK İŞARET İŞLEME

Doğrusal stokastik işaret modellemesi ve kafes modeli ile ilgili bölümde gerçekleştirilen öngörü süzgecini, nöral devre ile gerçekleştirmek için üç tabakadan oluşan bir nöral devre aşağıdaki gibi verilebilir.




Şekil 4-1 Çok giriş, tek çıkıştan oluşan üç tabakalı nöral devre.

Burada  $X$  giriş vektörü olup, ağırlık giriş tabakasına uygulanan  $[L \times 1]$  boyutlu bir vektördür.  $L$  ise nöral ağırlık giriş tabakasındaki eleman sayısıdır. Girişle çıkış arasındaki tabaka ise saklı tabaka (hidden layer) olup, buradaki elemanların sayısı uygulamaya göre daha sonra belirlenecektir. Çıkış tabakası ise sadece bir elemandan oluşturulmuştur. Buna göre  $X$  giriş vektörü ile  $y$  çıkışı arasındaki ilişki, tabakalar arasındaki katsayılar aracılığı ile sağlanmaktadır.

Ancak devrenin belirli girişlere, belirli çıkışları üretebilmesi için giriş-çıkış çiftleri arasındaki ilişkiyi öğrenmesi gerekir. Bu amaçla farklı giriş-çıkış takımları için devrenin önceden eğitilmesi gerekir. Bu süreç, 3. bölümde de söz edildiği gibi nöral devrenin "eğitim süreci" denilir.





Şekil 4-3 Nöral devrede giriş-çıkış olasılık yoğunluk fonksiyonu.

Burada, giriş olasılık yoğunluk fonksiyonu

$$f_g(x) = \frac{1}{\sqrt{2\pi\sigma_x^2}} \exp\left[-\frac{1}{2} \frac{(x - \mu_x)^2}{\sigma_x^2}\right] \quad (4.1)$$

gaussien o.y.f. olup,  $\sigma_x^2$  o.y.f. nun varyansı,  $\mu_x$  ise ortalama değeridir.  $y = s(x)$  ise aşağıda verildiği gibi sigmoid fonksiyonu olup,

$$y = s(x) = \frac{1}{1 + e^{-x}} \quad -\infty < x < +\infty \quad (4.2)$$

şeklindedir.

Bu durumda  $f_\chi(y)$ , çıkış o.y.f. nun hesaplanması aşağıda verilen temel teorem çerçevesinde yapılır.

**Teorem-4.1 :** Verilen bir  $y$  değeri için  $f_y(y)$  olasılık yoğunluk fonksiyonunu bulmak amacıyla,  $y = g(x)$  denklemi  $y$  cinsinden  $x$  'e göre çözülür. Eğer,  $x_1, x_2, \dots, x_n$  gerçel kökler ve  $y = g(x_1) = g(x_2) = \dots = g(x_n)$  ise, o zaman

$$f_y(y) = \frac{f_x(x_1)}{|g'(x_1)|} + \dots + \frac{f_x(x_n)}{|g'(x_n)|}$$

olup, burada

$$g'(x) = \frac{dg(x)}{dx}$$

dir. Açık olarak görülürki  $x_1, x_2, \dots, x_n$  değerleri  $y$  ye bağlıdır. Eğer belirli bir  $y$  değeri için  $y = g(x)$  denkleminin gerçel kökleri yoksa, o zaman  $f_y(y) = 0$  dır [25].

Bu, teorem Şekil 4-3 ile verilen duruma uygulanırsa,  $g(x)$  fonksiyonu olarak  $s(x)$  sigmoid fonksiyonu,  $f_y(y)$  ve  $f_x(x)$  olarak da sırasıyla  $f_{\hat{y}}(y)$  ve  $f_g(x)$  o.y.f. ları gözönüne alınabilir. O zaman, (4.2) eşitliğinin bir kökü olarak üstel terimin çözülmesi ile,

$$x = \ln \left( \frac{y}{1-y} \right) \quad (4.3)$$

elde edilir. Aynı zamanda, (4.2) nin türevi ise ,

$$s'(x) = \frac{ds}{dx} = \frac{e^{-x}}{(1+e^{-x})^2} = y^2 e^{-x} \quad (4.4)$$

veya

$$s'(x) = y(1-y) = y - y^2 \quad (4.5)$$

olup, (4.4) denkleminde (4.3) eşitliğinin yerleştirilmesi ile

$$s'(x) = y^2 e^{-\ln \left[ \frac{y}{1-y} \right]} \quad (4.6)$$

elde edilir.

Verilen teorem uyarınca ve  $f_g(x)$  o.y.f. na ilişkin (4.1) bağıntısının kullanılmasıyla, çıkış olasılık yoğunluk fonksiyonu


$$f_{\hat{y}}(y) = \frac{1}{|s'(x)|} f_g(x) = \frac{\exp \left[ \ln \left( \frac{y}{1-y} \right) \right]}{y^2 \sqrt{2\pi\sigma_x^2}} \exp \left[ -\frac{1}{2} \left( \frac{\ln \left[ \frac{y}{1-y} \right] - \mu_x}{\sigma_x} \right)^2 \right] \quad (4.7)$$

veya, (4.5) denklemine göre

$$f_c(y) = \frac{1}{(y-y^2)\sqrt{2\pi\sigma_x^2}} \exp \left[ -\frac{1}{2} \left( \frac{\ln \left[ \frac{y}{1-y} \right] - \mu_x}{\sigma_x} \right)^2 \right] \quad (4.8)$$

şeklinde gaussien olmayan bir o.y.f. elde edilir.

Sigmoid fonksiyonu  $-\infty < x < +\infty$  aralığı için (0,1) arasında asimptotik olarak değişen, doğrusal olmayan bir fonksiyondur. Ancak, belirli bir çalışma bölgesi içinde oldukça doğrusal bir karakter gösterir. Bu nedenle, giriş o.y.f. nun bu aralık içinde kalacak şekilde sınırlandırılması ve sigmoid fonksiyonunun (0.1-0.9) aralığına getirilmesiyle Şekil 4-3 'e ilişkin  $f_c(y)$ ; çıkış o.y.f. hesaplanabilir. Aşağıdaki Şekil 4-4 'e göre,



Şekil 4-4 Sigmoid fonksiyonun doğrusal bölgesi ve giriş o.y.f.

$f_g(x)$ ; giriş o.y.f. nun,  $x_{\min} \leq x \leq x_{\max}$  aralığındaki,

$$\mu_x = \frac{x_{\min} + x_{\max}}{2} \quad (4.9)$$

ortalamasıyla ve  $\sigma_x^2$  varyansıyla gaussian verildiğini kabul ederek, sigmoidin doğrusal bölgesine ilişkin doğru denklemi

$$y = m x + n \quad (4.10)$$

şeklinde olup, doğrunun eğimi olan m,

$$m = \left( \frac{0.9 - 0.1}{x_{\max} - x_{\min}} \right) = \left( \frac{0.8}{x_{\max} - x_{\min}} \right) \quad (4.11)$$

şeklinde hesaplanır. Doğru denleminin (4.9) ve (4.11) eşitlikleri yardımıyla,  $x=\mu_x$  için  $y=0.5$  noktasından geçecek şekilde yazılmasıyla, aşağıdaki (4.12) eşitliği elde edilir.

$$0.5 = \left( \frac{0.8}{x_{\max} - x_{\min}} \right) \left( \frac{x_{\min} + x_{\max}}{2} \right) + n \quad (4.12)$$

Bu son deklemden n değeri çözülürse,

$$n = \frac{0.1 x_{\max} - 0.9 x_{\min}}{(x_{\max} - x_{\min})} \quad (4.13)$$

olarak bulunur. Bulunan m ve n parametreleri cinsinden (4.10) denklemi yeniden yazılırsa,

$$y = \left( \frac{0.8}{x_{\max} - x_{\min}} \right) x + \left( \frac{0.1 x_{\max} - 0.9 x_{\min}}{x_{\max} - x_{\min}} \right) \quad (4.14)$$

denklemini elde edilir. Bu denklem, giriş o.y.f. nun  $(x_{\min}, x_{\max})$  aralığında sınırlandırılması durumunda sigmoid çıkışını (0.1 - 0.9) aralığında verecek olan, sigmoid fonksiyonun doğrusal ifadesidir.

