

## NOMA TABANLI BİLİŞSEL RADYO SİSTEMLERİNDE SINIR AĞI YÖNTEMLERİ İLE ERGODİK KAPASİTE TAHMİNİ VE BAŞARIM ANALİZİ

*Mustafa NAMDAR* \*<sup>ID</sup>  
*Abdulkadir GÜNEY* \*<sup>ID</sup>  
*F. Kebire BARDAK* \*\*<sup>ID</sup>  
*Arif BAŞGÜMÜŞ* \*\*\*<sup>ID</sup>

Alınma:25.10.2022; düzeltme:19.12.2022; kabul: 24.01.2023

**Öz:** Bu çalışmada, bilişsel radyo (BR) tabanlı dikgen olmayan çoklu erişim tekniği (NOMA) kullanılarak, yakın kullanıcıya ait toplam ergodik kapasite değerinin, önerilen ileri beslemeli geri yayımlı yapay sinir ağı (YSA) ve doğrusal olmayan dışsal girdili otoregresif ağ (Nonlinear Autoregressive Network with Exogenous Inputs, NARX) modeli ile farklı eğitim algoritmaları yoluyla yüksek doğruluk oranında ve hızlı eğitim sürelerinde tahmin edilmesi amaçlanmıştır. Sinir ağına kullanılan veri seti, üstel sönmüleme kanalı karakteristiği ile modellenen BR-NOMA sistem modelinden elde edilmiştir. Denetimli öğrenme yöntemi kullanılarak tasarlanan YSA'ya girdi ve çıktı verileri öğretilerek yakın kullanıcıya ait ergodik kapasite tahmini yapılmıştır. YSA ve NARX sinir ağları başarımları değerlendirilirken eğitim süresi, iterasyon sayısı, ağın doygunluğa ulaşmaması durumları göz önünde bulundurulmuştur. Yakın kullanıcıya ait gerçek ergodik kapasite değeri ile ileri beslemeli geri yayımlı YSA ve NARX ağlarının tahmin etmiş olduğu değerler karşılaştırılmıştır. Önerilen sinir ağlarının Levenberg-Marquardt, Bayesian ve Scaled-Conjugate eğitim algoritmaları altındaki performans analizi, hatanın minimuma ulaştığı epok değer grafiği, hata histogram analizi ve eğitim durum analizi açılarından incelenmiştir.

**Anahtar Kelimeler:** Bayesian, Bilişsel radyo, Levenberg-Marquardt, NARX, NOMA, Yapay sinir ağları

### Ergodic Capacity Estimation and Performance Analysis with Deep Learning Methods in NOMA-based Cognitive Radio Systems

**Abstract:** In this study, using the cognitive radio (CR)-based non-orthogonal multiple access (NOMA) technique, the total ergodic capacity value of the close user is estimated with high accuracy and fast training times through different training algorithms with the proposed feedforward backpropagation artificial neural network (ANN) and nonlinear autoregressive network with exogenous inputs (NARX) model. The data set used in the neural network was obtained from the CR-NOMA system model, which was modeled with the exponential fading channel characteristic. By training the input and output data to the ANN, which was designed using the supervised learning method, ergodic capacity estimates of the close user were made over the test data. While evaluating the performance of ANN and NARX neural networks, the training time, the number of iterations, and the conditions of the network not reaching saturation were taken into consideration. The actual ergodic capacity value of the close user and the predicted values of feedforward

\* Kütahya Dumlupınar Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü Evliya Çelebi Yerleşkesi 43100 Merkez/KÜTAHYA

\*\* Bandırma Onyedli Eylül Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik-Elektronik Mühendisliği Bölümü 10200 Bandırma/BALIKESİR

\*\*\* Bursa Uludağ Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü 16059 Nilüfer/BURSA

İletişim Yazarı: Arif BAŞGÜMÜŞ (basgumus@uludag.edu.tr)

backpropagation ANN and NARX networks were compared. The performance analysis of the proposed neural networks under Levenberg-Marquardt, Bayesian and Scaled-Conjugate training algorithms has been examined in terms of epoch value graph, error histogram analysis, and training state analysis where the error reaches the minimum.

