

TOPLU VE DAĞINIK ELEMANLI ALÇAK-GEÇİREN MERDİVEN TİPİ DEVRE PARAMETRELERİNİN YAPAY SİNİR AĞLARI KULLANILARAK HESAPLANMASI

Metin ŞENGÜL¹ Atilla ÖZMEN² Melek YILMAZ³

^{1,2,3}Kadir Has Üniversitesi
Mühendislik Fakültesi
Elektronik Mühendisliği Bölümü
34230, Cibali, Fatih, İstanbul

¹e-posta: msengul@khas.edu.tr

²e-posta: aozmen@khas.edu.tr

³e-posta: myilmaz@khas.edu.tr

Anahtar sözcükler: Toplu ve dağılık elemanlar, yapay sinir ağları, geriye yayılım.

ÖZET

Bu bildiri de, toplu ve dağılık devre elemanları içeren alçak-geçiren merdiven tipi devre parametrelerinin yapay sinir ağları kullanılarak hesaplanması sunulmuştur. Yapay sinir ağının eğitimi için elli adet örnek alınmıştır. Daha sonra girilen elli adet değer için devre parametreleri hesaplanmış ve olması gereken değerler ile karşılaştırılmış, birbirlerine oldukça yakın oldukları gözlenmiştir.

1. GİRİŞ

Haberleşme sistemlerinin tasarımında ve geliştirilmesinde temel problemlerden biri, verilen elemanın, sisteme, mümkün olan en geniş frekans bandında optimum performans elde edilebilmesi amacıyla kuplaj devreleri vasıtasıyla uyumlaştırılmasıdır. Bu problem, özünde, verilen karmaşık empedansların uyumlaştırılması için dengeleyici devrelerin tasarımını gerektirir ve literatürde empedans uyumlaştırma veya dengeleme olarak bilinir.

Toplu ve dağılık devre elemanı içeren devreler, özellikle yüksek frekanslarda, sadece toplu veya sadece dağılık eleman içeren devrelere göre çok daha avantajlı ve uygundur [1].

Bildirinin ikinci bölümünde toplu ve dağılık eleman içeren iki boyutlu devrelerin dağılım parametre yardımıyla analizi verilecektir. Üçüncü bölümde

yapay sinir ağları anlatılmış, bölüm 4 'de ise beşinci dereceden (3 toplu ve 2 dağılım eleman içeren) bir devrenin sentezinde kullanılacak parametrelerin yapay sinir ağlarıyla hesaplanması ve elde edilen sonuçlar sunulmuştur.

2. İKİ BOYUTLU KAYIPSIZ İKİ-KAPILILARIN DAĞILMIŞ PARAMETRE YAKLAŞIMIYLA ANALİZİ

Tek boyutlu iki-kapılılar teorisinde, saçılım matrisi ve saçılım transfer matrisi, özellikle Belevitch kanonik formları, sentez teorisinin en önemli aracı olarak kullanılmaktadır.

Fetweiss, çok boyutlu iki-kapılı reaktanslarının saçılım matrislerinin ve saçılım transfer matrislerinin, kanonik polinomlar f , g ve h ile ifade edilebileceğini göstermiştir. Burada izlenen yolun, tek boyutlu durumda izlenen yoldan farkı bulunmamaktadır. Tek boyutlularda kullanılan klasik Hurwitz polinomlarına karşılık olarak saçılım Hurwitz veya Temel Hurwitz polinomları adı verilen çok boyutlu Hurwitz polinomları tanımlanmıştır.

Aşağıda, kayıpsız iki-kapılıları kanonik polinomlarla ifade etmeden önce, ilerki bölümlerde kullanılacak iki değişkenli polinomlar ve notasyonları ile ilgili bazı temel tanımlar verilecektir.

p , λ değişkenleriyle, bir g polinomu, $g(p,\lambda)$ olarak gösterilecektir. $g(p,\lambda)$ polinomu şu şekilde yazılabilir,

$$g(p, \lambda) = \sum_{k=1}^{n_p} \sum_{l=1}^{n_\lambda} g_{kl} p^k \lambda^l$$

burada n_p ve n_λ , g polinomunun p ve λ türünden kısmi derecelerdir.