Buna göre, eğer  $x_{\min} = -1$  ,  $x_{\max} = 1$  alınarak, (4.1) ile verilen  $f_g(x)$ ; giriş o.y.f. sınırlandırılırsa, o zaman yukarıda verilen (4.14) denklemi

$$y = 0.4 x + 0.5 \quad (4.15)$$

olup, buna göre yukarıdaki denklemin  $x$  'e göre çözümünden elde edilen

$$x = \frac{y - 0.5}{0.4}$$

değeri için, teorem-4.1 in uygulanmasıyla, çıkış o.y.f.  $f_{\varphi}(y)$  aşağıdaki gibi hesaplanır.

$$f_{\varphi}(y) = \frac{1}{\sqrt{2\pi(0.4\sigma_x)^2}} \exp \left[ -\frac{1}{2} \frac{(y - (0.5 + \mu_x))^2}{(0.4\sigma_x)^2} \right] \quad (4.16)$$

Bu fonksiyona ilişkin varyans ve ortalamanın da aşağıdaki gibi tanımlanmasıyla,

$$\sigma_y^2 \triangleq (0.4)^2 \sigma_x^2 \quad (4.17)$$

$$\mu_y \triangleq (0.5 + \mu_x) \quad (4.18)$$


çıkış olasılık yoğunluk fonksiyonu (o.y.f)

$$f_{\varphi}(y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp \left[ -\frac{1}{2} \left( \frac{y - \mu_y}{\sigma_y} \right)^2 \right] \quad (4.19)$$

olur.

Buradan görüleceği gibi yukarıda hesaplanan çıkış olasılık fonksiyonu gaussien olup,  $\mu_y$  ortalamasının, (4.18) ifadesinden  $\mu_x$  'e bağlı olarak bir miktar kaydığı görülür.


Böylece, sigmoid fonksiyonunun doğrusal bölgesinden geçen  $\mu_x=0$  ortalamalı  $x_{\min} \leq x \leq x_{\max}$  arasında tanımlı, gaussien o.y.f. olan  $f_g(x)$ ; çıkışta  $\mu_y = 0.5$  ortalamalı,  $0.1 \leq x \leq 0.9$  arasında tanımlı, yine gaussien o.y.f. olan  $f_{\varphi}(y)$  yi oluşturur. Buna ilişkin şekil ise aşağıdaki gibi Şekil 4-5 ile verilebilir.



Şekil 4-5 Sigmoid fonksiyonunun doğrusal bölgesi için giriş-çıkış o.y.f. ları.

Buraya kadar olan incelemeler saklı tabakadaki bir nöronun bir girişi içindi. Oysa, bir nöral devre paralel dağıtılmış bir devre olduğu için saklı tabakadaki her bir nörona ilişkin girişlerin sayısı, giriş tabakasındaki elemanların sayısına eşit olacaktır.

Buna göre saklı tabakadaki  $j$ . nöron Şekil 4-6 ile verilip,



Şekil 4-6 Saklı tabakadaki  $j$ . saklı nöron.

burada  $\theta_j$  ek terimi gözönünde bulundurmadan bir inceleme yapılacak olursa gaussien bağımsız rastlantı değişkenleri olarak  $x_1, x_2, \dots, x_L$  nin ağırlıklı toplamaları da

gaussien olacağı için sigmoid çıkışındaki  $f_c(y_j)$  de, yine sigmoidin doğrusal bölgesi için, gaussien bir o.y.f. olacaktır.


Eğer  $\theta_j$  ile verilen ek terim etkisini incelemek üzere,  $\theta_j > 0$  ve  $\theta_j < 0$  durumları gözönüne alınırsa, sigmoidin doğrusal bölgesi bakımından,  $\theta_j > 0$  için "pozitif skewness" etkisiyle,  $f_c(y_j)$  çıkış o.y.f. nun değişim aralığında daralma ve sola çarpıklık,  $\theta_j < 0$  için ise tersine olarak "negatif skewness" etkisiyle, yine değişim aralığındaki daralmayla birlikte, sağa çarpıklık şeklinde bakışım bozukluğu oluşacaktır. Ayrıca önemli bir nokta olarak, sigmoid çıkışındaki işaret bakımından da ilintili bir durum söz konusu olacaktır. Bu şekilde, saklı tabaka nöronlarının çıkışlarından, çıkış tabakasındaki nörona varıldığında bu nöronun girişindeki rastlantı değişkenleri artık bağımsız olmayıp, birbirleriyle ilintili ancak yine gaussien olduğu için bunların toplamı da, aralarındaki bu ilinti katsayısına bağlı olarak değişen bir varyans ile gaussien bir o.y.f. olacaktır. O zaman, bu tek nöronun çıkışından da sabit terim etkisiyle bir miktar çarpılmış ve ortalaması kaymış, "yaklaşık gaussien" olan bir o.y.f. elde edilecektir. Nöral devreye öğretilecek hedef örüntüleri ise 0.1-0.9 arasında normalize edilerek ortalaması kaymış bir gaussien o.y.f. sahip işaret olarak devreye uygulanırsa, o zaman iki gaussien işaret birbirini karşılayacak ve böylece nöral devrede stokastik işaretlerle öğrenme sağlanmış olacaktır.

Buradaki temel özellik nöral devrenin, sigmoid fonksiyonunun doğrusal bölgesinde çalışmaya zorlanmış olmasıdır. Bu durum ise şöyle sağlanır; nöral devrede ağırlık katsayılarının sayısı azaldıkça doğrusal olmayan durum artmakta, tersine ise ağırlık katsayılarının sayısı arttıkça doğrusallık artmaktadır. O halde saklı tabakadaki elemanların sayısı arttırılırsa, ağırlık katsayılarının sayısı da artmış olur. Böylece, nöral devre de doğrusal çalışmaya zorlanmış olur.

## BÖLÜM 5

### GÜÇ SİSTEMİ GÖZETİMİNDE YAPAY NÖRAL DEVRE İLE STOKASTİK İŞARET İŞLEME VE ARIZA SAPTAMASI ÜZERİNE BENZETİM ÇALIŞMASI

Dördüncü bölümde anlatılan kafes model ve yapay nöral devreden oluşan sistem, yeniden gözönüne alındığında, Şekil 4-2 ile verilen öngörü süzgecinin doğrusal kısmı olan kafes yapıya ilişkin geriye doğru öngörü hatalarının; gaussian bağımsız rastlantı değişkenleri olarak, nöral devre girişine uygulanabileceği kabul edilmişti. Bu bölümdeki benzetim (simülasyon) çalışmasında ise, öngörü süzgecinin girişine, beşinci mertebeden özbağlısımlı (AR) modelden türetilen bir işaret verilerek, yukarıda sözü geçen sistemin iki önemli çıkışı olan doğrusal kısma ilişkin  $e_{p+1}(n+1)$  kalıntı hatası ile, doğrusal olmayan kısma (nöral devre) ilişkin  $\varepsilon_{p+1}(n+1)$  kalıntı hatası, sırasıyla AR-kalıntı hatası ve ND-kalıntı hatası olarak isimlendirilerek, bir benzetim yazılımı aracılığı ile, veri dosyaları halinde oluşturulmuşlardır.



Şekil 5-1 Benzetim çalışmasına ilişkin nöral devre ile öngörü süzgeci gerçekleştirilmesi.

Ayrıca, bu benzetim çalışmasının diğer olanakları olarak, yukarıda sözü geçen bu iki çıkış arasındaki çapraz ilişki fonksiyonu verileri ile kalıntı varyanslarına ilişkin veri dosyaları da oluşturulmuştur. Benzetim programının tüm çıkış veri dosyaları ise Tablo 5-1 'de gösterilmiştir.

Tablo 5-1 Benzetim programı çıkış veri dosyaları.


| BENZETİM PROGRAMI ÇIKIŞ VERİ DOSYALARI |           |
|----------------------------------------|-----------|
| ND-Kalıntı Varyansı :                  | ERR01.DAT |
| AR-Kalıntı Varyansı :                  | ERR02.DAT |
| Çapraz İlişki :                        | ERR03.DAT |
| AR-Kalıntı Hatası :                    | ERR04.DAT |
| ND-Kalıntı Hatası :                    | ERR05.DAT |

Bunlardan başka ayrıca kafes yapı ve nöral devre çıkışlarını da oluşturmak olasıdır. Çünkü Şekil 4-2 'ye göre kalıntı hataları, bu iki devreye ait çıkışın giriş işareti ile oluşturdukları farktan meydana gelmiştir. Bu bölüme ilişkin incelemelerde, kafes model ve nöral devreden oluşan öngörü süzgecinin girişine uygulanan işaret, önceden belirtildiği gibi beşinci merteye AR-süzgeçten veri blokları halinde üretilmekte olup, her bir blok 512 veri içermektedir. Buna göre blok sayısı  $k$  olmak üzere, üretilen toplam veri miktarı  $512 \times k$  olmaktadır. Nöral devre ise üç tabakadan oluşmakta olup; giriş tabakası, saklı tabaka ve çıkış tabakası olarak isimlendirilmiştir. Her bir tabakadaki eleman sayıları da sırasıyla  $L$ ,  $M$ ,  $N$  ile gösterilir. Burada  $L=5$ ,  $N=1$  olmak üzere saklı eleman sayısı olan  $M$ , nöral devrenin davranışını belirleyen önemli bir parametredir.  $M$  nin alacağı farklı değerler farklı nöral devre yapılarının oluşturulmasında kullanılır.