**Keywords:** Bayesian, Cognitive radio, Levenberg-Marquardt, NARX, NOMA, Artificial neural networks

## 1. GİRİŞ

NOMA son dönemde arařtırmacıların dikkatini çeken ve 5G ve ötesi yeni nesil telsiz haberleşme sistemleri için gelecek vaat eden bir yöntemdir. NOMA tekniđi ile bant genişliđi, zaman ve frekansın etkin biçimde kullanılmasına imkân sağlanarak kaynakların kullanıcıya tahsis edilebilmesi yoluyla spektral verimliliđin ve servis kalitesinin artması sağlanacaktır (Bardak ve diđ., 2020; Seyman, 2022). Geleneksel dikgen çoklu erişim (Orthogonal Multiple Access, OMA) yöntemlerinin aksine dikgen olmayan çoklu erişim yöntemi (Non-orthogonal Multiple Access, NOMA) ile çok kullanıcılı hücresel haberleşme sisteminde zaman ve frekans kaynakları, deđişken güç deđerleri ile kullanıcılara tahsis edilmektedir. NOMA tekniđi ile yeni nesil telsiz haberleşme sistemlerinde artan trafik ihtiyacının, yoğun kapasite talebinin ve ultra düşük gecikme süresinin karşılanması beklenmektedir. Genel anlamda NOMA tekniđi, yüksek spektral verimliliđin sağlanabilmesi için farklı kullanıcılara deđişken kanal koşullarına göre farklı güç katsayıları tahsis edilmesini benimsemektedir. Birden fazla kullanıcının bilgi işareti, verici tarafta üst üste bindirilerek alıcı tarafa gönderilmekte ve alıcı tarafta ardışık girişim iptali (Successive Interference Cancellation, SIC) işlemi uygulanarak girişimden arındırılan bilgi işareti elde edilmektedir. NOMA odađındaki bu tasarım, 3. Nesil ortaklık projesi (3rd Generation Partnership Project, 3GPP) standartlarına da girmiştir (Dai ve diđ., 2018).

Dođrusal olmayan problemlerin tahmin edilmesinde başarılı sonuçlar veren derin öğrenme yöntemleri, son dönemde birçok problemin çözülmesinde anahtar rol oynamaktadır. Makine öğrenmesi (Machine Learning, ML) yöntemlerinin alt kümesine dahil olan derin öğrenme yöntemleri, haberleşme, görüntü işleme, ses tanıma, otonom araçlar, akıllı şehirler, dođal dil işleme, medikal görüntü analizi ve finans başta olmak üzere birçok alanda kullanılmaktadır. Derin öğrenme yöntemlerinden haberleşme alanında; pozisyon kestirimi, girişim kontrolü, kanal tahmini, güç tahsisi, bilişsel radyo, sinyal tespiti, kanal kodlama, kanal kod çözme konularında faydalanılmaktadır. Biyolojik sinir ađı sisteminden esinlenilerek geliştirilen yapay sinir ađları (YSA), insan beyninin en temel özelliđi olan öğrenmeyi hedefleyen bilgi işleme sistemidir.

Yeni nesil telsiz haberleşme sistemlerinde kullanılan NOMA tekniđi ile derin öğrenme ađlarının iş birliđi içerisinde kullanılması, kablosuz haberleşme sistemlerinde birçok probleme çözüm sunabilmesi açısından önem arz etmektedir. NOMA tekniđi ile derin öğrenme yaklaşımı; sinyal tespiti (Signal Detection), modülasyon tespiti (Modulation Detection), kanal tahmini (Channel Estimation), kaynak tahsisi (Resource Allocation) başta olmak üzere birçok alanda kullanılmaktadır. Literatürde, bu alanlarda, DL-NOMA (Downlink-NOMA) ile ilgili birçok çalışma bulunmaktadır. Gui ve diđ., (2018)'de, uzun kısa süreli bellek (LSTM) ađları kullanılarak denetimli öğrenme tekniđi ile gerçek zamanlı kanal durum bilgisinin (Channel State Information) geliştirilen yapay sinir ađı (Artificial Neural Network, ANN) eđitilerek ve eđitim sonucunda test edilerek çeşitli öğrenme oranları (Learning Rate) altında farklı işaret gürültü oranı (Signal-to-Noise Ratio, SNR) seviyelerinde kanal tahmini performans analizine yer verilmektedir. Derin sinir ađları (Deep Neural Network, DNN) kullanılarak denetimli öğrenme tekniđi ile kanal durum bilgisinin otomatik olarak tespit edilmesi amaçlanan Lin ve diđ., (2019)'da farklı SNR seviyeleri altında sembol hata oranı ve klasik CSI tespit yöntemleri ile derin öğrenme yöntemlerinin sembol hata oranı (Sembol Error Rate, SER) performans karşılaştırması ele alınmıştır. Bir başka çalışma Liu ve diđ., (2018)'de, NOMA sistemleri için, yinelemeli sinir ađları (Recurrent Neural Network, RNN) kullanılarak, denetimli öğrenme tekniđi ile hızlı ve optimize edilmiş kaynak tahsisi gerçekleştirilmiştir. Emir ve diđ., (2022)'de evrişimli sinir ađları (Convolutional Neural Network,