Tanım 1: İki değişkenli $g(p,\lambda)$ polinomunun derecesi m 'dir, eğer $m = \max_{g_{kl} \neq 0} (k + l)$. Kısmi dereceler n_p ve n_λ türünden yazılırsa $m = n_p + n_\lambda$ olur.

$g(p,\lambda)$ polinomunu, bir değişkene göre düzenlenirse aşağıdaki tekrarlamalı kanonik form elde edilir,

$$g(p, \lambda) = \sum_{k=1}^{n_p} G(\lambda) p^k = \sum_{l=1}^{n_\lambda} \bar{G}(p) \lambda^k$$

Bu ifade matris notasyonu ile gösterilirse,

$$g(p, \lambda) = p^T \Lambda_g \lambda^T$$

burada $p^T = [1 \ p \ p^2 \ \dots \ p^{n_p}]$
 $\lambda^T = [1 \ \lambda \ \lambda^2 \ \dots \ \lambda^{n_\lambda}]$ ve $n_p \times n_\lambda$ boyutundaki Λ_g matrisi şu şekilde tanımlanır,

$$\Lambda_g = \begin{bmatrix} g_{00} & g_{01} & \dots & g_{0n_\lambda} \\ g_{10} & g_{11} & \dots & g_{1n_\lambda} \\ \vdots & \dots & \dots & \vdots \\ g_{n_p 0} & g_{n_p 1} & \dots & g_{n_p n_\lambda} \end{bmatrix}$$

İki değişkenli polinomların parakonjugesi

$g_* = g(-p, -\lambda)$ olarak gösterilecektir.

Tanım 2: İki değişkenli $g(p,\lambda)$ polinomu, eksik terimi olmayan m^{th} dereceli polinom olarak adlandırılır ve


$$g(p, \lambda) = \sum_{k=0}^m \left(\sum_{l=0}^{m-k} g_{kl} \lambda^l \right) p^k$$

olarak gösterilir. Burada, g_{ij} sıfır olmayan reel katsayılardır. Matris notasyonu ile, üst üçgende sıfır olmayan katsayı matrisi haline gelir,

$$\Lambda_g = \begin{bmatrix} g_{00} & g_{01} & \dots & g_{0n_\lambda} \\ g_{10} & g_{11} & \dots & 0 \\ \vdots & \dots & \dots & 0 \\ g_{n_p 0} & 0 & \dots & 0 \end{bmatrix}$$

Aşağıda toplu ve dağıtık elemanlı kayıpsız iki-kapılıların iki değişkenli karakterizasyonu ve kanonik polinomların özellikleri verilecektir.

Şekil 1 'de toplu ve dağıtık elemanların ardarda bağlanmasıyla elde edilen iki-kapılı kayıpsız yapı gözönüne alınacaktır.



Şekil 1. Ardarda bağlı toplu ve dağıtık elemanlı iki-kapılı

Bu iki-kapılıyı tanımlayan saçılım matrisi, Belevitch kanonik formu kullanılarak şu şekilde ifade edilebilir,

$$S(p, \lambda) = \frac{1}{g(p, \lambda)} \begin{pmatrix} h(p, \lambda) & \sigma f(-p, -\lambda) \\ f(p, \lambda) & -\sigma h(-p, -\lambda) \end{pmatrix}$$

burada,

$f(p, \lambda)$: iletim sıfırlarını içeren reel katsayılı monik polinom,

$h(p, \lambda)$ ve $g(p, \lambda)$: karmaşık değişkenler

$p = \sigma + j\omega$ ve $\lambda = \varepsilon + j\Omega$

($\lambda = \tanh(p\tau)$, τ birim eleman gecikme zamanı)

türünden reel katsayılı polinomlar

$g(p, \lambda)$: saçılım Hurwitz polinomu


σ : sabir sayısı, $|\sigma| = 1$

g , h ve f polinomları kullanılarak bir iki-kapılının kayıpsızlık ilkesi şu şekilde yazılabilir,

$$g(p, \lambda)g(-p, -\lambda) = h(p, \lambda)h(-p, -\lambda) + f(p, \lambda)f(-p, -\lambda)$$

burada $X(-p, -\lambda)$, $X(p, \lambda)$ polinomunun parakonjugesidir.