Uygulamada blok sayısı  $k$  nın bir kısmı kafes ve nöral devre yapılarının öğrenmesine ayrılırken geri kalan kısmı, çıkış dosyalarının oluşturulmasına ayrılır. Bu bölümdeki denemelerin çoğunda  $k=25$  alınarak, 8 blokluk kısmının kafes yapı öğrenmesine, 7 blokluk kısmının ise nöral devre öğrenmesine ayrılarak 10 blokluk çıkış veri dosyaları oluşturulmuştur. Veri bloklarının bu şekildeki dağılımı mutlak olmayıp, uygulamaya göre uygun bir dağılım kullanılabilir.

Stokastik işaret analizi bakımından bu bölümde yapılan incelemelerde ilk önce AR-kalıntı hatası veri dosyası ile ND-kalıntı hatası veri dosyasının olasılık yoğunluk fonksiyonlarına (o.y.f) ilişkin istatistiksel büyüklükler hesaplanarak bu verilere ilişkin o.y.f. ları çizilmiştir. Buradan elde edilen sonuçlardan, nöral devre ve AR-kalıntı hatalarının her ikisinin de gaussian o.y.f. larına sahip olduğunun kabul edilebileceği görülmüştür.


Nöral devrenin doğrusal devreye (kafes yapı), olan benzerliğini değiştirmek amacıyla, nöral devre saklı eleman sayısı  $M$  yi değiştirerek yaratılan farklı durumlar için ND-kalıntı hatasına ilişkin istatistiksel büyüklüklerden, varyans, kurtosis ve skewness in saklı düğüm sayısına göre olan, değişimleri ayrı ayrı birer grafikte Şekil 5-2. a, b ve c ' deki gibi gösterilmiştir.



Şekil 5-2.a Saklı eleman sayısı  $M$  ye göre, varyansın değişimi.



Şekil 5-2.b Saklı eleman sayısı, M ye göre skewness (çarpıklık) in değişimi.





Şekil 5-2.c Saklı eleman sayısı M ye göre kurtosis (basıklık) in değişimi.

Bu bilgilere göre varyansın yaklaşık bir (1.01, 1.21), Skewness (çarpıklık) in yaklaşık sıfır (-0.000038, -0.02), kurtosis (basıklık) in ise yaklaşık üç (2.84, 2.9) civarında değiştikleri görülmüştür. Böylece saklı eleman sayısını değiştirmenin o.y.f. nun gaussianliğine çok fazla etkimeyeceği gözlemlenmiştir. Ayrıca, nöral devre girişine uygulanan işaretin interpolasyon aralığının, (-1, +1) olan ilk değeri, (-3, +3) yapılarak yukarıdaki blok dağılımına göre, saklı eleman sayısını da  $M=1$  ve  $M=7$  alarak, farklı durumlardaki nöral devre kalıntı hatası o.y.f. ları da incelenmiştir. Buradan interpolasyon aralığını büyütmenin o.y.f. larını değiştirmedeği o.y.f. larının yine yaklaşık gaussian kaldıkları görülmüştür. Ancak daha büyük interpolasyon aralıklarında da olayı gözlemlemek bakımından, aralığın (-5, +5) değeri için saklı eleman sayılarını  $M=1$  ve  $M=14$  alarak yine aynı blok dağılımına göre denemenin tekrarlanması ile o.y.f. nun gaussianliğinin bozulmadığı, sadece  $M=1$  için varyansın bir miktar büyüdüğü görülmüştür. Bu durum aşağıdaki gibi Tablo 5-2 'de birbirleriyle karşılaştırmalı olarak gösterilmiştir.

Tablo 5-2 (-5, +5) İnt. aralığında, saklı eleman sayısı  $M=1$  ve  $M=14$  için ND-kalıntı hatasına ilişkin istatistiksel büyüklükler.


| İSTATİSTİKSEL<br>BÜYÜKLÜKLER | SAKLI ELEMAN<br>SAYISI $M=1$ | SAKLI ELEMAN<br>SAYISI $M=14$ |
|------------------------------|------------------------------|-------------------------------|
| Minumum değer                | - 5.559783                   | -3.212473                     |
| Maksimum değer               | 6.733295                     | 3.655742                      |
| Ortalama değer               | 0.099055                     | 0.027418                      |
| Varyans                      | 3.116835                     | 1.078266                      |
| Standart sapma               | 1.765456                     | 1.038396                      |
| Üçüncü moment                | - 0.069927                   | - 0.010068                    |
| Dördüncü moment              | 28.480604                    | 3.303049                      |
| Skewness (Çarpıklık)         | 0.012708                     | -0.008992                     |
| Kurtosis (Basıklık)          | 2.931713                     | 2.840949                      |

Bu büyüklüklere ilişkin olasılık yoğunluk fonksiyonları (o.y.f.) ise, Şekil 5-3.a ve Şekil 5-3.b 'deki gibidir.



Yukarıdaki şekillerden ve Tablo 5-2 'deki değerlerden dördüncü moment ile varyansın karesi arasındaki oran şeklinde tanımlanan kurtosis in  $c=3$  civarında değer alması ve skewness inde yine  $s=0$  civarında olması nedeniyle, o.y.f. larının gaussian oldukları gözlenmiştir.

Devrenin çeşitli durumlarda, çeşitli çıkışlarına ilişkin olasılık yoğunluk fonksiyonlarının incelenmesinden başka AR ve ND kalıntı hatalarına ilişkin çapraz ilişki fonksiyonları da hesaplanarak grafik olarak incelenmiştir (Şekil 5-4). Ayrıca, çapraz ilişki verisini kullanarak AR ve ND-kalıntı hataları arasındaki ilişkinin, her iki incelemede de  $\sim 1$ , (0.98), civarında olduğu görülmüştür. Bu sonuç ilişki katsayısı hesabı ile de doğrulanmıştır. Buradan nöral devrenin saklı eleman sayısının değiştirilmesi ile sonucun çok fazla değişmediği, iki verinin yine ilişkili kaldığı belirlenmiştir.




Şekil 5-4 AR ve ND -kalıntı hataları arasındaki çapraz ilişki verisi.

Bu sonuçlara göre görülmüştür ki, nöral devre doğrusal olmayan bir devre olmasına rağmen, yukarıdaki gibi yaratılan, farklı durumlarda bile doğrusal devreyle olan benzerliğinde önemli bir azalma görülmemiştir. Bilindiği gibi bir nöral devrede saklı


eleman sayısı arttıkça doğrusallık, saklı eleman sayısı azaldıkça doğrusal olmayan durum artar. Ancak bu benzetimde saklı eleman sayısının azaltılması ile de doğrusallıktan önemli bir sapma gözlenmemiştir. Çünkü, nöral devrenin ağırlık katsayılarının en uygun değerlerine (optimizasyonuna) ilişkin olarak, devre yine doğrusal bölgede çalışmaya zorlanmıştır. Böylece giriş işaretinin interpolasyon aralığı büyütülse veya saklı düğüm sayısı azaltılsa bile nöral devre doğrusal çalışmaya zorlanacak ve ağırlık katsayıları ona göre ayarlanacaktır. Devrenin bu şekilde normal çalışma durumları için çıkış dosyalarındaki verilerin o.y.f. ları ve aralarındaki ilişki fonksiyonlarının incelenmelerinden sonra, benzetimin normal olmayan bir durumu temsil etmesi bakımından "arıza" durumu da incelenmiştir. Arızayı yaratan bozucu etki ise birinci mertebe AR süzgeçten, "a" bozucu etki katsayısı ve "k" kazanç katsayısı ile yapay olarak üretilmiş olup, varyansı aşağıdaki formülle,  $\sigma_w$  beyaz gürültü varyansına bağlı olarak hesaplanabilir.

$$\sigma_b^2 = \frac{k^2 \sigma_w^2}{1 - a^2} \quad (5.1)$$

Bu amaçla, nöral devre öğrenmesinden hemen sonra uygulama bloğunun 20 - 300. verileri arasına bir bozucu etki koyarak, AR ve ND-kalıntı hatalarına ilişkin olarak, işaretteki bu bozucu etki ayrı ayrı gözlemlenmiştir. Önce AR-kalıntı hatası ve ND-kalıntı hatası veri dosyalarındaki bozucu etkiyi görmek için, toplam 25 blokluk verinin 8 blokluk kısmı kafes yapı öğrenmesine, 7 blokluk kısmı ise nöral devre öğrenmesine ayrılarak, 10 blokluk çıkış veri dosyaları hazırlanmıştır. Ancak, ilk bloktaki bozucu etkiyi görmek bakımından, çıkış bloklarının ilk ikisi gözönüne alınarak AR ve ND kalıntı hataları verilerinin zaman serilerinin çizilmesiyle, birinci bloktaki verilere ait büyük genliklerin, ikinci blok genliklerine göre olan farkı Şekil 5-5 ve Şekil 5-6 'den kolayca görülebilmektedir.




Şekil 5-5 Arıza durumunda AR-kalıntı hatası zaman serisinin, birinci bloktaki arıza gösterimi.