CNN) kullanılarak, NOMA haberleşme sistemlerinde yakın ve uzak kullanıcı ağıyla alıcı tarafa ulaşan aşağı ve yukarı yönlü işaretlerin derin öğrenme ağları ile tespit edilmesi amaçlanmış, olasılık tabanlı klasik tespit yöntemlerinden olan en büyük olasılık tahmini (Maximum Likelihood Estimation, MLE) ile derin öğrenme yöntemlerinin performans analizi incelenmiştir. LSTM ağları kullanılarak, Rayleigh sönümlenme kanalı altında, minimum ortalama kare hatası kestirimi (Minimum Mean Square Error, MMSE), en küçük kareler yöntemi kestirimi (Least Square Estimator, LSE) ve derin öğrenme tahminleyicisinin farklı SNR seviyelerinde bit hata oranı (Bit Error Rate, BER) performans analizi sonucu Bhatt ve diğ., (2022)'de değerlendirilmiştir. Narengerile ve Thompson, (2019)'da iki kullanıcı NOMA sistemi için LSTM ağları kullanılarak, minimum ortalama kare, en küçük kareler yöntemi, en büyük olasılık yöntemi ve derin öğrenme tahminleyicisinin farklı SNR seviyeleri altında SER karşılaştırması yapılmıştır. Son olarak Sim ve diğ., (2020)'de CNN kullanarak, çok kullanıcı tek baz istasyonunun performansını artırmak için yeni bir CNN tabanlı ardışık girişim engelleme (Successive Interference Cancellation, SIC) şeması üzerine çalışılmıştır. Farklı öğrenme oranları, kayıp fonksiyonları ve epok değerleri altında performans analizi incelenmiştir.

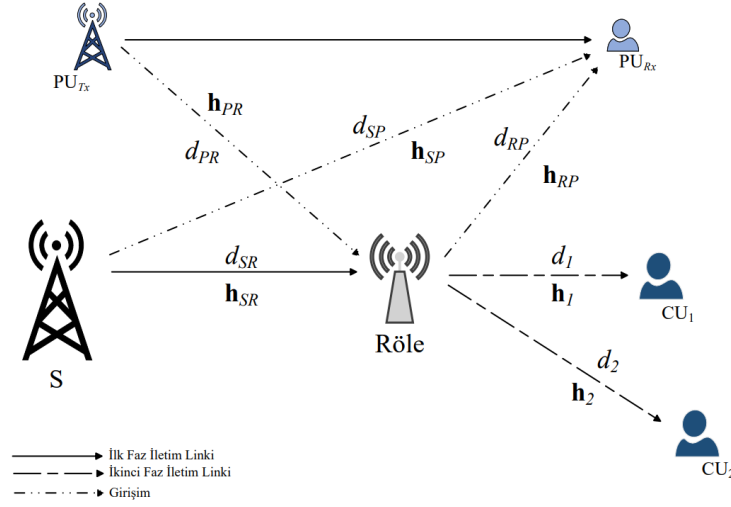
Literatür özetinde, DL-NOMA ile ilgili olarak kanal tahmini ve kaynak tahsisi konularında en küçük kareler yöntemi kestirimi ve en büyük olasılık yöntemine dayalı olasılık tabanlı yöntemler ile derin öğrenme yöntemlerinin farklı SNR değerleri altında BER performans analizlerinin ele alındığı çalışmalar incelenmiştir. Yakın kullanıcıya ait üstel dağılımlı bir kanal ile modellenen aşağı yönlü BR-NOMA sisteminde yakın kullanıcıya ait ergodik kapasite tahmini ilk kez bu çalışmada ele alınmıştır.