Fiziksel gerçekleştirilebilirlik açısından bakıldığında, pratik bir devre konfigürasyonu, birim elemanlarla birbirine bağlanan alçak geçiren merdiven yapısıdır. Bu şekilde birim elemanlarla bağlanan alçak geçiren merdiven yapıya (LPLUE, Low-pass ladder structures with unit element) adı verilir.



Şekil 2. Birim elemanlarla bağlanan alçak-geçiren merdiven devre formu

Beş elemanlı (üç toplu, iki dağınmık elemanlı) bu tür devreleri tanımlayan, h, g ve f polinomlarının katsayıları arasındaki ilişkilerin açık ifadeleri aşağıdaki tabloda görülmektedir [1].

Tablo 1. Beşinci dereceden LPLUE devrelerinin açık katsayı ilişkileri

n	Katsayı İlişkileri
5	$[h_{01}, h_{02}, h_{10}, h_{20}, h_{30}]$ bağımsız katsayılar
	$g_{01} = (2 + 2g_{02} + h_{01}^2)^{1/2}$ $g_{11} = g_{10}g_{01} - h_{10}h_{01}$
	$g_{02} = (1 + h_{02}^2)^{1/2}$ $h_{11} = h_{02}\beta/\alpha + h_{20}\alpha/\beta$
	$g_{10} = (h_{10}^2 + 2g_{20})^{1/2}$ $g_{12} = (g_{11}g_{02} - h_{11}h_{02})/\alpha$
	$g_{30} = h_{30} , \mu = h_{30}/g_{30}$ $\alpha = g_{01} - \mu h_{01}$
	$h_{12} = \mu g_{12}, h_{21} = \mu g_{21}$ $\beta = g_{10} - \mu h_{10}$
	$g_{20} = (h_{20}^2 + 2g_{10}g_{30} - 2h_{10}h_{30})^{1/2}$
	$g_{21} = (g_{11}g_{20} - h_{11}h_{20} - g_{01}g_{30} + h_{01}h_{30})/\beta$

3. YAPAY SİNİR AĞLARI

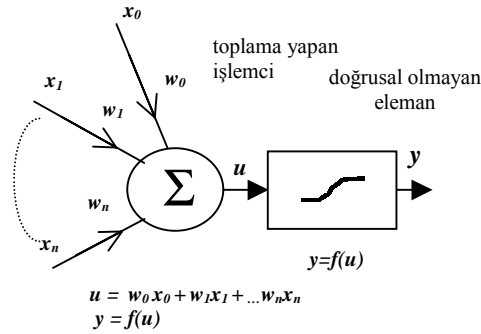
Canlı sinir sisteminin bir anlamda modellenmesi temeline dayanan yapay sinir ağları (YSA) basitleştirilmiş nöron adı verilen ve çeşitli yollarla birbirine bağlı birimlerden oluşmuş topluluklardır. Tek olarak düşünüldüklerinde basit bir işleve sahip olan nöronlar bir arada kullanıldıklarında oldukça karmaşık işlemleri gerçekleştirebilecek bir yapıya dönüşebilmektedirler.

YSA'lar eğitilebilir adaptif sistemlerdir. Sistem değişen koşullara uyar ve kendi kendine organize olabilir. Yapay sinir ağları, eğitmeye/örnek bilgiye dayanan bir fonksiyon geliştirir ve tasarımdan ziyade eğitmeyle hesaplama yapıları sağlayabilir. YSA'lar daha önce öğrendikleri bilgiyi eksik veya bozuk giriş verildiği zaman bile yeniden üretebilir ve doğrusal olmayan bir karakteristiğe sahip olmaları nedeniyle de gerçek dünya problemlerine daha doğru çözümler getirebilirler [2].

Yapay sinir ağlarının avantajlarını şu şekilde sıralayabiliriz: Yoğun bir şekilde paralel ve paralellikten dolayı hataya toleranslı olması, adaptif olarak tasarlanabilir olması ve eğitim setinin dışında problemin tam tanımlı olması gerekmemesi [2].