Şekil 5-6 Arıza durumunda ND-kalıntı hatası zaman serisinin, (-1, +1) int. aralığında birinci bloktaki arıza gösterimi ( M=1).

Yukarıdaki veri dağılımına göre, AR-kalıntı varyansının da çizilmesiyle aşağıdaki Şekil 5-7 'den de görüleceği gibi kafes yapıya ilişkin arıza varyansının  $\sigma^2 \approx 2.9$ , normal çalışma durumundaki varyansın ise  $\sigma^2 \approx 1$  olduğu saptanmıştır.




Şekil 5-7 AR-kalıntı varyansı.

Bundan sonra nöral devrenin, farklı durumlardaki davranışını da incelemek bakımından, nöral devre giriş interpolasyon aralığını (-1, +1) de sabit tutarak saklı eleman sayısının  $M=1$  ve  $M=9$  değerleri için bozucu etkinin gözlenmesiyle (Şekil 5-8.a, b), her iki durumda da bozucu etki genliklerinin yaklaşık aynı mertebede kaldığı görülmüştür.




Şekil 5-8.a  $M=1$  için arıza durumunda ND-kalıntı hatası zaman serisi.




Şekil 5-8.b  $M=9$  için arıza durumunda ND-kalıntı hatası zaman serisi.

Nöral devre giriş büyüklüklerine ilişkin interpolasyon aralığının (-3, +3) yapılmasıyla ise,  $M=1$  için kalıntı genliklerinde büyüme görülmesine rağmen  $M=9$  için bu durumun düzeldiği görülmüştür (Şekil 5-9.a ve Şekil 5-9.b). Böylece saklı düğüm sayısını arttırmakla ND yine doğrusal devreye (AR-kafes yapı) uyum sağlamıştır.




Şekil 5-9.a  $M=1$  için arıza durumunda ND-kalıntı hatası zaman serisi.




Şekil 5-9.b  $M=9$  için arıza durumunda ND-kalıntı hatası zaman serisi.


Bundan sonra kalıntı hatalarına ilişkin yapılan denemeler benzer şekilde kalıntı varyansları içinde yapılarak nöral devre kalıntı varyansına ilişkin bozucu etki durumunun, yine  $(-1, +1)$  interpolasyon aralığında  $M=1, 2, 3, 7, 9$  ve  $14$  gibi değerler için gözlenmesiyle bozucu etkinin olmadığı blokta varyansın ortalama olarak  $1$  civarında kaldığı, bozucu etkinin olduğu blokta ise  $M=1, 2$  ve  $3$  için biraz daha büyük olan varyans değerlerinin,  $M=7, 9$  ve  $14$  için küçülerek yaklaşık sabit bir büyüklüğe ( $1$  den büyük) eriştiği görülmüştür (Şekil 5-10.a,b,c,d,e,f).




Şekil 5-10.a  $M=1$  için arıza durumunda ND-kalıntı varyansı.




Şekil 5-10.b M=2 için arıza durumunda ND-kalıntı varyansı.




Şekil 5-10.c M=3 için arıza durumunda ND-kalıntı varyansı.



Şekil 5-10.d M=7 için arıza durumunda ND-kalıntı varyansı.




Şekil 5-10.e M=9 için arıza durumunda ND-kalıntı varyansı.




Şekil 5-10.f M=14 için arıza durumunda ND-kalıntı varyansı.


Ancak, M ye göre değişimi daha iyi gözlemlemek için nöral devre giriş interpolasyon aralığının (-5, +5) yapılmasıyla (Şekil 5-11.a, b, c, d, e, f), M=1 durumundaki büyük varyans değerleri, M=7 durumunda dengelenmiştir. Özellikle bozucu etkinin bulunmadığı bloktaki varyansın ortalama değer olarak ~1 civarına inmesi, ve arıza durumundaki varyans değerinin dengelenmesi Şekil 5-11.c ' den itibaren daha açık olarak görülebilir. Burada da saklı eleman sayısının artmasıyla nöral devrenin kendini doğrusal yapıya (kafes yapı) nasıl benzettiği, Şekil 5-7 'den karşılaştırmalı olarak gösterilebilir.




Şekil 5-11.a M=1 için arıza durumunda ND-kalıntı varyansı.




Şekil 5-11.b M=3 için arıza durumunda ND-kalıntı varyansı.



Şekil 5-11.c  $M=7$  için arıza durumunda ND-kalıntı varyansı.




Şekil 5-11.d  $M=9$  için arıza durumunda ND-kalıntı varyansı.




Şekil 5-11.e  $M=14$  için arıza durumunda ND-kalıntı varyansı.

Bozucu etki durumundaki kalıntı varyanslarının gözetimi toplam üç çıkış bloğu için de gerçekleştirilebilir. Nöral devre öğrenme bloklarının sonuncusundan hemen sonra arızanın bulunduğu duruma ilişkin AR ve ND-kalıntı çıkışları gözönüne alınırsa, oluşturulan bu üç blokluk verilerin varyans değişimleri Şekil 5-12.a ve Şekil 5-12.b den görüldüğü gibi, orta bloktaki büyük varyans değerleri ile kolaylıkla belirlenebilir. Burada nöral devre,  $(-1, +1)$  interpolasyon aralığında,  $M=7$  ile belirlenmiş durumdadır.



Şekil 5-12.a Arıza durumunda, üç blokluk AR-kalıntı varyansı.



Şekil 5-12.b Arıza durumunda, üç blokluk ND-kalıntı varyansı.


Sonuç olarak bu benzetim çalışmasında, sistemin normal ve normal dışı durumları için kalıntı hataları ve kalıntı varyanslarına ilişkin verilerin, hem kafes yapı hem de nöral devre çıkışları için oluşturulmasıyla, her iki devrenin de arızalı durumu algılamasında önemli bir fark görülmemiştir. Ancak, bu bölümde elde edilen sonucun bundan sonraki bölüme esas olması bakımından, kalıntı hatalarının gaussian o.y.f. larına sahip olduğu ve nöral devrenin de doğrusal devreyi (AR, kafes yapı) taklit etmesinden dolayı, nöral devre saklı düğüm sayısının hangi durumlarda önemli rol oynayacağı gözlenmiş olup, burada M nin 7-9 arasında bir değer almasının daha uygun olacağı saptanmıştır. Çünkü Şekil 5-10.d, e ve Şekil 5-11.c, d 'nin Şekil 5-7 ile olan varyans değerlerinin karşılaştırmasına göre, saklı eleman sayısının  $M=7-9$  alınması durumunda, nöral devre doğrusal devreye daha iyi uyum sağlamıştır. Aynı durum Şekil 5-12.a, b ve Şekil 5-7 'deki varyans değerlerinin karşılaştırmasından da görülebilir. Sonuç olarak ND, AR devreyi taklit etmekte olup, ayrıca bu iki devrenin ürettikleri çıkışlar da, Şekil 5-4 'den görüleceği gibi birbirleri ile ilişkilidir.

AR ve ND çıkışları arasındaki ilişkinin (korelasyonun) yok edilmesi amacıyla, AR-çıkışının altıncı giriş olarak nöral devreye verilmesi ile yapılan incelemelerde ise arıza belirlemesinin daha duyarlı hale geldiği görülmüştür. Bu konuya ilişkin daha kapsamlı açıklamalar, hem gerçek güç sisteminden alınan verilere uygulanması bakımından, hem de bu konuya getirilen katkının önemini vurgulamak bakımından, bundan sonraki bölüm olan 6. bölümde verilecektir.


## BÖLÜM 6

### GERÇEK GÜÇ SİSTEMİNDE İŞARET MODELLEMESİ VE ARIZA SAPTAMASI

Beşinci bölümde yapılan benzetim çalışmasında kullanılan yapay veri yerine bu bölümde, Hollanda 'da BORSSELE-PWR Nükleer Güç Santralının gözetimine ilişkin, 31.1.1994 den 2.2.1994 gününe kadar kaydedilen B20277A1.UNF verisinin 29.kanalına ait elektrik gücü verisi B20277.C29 kullanılmıştır. Bu verinin uygun bir okuma programı ile okunup, her biri 512 veriden oluşan 25 blokluk BB2.DAT veri dosyasının hazırlanması ile gerçek güç sistemine ilişkin veri olarak, Şekil 4-10 ile verilen öngörü süzgecinin girişine uygulanmıştır. Bu durum Şekil 6-1'de gösterilmektedir. Nükleer güç santralından veri toplama ve izleme sisteminin şematik gösterilimi ise Şekil 6-2 'de verilmektedir.




Şekil 6-1 Nöral devre ile öngörü süzgeci gerçekleştirilmesine ilişkin, gerçek sistem verisinin uygulanması.



Şekil 6-2 Nükleer Güç Santrali (NGS) izleme sisteminin şematik gösterilimi.

B20277.C29 verisinin orjinal şekli ise aşağıdaki gibidir.




Şekil 6-3 Borssele-PWR Nükleer Güç Santralının elektrik gücü verisi.

Benzetim çalışmasındaki gözlemlere göre nöral devre saklı düğüm sayısının büyük seçilmesinin nöral devreyi doğrusal çalışmaya zorladığı anlaşıldığından, bu bölümdeki çalışmalarda nöral devre saklı eleman sayısının  $M=9$  alınması sonucunda, ND-kalıntı hatası, AR-kalıntı hatası, çapraz ilişki verisi ve kalıntı varyansları incelenerek bu veri dosyaları için istatistiksel büyüklükler hesaplanmıştır. Bunun sonucunda, gerçek güç sistemi verisinden oluşan toplam 25 blokluk verinin 8 bloğu kafes yapı uyarlamasına, 7 blokluk kısmı da ND-öğrenmesine ayırdıktan sonra 10 blokluk uygulama verileri bakımından ND-kalıntı hatası istatistiksel büyüklükleri, Tablo 6-1 ile verilmiştir.

Tablo 6-1 ND-kalıntı hatası istatistiksel büyüklükleri.

|                      |           |
|----------------------|-----------|
| Minimum değer        | -0.412693 |
| Maksimum değer       | 0.571979  |
| Ortalama değer       | 0.000408  |
| Varyans              | 0.012441  |
| Standart sapma       | 0.111538  |
| Üçüncü moment        | 0.000128  |
| Dördüncü moment      | 0.000499  |
| Skewness (Çarpıklık) | 0.092421  |
| Kurtosis (Basıklık)  | 3.225699  |

ND-kalıntı hatası o.y.f. nun ise Şekil 6-4 'deki gibi yaklaşık gaussian olduğu görülmüştür.




Şekil 6-4 ND-kalıntı hatası o.y.f.

Aynı şekilde AR-kalıntı hatası istatistiksel büyüklükleri de Tablo 6-2 ile verilip, olasılık yoğunluk fonksiyonu da Şekil 6-5 'deki gibidir.


Tablo 6-2 AR-kalıntı hatasına ilişkin istatistiksel büyüklükler.

|                      |           |
|----------------------|-----------|
| Minimum değer        | -0.516743 |
| Maksimum değer       | 0.826372  |
| Ortalama değer       | 0.029012  |
| Varyans              | 0.020921  |
| Standart sapma       | 0.144642  |
| Üçüncü moment        | 0.000324  |
| Dördüncü moment      | 0.001418  |
| Skewness (Çarpıklık) | 0.107163  |
| Kurtosis (Basıklık)  | 3.239790  |



Şekil 6-5 AR-kalıntı hatası o.y.f.


Ayrıca AR ve ND-kalıntı hataları arasındaki çapraz ilişki verisinin de zaman serisi çizilerek, Şekil 6-6 'dan, varyansının ortalama olarak  $\sigma^2 = 0.02$  olduğu görülmüştür.




Şekil 6-6 Çapraz ilişki verisine ilişkin zaman serisi.

Buradan görüldüğü gibi gerçek güç sisteminden alınan verinin uygulandığı ve arızanın olmadığı bu durumda, AR ve ND kalıntı hataları gaussien olasılık yoğunluk fonksiyonlarına sahip olup, aralarında bir ilinti vardır.


Bundan sonra nöral devrenin öğrenmesinden hemen sonraki uygulama bloklarının birincisinin 20. ve 300. verileri arasına AR-katsayısı  $a = 0.01$  ve kazancı  $k = 0.17$  olacak şekilde bir bozucu etki koyarak, AR ve ND kalıntı hatalarının 2 blokluk zaman serileri ve kalıntı varyansları, Şekil 6-7.a, b ve Şekil 6-8.a, b 'deki gibi gösterilmiştir.




Şekil 6-7.a Arıza durumunda ( $a=0.01$  ve  $k=0.17$ ), ND-kalıntı hatası zaman serisinin iki blokluk gösterimi.



Şekil 6-7.b Arıza durumunda ( $a=0.01$  ve  $k=0.17$ ), ND-kalıntı varyansı.



Şekil 6-8.a Arıza durumunda ( $a=0.01$  ve  $k=0.17$ ), AR-kalıntı hatası zaman serisinin iki blokluk gözetimi.



Şekil 6-8.b Arıza durumunda ( $a=0.01$  ve  $k=0.17$ ), AR-kalıntı varyansı.

Böylece birinci bloktaki bozucu etkinin neden olduğu büyük genlikler ile ikinci bloktaki normal çalışma durumuna ilişkin genlikler kolayca ayırd edilmiştir. Varyans durumları incelendiğinde ise ND-kalıntı varyansı, normal çalışma durumunda  $\sigma^2 \approx 0.01$  iken, şekilden de görüleceği gibi arıza durumundaki varyans;  $\sigma^2 \approx 0.04$  olmuştur. Kafes yapı çıkışı için ise AR-kalıntı varyansı normal çalışma durumunda  $\sigma^2 \approx 0.02$  iken, arıza durumunda  $\sigma^2 \approx 0.2$  olmuştur.


Ancak beşinci bölümdeki benzetim çalışmasından da gözlendiği gibi burada da arıza belirlemesi için AR ve ND çıkışlarına ilişkin kalıntı hata ve varyansları bakımından çok büyük bir kazanç elde edilememiştir. Çünkü Şekil 6-1 'den de görüleceği gibi gerçek güç sisteminden alınan elektrik gücü verisinin, kafes yapı ile beşinci mertebeden modellenerek,  $e_i^-(n)$  geriye doğru kalıntı hatalarının beyaz gürültü sürecine ilişkin bağımsız rastlantı değişkenleri olarak nöral devre girişine verilmesi ile, beş giriş elemanından oluşan nöral devre ile kafes yapı, benzer davranışı göstermektedir. Böylece ND-kalıntı hatası, AR-kalıntı hatasını taklit etmektedir. Ayrıca nöral devre, eğitim süreci esnasında  $\varepsilon_{p+1}(n+1)$  kalıntı hatasını en küçük



Bu durumda 25 blokluk varyansı değiştirilmiş uygulama verisinin, yine 8 blokluk kısmı kafes yapı öğrenmesine, 7 blokluk kısmı ise nöral devre öğrenmesine ayrılarak oluşturulan 10 blokluk çıkış verileri bakımından, AR-kalıntı hatası o.y.f. için istatistiksel büyüklükler Tablo 6-3 'deki gibi saptanmıştır.

Tablo 6-3 Varyansı değiştirilmiş gerçek verinin Şekil 6-9 'a uygulandıktan sonra AR-kalıntı hatası o.y.f. 'nun istatistiksel büyüklükleri.

|                      |           |
|----------------------|-----------|
| Minimum değer        | -3.143119 |
| Maksimum değer       | 5.064942  |
| Ortalama değer       | 0.183841  |
| Varyans              | 0.748187  |
| Standart sapma       | 0.864978  |
| Üçüncü moment        | 0.057932  |
| Dördüncü moment      | 1.821831  |
| Skewness (Çarpıklık) | 0.089516  |
| Kurtosis (Basıklık)  | 3.254531  |




Şekil 6-10 Tablo 6-3 'deki büyüklüklere ilişkin AR-kalıntı hatası o.y.f.

Benzer durumda ND-kalıntı hatasına ilişkin istatistiksel büyüklükler de Tablo 6-4 ile verilerek, olasılık fonksiyonu (o.y.f.) da Şekil 6-11 'de gösterilmiştir.


Tablo 6-4 Varyansı değiştirilmiş gerçek verinin Şekil 6-9 'a uygulandıktan sonra ND-kalıntı hatası o.y.f. 'nun istatistiksel büyüklükleri.

|                      |           |
|----------------------|-----------|
| Minimum değer        | -1.623402 |
| Maksimum değer       | 2.975582  |
| Ortalama değer       | 0.001681  |
| Varyans              | 0.030442  |
| Standart sapma       | 0.174477  |
| Üçüncü moment        | 0.008458  |
| Dördüncü moment      | 0.032467  |
| Skewness (Çarpıklık) | 1.592398  |
| Kurtosis (Basıklık)  | 35.033279 |




Şekil 6-11 Tablo 6-4 'deki büyüklüklere ilişkin ND-kalıntı hatası o.y.f.

Ancak, Tablo 6-4 'deki verilerden ve Şekil 6-11 'den görüldüğü gibi ND-kalıntı hatası olasılık yoğunluk fonksiyonunun, gaussienlikden uzaklaşmasını açıklamak için, ND-kalıntı hatası ve AR-kalıntı hatası zaman serileri incelendiğinde, her iki veri dosyasında da büyük genlik değerlerine sahip fazlalıkların olduğu görülmüştür. Buna ilişkin şekiller ise aşağıda belirtildiği gibi, Şekil 6-12 ve Şekil 6-13 'deki gibidir.



Şekil 6-12 ND-kalıntı hatası zaman serisi.




Şekil 6-13 AR-kalıntı hatası zaman serisi.