Ancak rastgele uygulamalar için kesin kurallar ve tasarım kriterlerinin olmaması, ağıın iç çalışmasını değerlendirecek genel bir yolun bulunamaması nedeniyle eğitim zor veya imkansız olabilir, ağıın gelecekteki performansını da tahmin etmek zordur.

Bir YSA modelinde kullanılan ve toplama işlemi yapan bir elemanla, doğrusal olmayan bir fonksiyondan (aktivasyon fonksiyonu) oluşan nöron Şekil 3'de gösterilmiştir. Burada x_1, x_2, \dots, x_n girişleri gösterirken; w_1, w_2, \dots, w_n ise bağlantı ağırlık katsayılarına karşılık gelmektedir. y ise çıkışı göstermektedir [3].



Şekil 3. Nöron modeli

En genel anlamda bir yapay sinir ağ modeli Şekil 4'de gösterildiği gibidir. Bu şekilden de görülebileceği gibi her nöronun birçok girişi ve tek çıkışı vardır. Bu çıkış diğer nöronların girişlerini oluşturur ve sistem böylece paralel bir şekilde yayılır.



Şekil 4. Tek gizli katmanlı YSA

Yapay sinir ağlarının görüntü işleme, işaret işleme, patern tanıma, tıp, askeri sistemler, finansal sistemler, planlama, kontrol ve araştırma, yapay zeka ve güç sistemleri gibi uygulama alanları vardır.

3.1. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarındaki öğrenme, sistemden yapılması istenen işe uygun olarak bağlantı ağırlık katsayılarının hesaplanması temeline dayanmaktadır. Öğrenme kuralı ise, istenen amaca yönelik olarak bağlantı ağırlık katsayılarının bazılarının veya tümünün değiştirilmesine yönelik olan bir denklem takımı olarak ifade edilebilir. Bu kural zamanla her bir nöronun cevabının değişmesine ve dolayısıyla ağırlık kendisini istenen cevaplara uyarlayabilmesine, bilgiyi kendi içinde istediği gibi düzenleyebilmesine veya kısaca öğrenmesine olanak tanır.

Yapay sinir ağları, programlama yerine örnekler ile eğitilir. Eğitime işlemi öğreticili ve öğreticisiz olmak üzere iki şekilde yapılır.

Öğreticili bir eğitime de, sisteme hem giriş bilgisi, hem de bu girişe karşın üretilmesi istenen çıkış bilgisi verilir. Böylece her denemeden sonra istenilen çıkış ile gerçek çıkış değerleri arasındaki fark öğrenme kuralına bağlı olarak uyarlanan ağırlık katsayıları ile en aza indirilmeye çalışılır. Çıkış hatası kabul edilebilir bir seviyeye gelince eğitim işlemine son verilir ve daha sonra eğitimde yer almamış yeni setler üzerinde elde edilen bu ağırlık katsayılarının veya başka bir deyişle ağırlık başarımına bakılır [4].

3.2. Geriye Yayılım Algoritması

Bu çalışmada öğrenme algoritması olarak öğreticili algoritmalarından olan geriye yayılım algoritması kullanılmıştır. Bu algoritma çok katlı ileri yayılım ağlarının tasarımında en çok kullanılan ve en iyi sonuç veren algoritmadır. İşleyebilmesi için ağırlık katsayılarının özel bir niteliği olması gerekir. Çıkışları iki değerli (1 ve 0 ,ya da +1 ve -1) değil, çok değerli olmalıdır. Bu değerler 0 ve 1 arasında olabilir.

Öğrenme sırasında öncelikle, gerçek değerden bulunan değer çıkarılarak hata elde edilir ve hatanın karesi alınır. Amaç, hatanın karesini minimum tutarak en iyi öğrenmeyi gerçekleştirebilmektir.

$$\varepsilon^2 = (t - y)^2$$

$$\varepsilon = \varepsilon(y(u(w)))$$

Daha sonra çıkış düğümlerindeki delta değerleri hesaplanır.

$$\nabla_w \varepsilon^2 \equiv \frac{\partial \varepsilon^2}{\partial w}$$

ve geriye yayma yöntemiyle, bütün gizli düğümlerdeki deltalar hesaplanır.

$$\begin{aligned} \nabla_w \varepsilon^2 &= \frac{\partial \varepsilon^2}{\partial y} \cdot \frac{\partial y}{\partial u} \cdot \frac{\partial u}{\partial w} \\ &= -2\varepsilon \operatorname{sgm}'(u)x \\ &= 2\delta x \\ \delta &\equiv -\varepsilon \operatorname{sgm}'(u) \end{aligned}$$



Son olarak gradyanın bileşenleri hesaplanır ve gereken ağırlık değişimleri elde edilir.

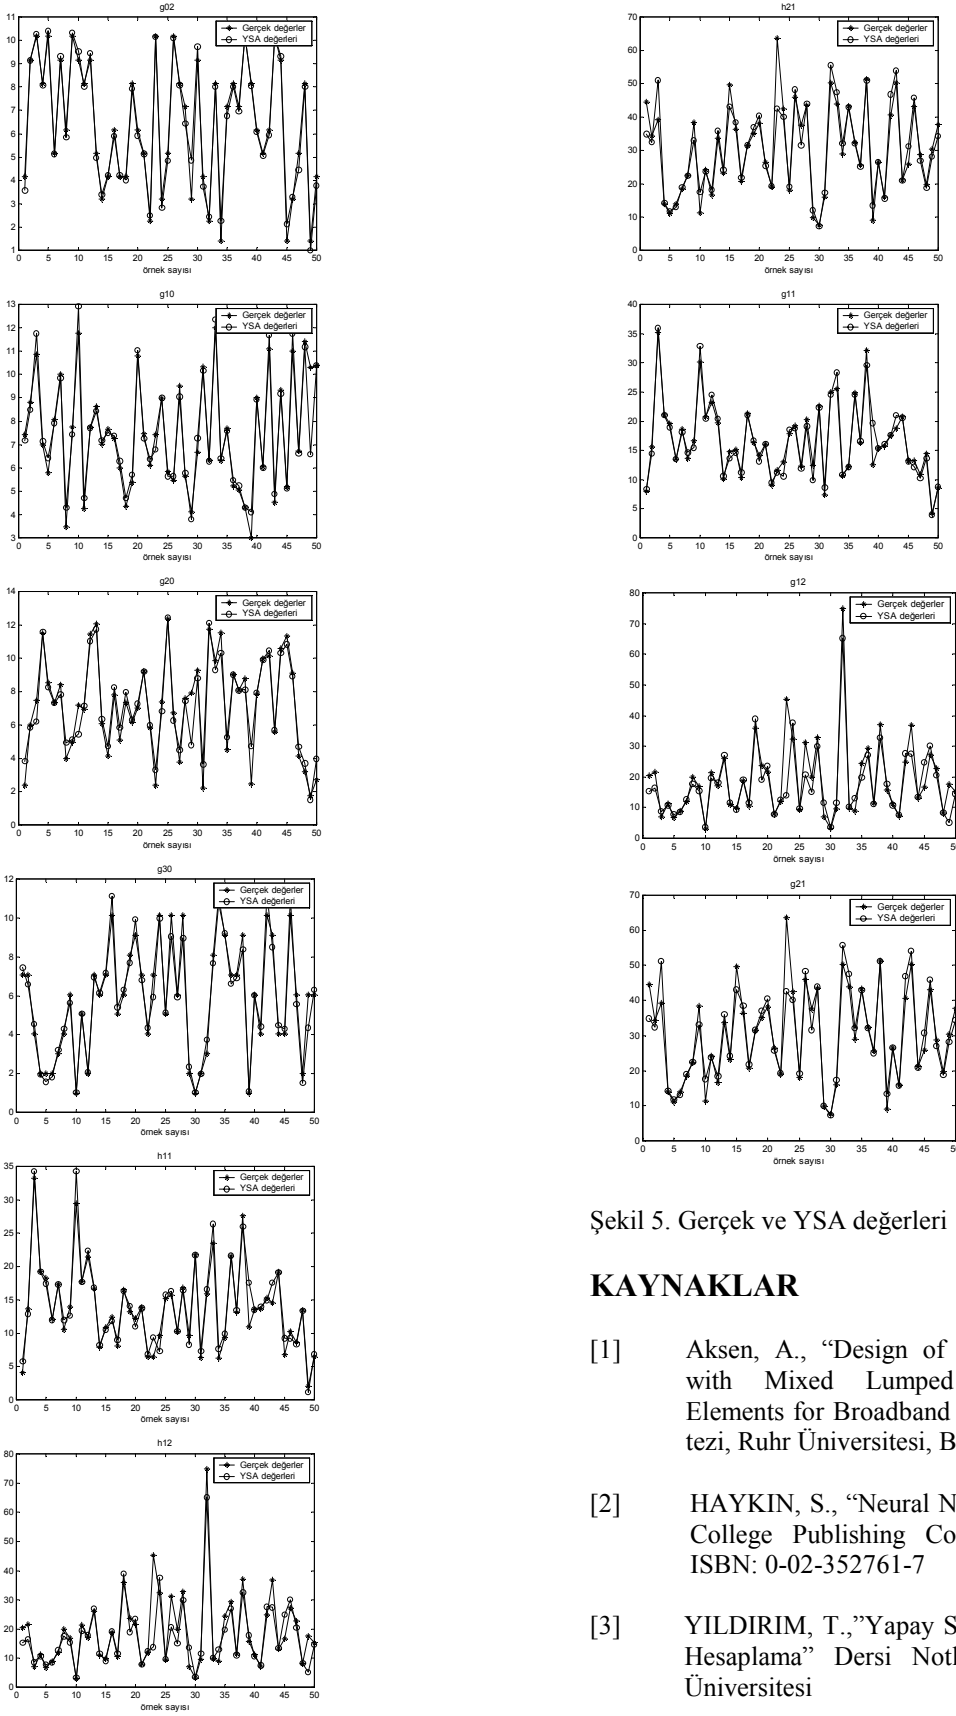
$$\begin{aligned} \Delta w &= -2\mu \delta x \\ w_{\text{yeni}} &= w_{\text{eski}} + \Delta w \end{aligned}$$