Yukarıdaki şekillerden de görüleceği gibi ND çıkışının istatistiksel karakterini bozup onu gaussienlikten uzaklaştıran neden, fazlalık şeklindeki bu genliklerdir. Bu nedenle, ND-kalıntı hatasının olasılık yoğunluk fonksiyonu verilerine ilişkin (min., maks.) aralığı,  $(-0.4, 0.4)$  seçilerek, Tablo 6-5 'deki istatistiksel büyüklükler elde edilmiştir.

Tablo 6-5 Değiştirilmiş ND-kalıntı hatası o.y.f. büyüklükleri.


|                      |          |
|----------------------|----------|
| Minimum değer        | -0.4     |
| Maksimum değer       | 0.4      |
| Ortalama değer       | 0.661427 |
| Varyans              | 0.426696 |
| Standart sapma       | 0.653219 |
| Üçüncü moment        | 0.036646 |
| Dördüncü moment      | 0.614509 |
| Skewness (Çarpıklık) | 0.131476 |
| Kurtosis (Basıklık)  | 3.375143 |

Böylece, ND-kalıntı hatasının olasılık yoğunluk fonksiyonunun gaussienliği düzeltilerek, sonuçlar bu fazlalık şeklindeki genliklerden arındırılmıştır. Bu duruma ilişkin o.y.f. ise aşağıdaki gibi Şekil 6-14 ile verilmiştir.




Şekil 6-14 Düzeltilmiş ND-kalıntı hatası o.y.f.

Bu şekilde yapılan bir çok inceleme sonucunda, başlangıçta arızayı saptama açısından birbirleriyle aynı mertebede, eşdeğer sonuçlar veren AR ve ND çıkışlarının, aralarındaki ilişkinin yok edilmesinden sonra, normal çalışma durumunda  $\sigma^2 \approx 1$  civarında olan AR-kalıntı varyansının, Şekil 6-15 'den de görüleceği gibi,  $a=0.9$  ve  $k=0.2$  değerleri ile oluşturulan arıza durumunda  $\sigma^2 \approx 4.5$  civarında olduğu saptanmıştır.




Şekil 6-15 ( $a=0.9$ ,  $k=0.2$ ) arıza durumu için AR-kalıntı varyansı.

Benzer şekilde yine aynı arıza durumu için giriş ve çıkışı birbirinden bağımsız, kalıntı hataları dağılımı bakımından gaussian o.y.f. na sahip olan ND-kalıntı varyansının ise normal çalışma durumunda  $\sigma^2 \approx 0.05$  civarında olduğu görülürken, arıza durumundaki varyansının Şekil 6-16 'dan  $\sigma^2 \approx 0.49$  civarında olduğu belirlenmiştir.



Şekil 6-16 ( $a=0.9$ ,  $k=0.2$ ) arıza durumu için ND-kalıntı varyansı.

Önceki çalışmalarda olduğu gibi 2 blokluk veriler üzerinde yapılan gözlemler sonucunda arıza, kalıntı varyansları bakımından AR ve ND çıkışlarının her ikisi için de kolaylıkla saptanabilmektedir. Ayrıca çapraz ilişki verisi için yapılan incelemelerde de, birinci blokta  $a=0.9$  katsayısı ve  $k=0.2$  kazanç değeri ile oluşturulan arıza etkisi, bu bloktaki büyük varyans değeri ile hemen belirlenebilmektedir. İkinci blokla temsil edilen normal çalışma durumunda ise sıfır ortalamalı varyans değeri gözlenmiştir. Bu durum açık olarak Şekil 6-17'den görülmektedir.



Şekil 6-17 Arıza durumunda, çapraz ilişki varyansı.

Böylece AR-kalıntı varyansı değişimindeki arıza durumu, normal çalışma durumunun 4-5 katı kadar daha bir büyük değeri gösterirken, ND için bu oran yaklaşık 10 olmaktadır. Bu sonuç, AR ve ND çıkışlarının ilişkili olduğu durumdan çok farklı olmayan bir durumu göstermektedir. Ancak, AR ve ND çıkışlarının ilişkisizliğinin getireceği avantajı göstermek bakımından; yine aynı bozucu etki durumunda ( $a=0.9$ ,  $k=0.2$ ), Şekil 6-17 ile gösterilen çapraz ilişki verisi için arıza durumu incelenirse, burada normal çalışma durumundaki varyansın  $\sigma^2 \approx 0$ , arıza varyansının ise  $\sigma^2 = 1.2$  olduğu görülür. Böylece, arızalı durum ve normal çalışma durumunu gösteren varyanslar arasındaki oran da çok büyük bir değere ulaşmış olur.

Bu şekilde, ayrıntılarının yukarıda belirtildiği ve nöral devrenin önemli bir özelliğinin kullanılması ile oluşturulan bu yöntem ile arızalı durumun saptanması, işaret-gürültü oranının büyütülmesi ile çok daha duyarlı bir hale getirilip, bu konuda yapılan çalışmalara yeni bir katkı sağlamaktadır.

## SONUÇLAR

Sistem dinamiğindeki değişimlerin saptanması için özbağlaşımlı süreç yaklaşımı ile kafes yapı parametreleri uyarlamalı olarak belirlenmiştir.

Kafes yapıdaki geriye doğru kalıntılar ise nöral devre yardımıyla işlenmiştir. Bilindiği gibi kafes yapının doğrusal bir yapı olmasına karşın nöral devre doğrusal olmayan bir yapıya sahiptir. Ancak, nöral devrenin doğrusal çalışmaya zorlanmasıyla ve her iki devrenin de aynı kaynaktan beslenmesi nedeniyle bu iki yapının (AR ve ND) ürettikleri çıkışlar bakımından, aralarında bir ilişki (korelasyon) söz konusudur. Bu durumda yapılan arıza belirleme incelemelerinde, arıza çeşitli istatistiksel özellikleri ile saptanmasına rağmen, AR ve ND çıkışlarının her ikisi de aynı mertebede eşdeğer sonuçlar vermiştir. Ancak, nöral devre girişine ilave bir giriş olarak AR-çıkışının verilmesi sonucunda nöral devre, artık aynı kaynaktan beslenen bir devre olmayıp kafes yapıdan bağımsız bir devre gibi çalıştığından,  $e_{p+1}(n+1)$ ; AR-çıkışı ile  $\varepsilon_{p+1}(n+1)$ ; ND-çıkışı birbirlerinden bağımsız hale gelmişlerdir. Bu durumda arıza belirlemesine ilişkin incelemelerin yeniden ele alındığında ise, kalıntı varyansları bakımından arızayı saptamadaki duyarlılığın oldukça arttığı saptanmıştır.

AR ve ND çıkışları arasındaki ilişkinin yok edildiği, bozucu etki katsayısını  $a=0.9$  ve kazancını  $k=0.2$  olarak oluşturulan normal çalışma dışı durumda ise AR çıkışı için arızalı durumdaki varyansın, normal çalışma durumundaki varyansa göre 4-5 kat daha büyük değeri gözlenirken, ND çıkışı için yine aynı arıza durumundaki varyansının, normal çalışma durumundaki varyansa göre yaklaşık 10 kat daha büyük değere ulaştığı görülmüştür. Fakat, konuya daha ilginç sonuç getirmesi bakımından ve arıza durumunu saptamada esas olmak üzere, eğer AR ve ND çıkışları arasındaki çapraz ilişki verisi gözönüne alınırsa, normal çalışma durumunda aralarında yaklaşık olarak ilişki bulunmayan AR ve ND verilerinin, arıza durumunda birbirleriyle ilintili (korelasyonlu) hale gelerek, arızanın bulunduğu bloktaki varyans değerinin normal çalışma durumundaki varyans değerine göre büyük bir oranda arttığı belirlenmiştir. Çünkü ilişki verisi incelendiğinde, normal çalışma durumundaki varyans değeri  $\sigma^2 \approx 0$  iken, arıza katsayısının  $a=0.9$  ve kazanç değerinin  $k=0.2$  alınmasıyla oluşturulan bozucu etkinin temsil edildiği blokta bu değer, maksimum değer olarak  $\sigma^2=1.2$  ye kadar ulaşmaktadır. Bu durumda arıza ve normal çalışma durumu arasındaki oran

$\sigma^2=0$  için kuramsal olarak sonsuz olmaktadır. Böylece arızayı saptama bakımından nöral devrenin ne kadar etkili olduğu kolayca görülerek, arıza belirlemenin duyarlılığı açısından da önemli bir sonuç elde edilmektedir.

Ayrıca, gerçek güç sistemi olan nükleer santralının güç seviyesi arttıkça, varyansı değişeceğinden AR-kalıntı varyansını, güç seviyesinin her değişiminde yeniden hesaplamak gerekecektir. Fakat normal çalışma durumunda, kullanılan nöral devre kalıntı varyansının  $\sigma^2 \approx 0$  olmasından dolayı, reaktörün güç seviyesi nöral devre kalıntı varyansından bağımsız hale gelecektir. Bu da ilgi çekici diğer bir sonuçtur. Çünkü, her güç seviyesinde bu yeni arıza belirleme yöntemi kolay ve etkin olarak kullanılabilecektir.



## KAYNAKLAR

- [1] WILLSKY, A. S., A Survey of Design Methods for Failure Detection in Dynamics Systems , Automatica, Vol. 12, pp. 601-611, 1976.
- [2] WILLSKY, A. S., JONES, H. L., A Generalized Likelihood Ratio Approach to the Detection and Estimation of Jumps in Linear Systems, IEEE Transactions of Automatic Control AC-21, pp. 108-112, 1976.
- [3] ALBERST BENVENISTE, M. BASSEVILLE , G. V. MOUSTAKIDES, The Asymptotic Local Approach to Change Detection and Model Validation, IEEE Transactions on Automatic Control, Vol. AC-32, No. 7, July 1987.
- [4] BASSEVILLE, M., Edge Detection Using Sequential Methods for Change in Level, Part II : Sequential Detection of Change in Mean, IEEE Transaction on Acoustics, Speech and Signal Processing, Vol. ASP. 29 No. 1, Feb.1981.
- [5] TYLEE, J. L., On-Line Failure Detection in Nuclear Power Plant Instrumentation, IEEE Transactions on Automatic Control, Vol. AC-28, No.3, March, 1983.
- [6] TUGNAIT, J. K., Detection and Estimation for Abruptly Changing Systems Automatica, Vol. 18, No.5, pp 607-615, 1982.
- [7] ÇİFTÇİOĞLU, Ö., TÜRKCAN, E., Real-Time Sensor Failure Detection by Dynamic Modelling of a PWR Plant, 8<sup>th</sup> Power Plant Dynamics, Control & Testing Symposium, Knoxville, Tennessee, USA, May 27-29, 1992.
- [8] FRIEDLANDER, B., Lattice Filters for Adaptive Processing, Proceed. IEEE, Vol. 70, No. 8, pp. 829-867, 1982.
- [9] FRIEDLANDER, B., Lattice Methods for Spectral Estimation, Proceed. IEEE, Vol. 70, No. 9, pp.990-1017, 1982.
- [10] DANIEL, T. L., Recursive Least Squares Ladder Estimation, IEEE Trans., Vol. ASSP-29, No. 3, pp. 627-641, 1981.
- [11] HONING, M. L. , MESSERSCHMITT, D.G., Adaptive Filters, Kluwer Academic Publishers AH Dordrecht, The Netherlands, 1984.

- [12] TURNER, J. M., Adaptive Filters, Ed. by Cowan, C. F. N., Grant, P. M., Prentice-Hall, Englewood Cliffs, Chapter 5., pp. 91-144, New Jersey, 1985.
- [13] LJUNG, L., SÖDERSTRÖM, T., Theory and Practice of Recursive Identification, MIT, Cambridge, Massachusetts, 1985.
- [14] FALCONER, D. D., LJUNG, L., Application of Fast Kalman Estimation to Adaptive Equalization, IEEE Trans. Comm., Vol. COM-26, No. 10, 1978.
- [15] MAKHOUL, J. I., COSELL, L. K., Adaptive Lattice Analysis of Speech, IEEE Trans. ASSP, Vol. ASSP-29, No. 3, pp. 654-659, 1981.
- [16] MORF, M., Ladder Forms for Identification and Speech Processing, Proc. IEEE Conf. on Decision and Control, New Orleans, pp. 1074-1078, 1977.
- [17] OGUMA, R., Reactor Noise Surveillance Algorithms Using Lattice Filters, Ann. Nucl. Energy, Vol. 16, No. 11, pp. 577-588, 1989.
- [18] RICHARD P. LIPPMANN, An Introduction to Computing with Neural Nets, Artificial Neural Networks : Theoretical Concepts, Ed. by V. Vemuri, Computer Society Press Technology Series, IEEE, pp.36-54, New York, 1988.
- [19] TRELEAVEN, P., VELLASCO, M., Neural Computing Overview, Computer Physics Communications, Vol. 57, pp.543-559, 1989.
- [20] HUMPERT, B., A Comparative Study of Neural Network Architectures, Computer Physics Communications, Vol. 58, pp. 223-256, 1990.
- [21] ÇİFTÇİOĞLU, Ö., TÜRKCAN, E., Neural Network Training by Parameter Optimization Approach, International Conference on Artificial Neural Networks ICANN '93, Amsterdam, September 13-16, 1993.
- [22] ÇİFTÇİOĞLU, Ö., TÜRKCAN, E., Selection of Hidden Layer Nodes in Neural Networks by Statistical Tests, EUSIPCO '92, Sixth european Signal Processing Conference, Brussels, Belgium, pp.1181-1184, August 24-27, 1992.
- [23] ÇİFTÇİOĞLU, Ö., TÜRKCAN, E., Real -Time Sensor Failure Detection by Dynamic Modelling of a PWR Plant, 8<sup>th</sup> Power Plant Dynamics, Control & Testing Symposium, Knoxville, Tennessee, USA, May 27-29, 1992.

- [24] ÇİFTÇİOĞLU, Ö., TÜRKCAN, E., Enhancement of Verification & Validation for Nuclear Power Reactor Through Artificial Intelligence, IAEA International Working Group on Nuclear Power Plant Control and Instrumentation (IWG-NPPCI), Specialist Meeting on Operator Support Systems in Nuclear Power Plants, Moscow, Russian Federation, May 17-21, 1993.
- [25] PAPOULIS, A., Probability, Random Variables and Stochastic Processes International Student Edition, McGraw-Hill Book Company, pp. 126-127, 1965.



## EK-A

### GERİYE YAYINIM ALGORİTMASI

Bir yapay nöral devrenin ağırlık katsayılarının uyarlamalı olarak ayarlanması, en basit şekilde, en küçük karesel ortalama (LMS) anlamındaki bir öğrenme kuralı ile gerçekleştirilebilir. Bu yaklaşım "gradyent azalması" olarak da isimlendirilip, ağırlık katsayıları tarafından oluşturulan performans yüzeyinin minimumunu araştırmak için, her adımda karesel hata ( $e^2$ ) nin beklenen değerinin minimumuna doğru ilerlenir. Ayrık zamanda minimuma yaklaşma

$$\underline{W}_{k+1} = \underline{W}_k + \eta \underline{\nabla}_k E[e^2] \quad (\text{A.1})$$

olup,

$$\underline{\nabla}_k E[e^2] = \left[ \frac{\partial E[e^2]}{\partial w_{i1}}, \dots, \frac{\partial E[e^2]}{\partial w_{in}} \right]_k^T \quad (\text{A.2})$$

dır. Burada  $\underline{w}_k$ , k. adımdaki ağırlık katsayıları vektörü,  $\eta$  ise yakınsama çarpanıdır. LMS algoritmasında,

$$\underline{\nabla}_k E[e^2] = \frac{\partial E[e^2]}{\partial \underline{w}_k} \quad (\text{A.3})$$

yerine, çıkış düğümlerindeki hatanın gradyenti

$$\underline{\nabla}_k e^2 = \frac{\partial (e_j^2)}{\partial \underline{w}_k} = 2e_j \left( \frac{\partial e_j}{\partial \underline{w}_k} \right) \quad (\text{A.4})$$

kullanılır.

Nöral devrelerde LMS yönteminin özel bir uygulaması " Geriye yayılım" algoritması olup, bu algoritma aşağıdaki gibi verilir.

Burada, gerçek ve istenen çıkış arasındaki farkın karesiyle orantılı olacak şekilde bir hata fonksiyonu gözönüne alarak,

$$e^2 = \sum_j (d_j - F_j)^2 \quad (\text{A.5})$$

yazılabilir ve j. birimin ağırlıklı toplamını bir önceki tabaka çıkışları,  $F_i$  yi, j. nörona giriş olacak şekilde alıp

$$s_j = \sum_i F_i w_{ij} \quad (\text{A.6})$$

oluşturulabilir. Her bir j. nöronun çıkışı girişine  $s_j$  nin uygulandığı bir eşik fonksiyonu ile hesaplandığından ve eşik fonksiyonu olarak da türetilen bir fonksiyon olmasından dolayı sigmoid fonksiyonunu,  $f(\cdot)$ , kullanarak

$$F_j = f(s_j) \quad (\text{A.7})$$


gerçek çıkış değeri elde edilir. LMS algoritmasından zincir kuralına göre,

$$\frac{\partial(e^2)}{\partial w_{ij}} = \frac{\partial(e^2)}{\partial s_j} \frac{ds_j}{dw_{ij}} \quad (\text{A.8})$$

yazarak ve aşağıda verilen şekil A.1 den de görülebileceği gibi,

$$\frac{ds_j}{dw_{ij}} = \frac{d}{dw_{ij}} \sum_i F_i w_{ij} = F_i \quad (\text{A.9})$$

olur. Burada i' yardımcı indistir.