4. UYGULAMA VE SONUÇ

Bu çalışmada 15 nörondan oluşan tek gizli katmana sahip bir YSA oluşturulmuştur. Tablo 1 'de verilen atsayılar arasındaki açık ifadeler kullanılarak elde edilen 100 çıkış vektörünün ilk 50 tanesi eğitim seti olarak değerlendirilmiş, geriye yayılım algoritması kullanılarak yapılan eğitim sonucunda elde edilen bağlantı ağırlık katsayıları, sonraki 50 veri için test amacıyla kullanılmıştır. Veriler YSA'ya verilmeden önce [0,1] aralığında normalize edilmiş ve eğitim işleminden sonra gerçek verilerle karşılaştırma yapılabilmesi amacıyla denormalize edilmiştir. n=5 değeri için giriş vektörü olarak $h_{00}, h_{01}, h_{02}, h_{10}, h_{20}, h_{30}$, çıkış vektörü olarak da $g_{00}, g_{01}, g_{02}, g_{10}, g_{20}, g_{30}, h_{11}, h_{12}, h_{21}, g_{11}, g_{12}, g_{21}$ seçilmiştir.

Eğitim sonucunda gerçek değerlerle YSA kullanılarak elde edilen değerler her bir parametre için grafiksel olarak elde edilmiştir (Şekil 5). Grafiklerden de görüldüğü gibi YSA çıkışları gerçek değerleri takip eden bir yapı göstermektedir.





Şekil 5. Gerçek ve YSA değerleri

KAYNAKLAR

- [1] Aksın, A., "Design of Lossless Two-ports with Mixed Lumped and Distributed Elements for Broadband Matching", Doktora tezi, Ruhr Üniversitesi, Bochum, 1994
- [2] HAYKIN, S., "Neural Networks" Macmillan College Publishing Company Inc., 1994, ISBN: 0-02-352761-7
- [3] YILDIRIM, T., "Yapay Sinir Ağları ve Nöral Hesaplama" Dersi Notları, Yıldız Teknik Üniversitesi
- [4] GEÇKİNLİ, M., "Artificial Intelligence and Nuc.Eng.App." Dersi Notları İstanbul Teknik Üniversitesi, İTÜ Nükleer Enerji Enstitüsü