Şekil A-1. Geriye yayılım algoritmasında ileriye doğru hesaplamanın şematik gösterimi.

$s_j$  girişlerinin fonksiyonu olarak karesel hatadaki değişim aşağıdaki şekilde ifade edilebilir.

$$\frac{\partial e^2}{\partial s_j} = -\delta_j \quad (\text{A.10})$$

Burada kısmi türevin negatif olması istendiğinden  $\delta_j > 0$  olur. Bu durumda (A.9) ve (A.10) eşitliklerini (A.8) denkleminde yerine yazarak,

$$\frac{\partial(e^2)}{\partial w_{ij}} = -F_i \delta_j \quad (\text{A.11})$$

bulunur. Böylece ağırlık katsayılarındaki değişim aşağıdaki gibi verilebilir.

$$\Delta w_{ij} = \eta F_i \delta_j \quad (\text{A.12})$$

Diğer taraftan (A.10) denkleminde zincir kuralına göre ,

$$\delta_j = -\frac{\partial(e^2)}{\partial F_j} \frac{\partial F_j}{\partial s_j} \quad (\text{A.13})$$

yazılıp, (A.5) ve (A.7) eşitliklerini gözönüne alarak türevlerin hesaplanmasıyla,

$$\delta_j = 2(d_j - F_j) f'(s_j) \quad (\text{A.14})$$

eelde edilir. Bu hesaplama çıkış tabakası için olup, saklı tabakalar için  $d_j$  değerleri bilinmediği için,

$$\frac{\partial(e^2)}{\partial F_j} = \sum_l \frac{\partial(e^2)}{\partial s_l} \frac{d s_l}{d F_j} \quad (\text{A.15})$$

$$\sum_l \frac{\partial(e^2)}{\partial s_l} \frac{d}{d F_j} \sum_i F_i w_{il} = - \sum_l \delta_l w_{jl} \quad (\text{A.16})$$

yazılırsa, (A.16) ve (A.17) yardımıyla, (A.13) denklemi saklı tabaka nöronları için,

$$\delta_j = f'(s_j) \sum_l \delta_l w_{jl} \quad (\text{A.17})$$

şekline gelir.  $f(.)$  fonksiyonu sigmoid fonksiyonu olduğu için

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

şeklinde verilirsede  $\sigma = 1$  almak problemin genelliğini bozmadığı için

$$f(x) = \frac{1}{1 + e^{-x}} \quad (\text{A.18})$$

şeklinde alınıp, türevide aşağıdaki gibi verilebilir.

$$f'(x) = f(x)[1 - f(x)] \quad (\text{A.19})$$

Böylece (A.14) ve (A.17) denklemleri aracılığı ile çıkış tabakası için ,

$$\delta_j = 2(d_j - F_j)F_j(1 - F_j) \quad (\text{A.20})$$

olup, saklı tabaka için ise

$$\delta_j = F_j(1 - F_j) \sum_l \delta_l w_{jl} \quad (\text{A.21})$$

elde edilerek, (A.12) denklemine göre ağırlık katsayılarının değişimi hesaplanabilir.

## EK-B

### BAZI İSTATİSTİKSEL BÜYÜKLÜKLER

Rastgele olayların istatistiksel özellikleri karakteristik fonksiyonlarla veya böyle fonksiyonlardan türetilen karakteristik değerlerle tanımlanır. Bu tip karakteristik değerler şöyledir :

$X$  , bir rastlantı değişkeni olmak üzere;  $X$  'in  $x_i$  değerini alma olasılığı

$$P_i = P(X = x_i) \quad (B.1)$$

şeklinde gösterilebilir.

Benzer şekildeki rastlantı değişkenleri için olasılık yoğunluk fonksiyonları

$$P(x_i) = \frac{P(x_i < X < x_i + \Delta x_i)}{\Delta x} \quad (B.2)$$

olup, dağılım fonksiyonları da,

$$F(x_i) = P(X < x_i) = \sum_{\substack{i \\ X < x_i}} P_i = \int_{-\infty}^{x_i} p(x_i) dx \quad (B.3)$$

şeklindedir.

Dağılım fonksiyonlarının kestirimi için her zaman, yukarıda sözü geçen karakteristik fonksiyonları kullanılmaz. Bunun yerine bu fonksiyonlardan türetilen ve moment değerleri olarak isimlendirilen karakteristik büyüklükleri kullanmak yeterlidir.  $E$ , beklenen değer veya matematiksel beklenti işlemcisi olmak üzere,  $k$ . mertebeden momentler aşağıdaki gibi ifade edilebilirler.

$$m_k = E[x^k] \quad (B.4)$$

ve  $k$ . mertebeden merkezi momentler de,

$$\mu_k = E[(X - E[X])^k] \quad (B.5)$$

olarak verilebilir.  $k=1$  için birinci mertebeden moment aritmetik ortalama olarak isimlendirilir. Burada aritmetik ortalama

$$m_1 = E[X] = \bar{x} = \frac{1}{n} \left( \sum_{i=1}^n x_i \right) \quad (\text{B.6})$$

şeklindedir. Birinci merkezi moment ise daima sıfırdır.

$$\mu_1 = E[X - E[X]] = \overline{x_i - \bar{x}} = 0 \quad (\text{B.7})$$

İkinci merkezi moment " varyans " olarak isimlendirilip ortalama değerden sapmanın, ölçüsüdür. Burada varyans,

$$\sigma^2 = \mu_2 = D^2 = E[(X - E(X))^2] \quad (\text{B.8})$$

olup, bu değer ortalama karesel sapması ise

$$\sigma = +\sqrt{D^2[X]} = +\sqrt{\sigma^2} \quad (\text{B.9})$$

standart sapma olarak isimlendirilir. Eğer üçüncü merkezi moment, standart sapmanın üçüncü kuvvetine bölünürse elde edilen bu büyüklük skewness (çarpıklık) olarak isimlendirilir. Dağılım fonksiyonunun bakışım bozukluğunu tanımlayan bu ifade

$$s = \frac{\mu_3}{\sigma^3} \quad (\text{B.10})$$

şeklinde yazılabilir. Burada,

$$\mu_3 = E[(X - m_1)^3]$$

olup, gaussian olasılık yoğunluk fonksiyonu (o.y.f.) dağılımının skewness değeri  $s=0$  dir. Dağılım fonksiyonunun basıklığını karakterize eden; dördüncü merkezi momentin standart sapmanın 4. kuvvetine olan oranı ise "kurtosis" olarak isimlendirilip, tanımı da aşağıdaki gibidir.

$$c = \frac{\mu_4}{\sigma^4} \quad (\text{B.11})$$

Gaussian o.y.f. dağılımın kurtosis değeri  $c=3$  olduğu için bu nedenle kurtosis bazen  $(c-3)$  şeklinde de tanımlanabilir.

**T.C. YÜKSEKÖĞRETİM KURULU  
DOKÜMANTASYON MERKEZİ**

**ÖZGEÇMİŞ**

Serhat Şeker, 2.7.1959 da İstanbul 'da doğdu. İlk ve orta eğitimini İstanbul 'da sırasıyla, İ. A. Gövsa İlkokulu, Çapa Ortaokulu ve Şehremini Lisesinde tamamladı. Yüksek eğitimine, 1976 da İstanbul Teknik Üniversitesi ( İ.T.Ü.), Temel Bilimler Fakültesi, Matematik Mühendisliği Bölümü 'nde başladı. 1980 yılında İ.T.Ü. Elektrik Fakültesi 'ne geçerek 1984-85 yılının şubat döneminde Enerji Bölümünden mezun oldu. Aynı yıl, İ.T.Ü. Elektrik-Elektronik Fakültesi 'nin, Elektrik Mühendisliği Bölümü, Elektrikte Nükleer Güç Birimi 'ne Araştırma Görevlisi olarak girdi. 1985-86 döneminde lisans üstü eğitime başlayarak, Temmuz 1988 de, İ.T.Ü. Nükleer Enerji Enstitüsü 'nden Yüksek Mühendis olarak mezun oldu. Şubat 1989 döneminde İ.T.Ü. Fen Bilimleri Enstitüsü, Elektrik Mühendisliği Anabilim Dalı 'nda, doktora eğitime başladı. 1990 yılında, Yüksek Öğretimde Uluslararası İşbirliği, Hollanda Organizasyonu-NUFFIC 'den aldığı bursla, Ekim 1990-Ocak 1991 arasında, Hollanda Enerji Araştırma Merkezi-ECN 'de doktora çalışmasına ilişkin, ön araştırmalarda bulundu. Yine aynı burs desteği ile Kasım 1993-Şubat 1994 arasında ikinci kez gittiği ECN 'de, önceki çalışmalarına devam etti ve çalışmalarını İ.T.Ü. Elektrik Mühendisliği Bölümü 'nde sonuçlandırdı. Halen, İ.T.Ü. deki görevine devam etmektedir.