Bu çalışmanın amacı, BR-NOMA sisteminde yer alan yakın kullanıcıya ait ergodik kapasite değerini, ileri beslemeli geri yayımlı ANN ağı ve NARX sinir ağları kullanılarak yüksek doğruluk oranında tahmin etmeyi gerçekleştirmektir. Tasarlanan sinir ağının, geleneksel yöntemlere göre işlem maliyetini azaltması hesaplama sürelerini hızlandırması amaçlanmıştır. Ek olarak bu çalışmada, farklı yapay sinir ağ modelleri ve eğitim fonksiyonları kullanıldığı durumda, yakın kullanıcıya ait ergodik kapasite değerinin tahmin edilen değerler ile gerçek değerler arasındaki ortalama kare hata performans fonksiyonu, hata histogram analizi, sinir ağının en uygun epok değeri, sinir ağının eğitim süresi ve eğitim durum grafiği incelenmektedir.

Çalışma 5 bölümden oluşmaktadır. Bölüm 2'de röle yardımıyla aşağı yönlü BR-NOMA sistem modeli verilmektedir. Bölüm 3'de yakın kullanıcıya ait ergodik kapasite kestiriminin gerçekleştirildiği ileri beslemeli geri yayımlı YSA ve NARX ağı sistem modeli ve parametrelerinden bahsedilmektedir. Bölüm 4'te YSA ve NARX ağ modellerinin gerçek değerler ile tahmin edilen değer arasındaki korelasyonu ve nümerik sonuçlar sunulmaktadır. Son bölümde ise genel sonuçlar ve öneriler değerlendirilmektedir.

## 2. SİSTEM MODELİ

Sistem modelinde, Şekil 1'de görüldüğü gibi, kaynağın (S), çöz-ve-aktar çift yönlü rölenin (R), birincil ağ (BA) için tanımlı verici-alıcı kullanıcılarının ( $PU_{Tx}$ ,  $PU_{Rx}$ ) yanı sıra iki adet hedef İA kullanıcılarının ( $CU_1$ ,  $CU_2$ ) yer aldığı aşağı yönlü (downlink) BR-NOMA sistemi incelenmiştir. Önerilen model de ikincil ağ (İA) kullanıcılarının, BA kullanıcıları ile aynı frekans bandını kullandıkları varsayılmaktadır. S ile R arasında doğrudan bir iletim linkinin olduğu, öte yandan S ile İA kullanıcıları arasında ise direkt bir iletim linkinin olmadığı kabul edilmektedir. S'nin, İA kullanıcıları ile DF röle üzerinden NOMA tekniği yardımıyla haberleştiği düşünülmektedir.  $CU_1$  yakın kullanıcı,  $CU_2$  ise uzak kullanıcı olarak tanımlanmıştır. Kullanıcı düğümleri arasına karşılık gelen mesafeler  $d_{PR}$ ,  $d_{SP}$ ,  $d_{RP}$ ,  $d_{SR}$ ,  $d_1$  ve  $d_2$  olarak verilmektedir. S'nin tek verici antene,  $CU_1$  ve  $CU_2$  kullanıcılarının tek alıcı antene, R'nin ise  $N_T$  adet verici ve  $N_R$  adet alıcı antene sahip olduğu değerlendirilmiştir. Rölede,  $CU_1$  ve  $CU_2$  kullanıcılarında SIC uygulandığı varsayılmaktadır. İA'da yer alan S'nin ve R'nin işaretlerini aynı zamanda ve aynı frekans bandını kullanarak ilettiği ve dolayısı ile S'nin ve R'nin, BA alıcısına ( $PU_{Rx}$ ) girişim (ortak kanal girişim linki) oluşturdukları değerlendirilmektedir (Bardak ve diğ., 2021; Namdar ve diğ., 2018).



**Şekil 1:**  
Aşağı yönlü BR-NOMA sistem modeli.

BA kullanıcılarının ( $PU_{Tx}$ ,  $PU_{Rx}$ ), İA kullanıcıları olan  $CU_1$  'den ve  $CU_2$  'den uzak oldukları, dolayısıyla, BA kullanıcılarının  $CU_1$  ve  $CU_2$  üzerinde girişim oluşturmayacakları varsayılmaktadır. Bu durumda  $s[n]$ , aşağı yönlü NOMA yönteminin kullanıldığı BR sistem modeline göre, S'nin R'ye göndereceği toplam işaret olarak tanımlanabilir.

$$s[n] = \sqrt{\frac{P_S}{d_{SR}^\tau}} a_1 x_1[n] + \sqrt{\frac{P_S}{d_{SR}^\tau}} a_2 x_2[n] \quad (1)$$

Burada,  $x_i[n]$ ,  $i \in \{1,2\}$   $CU_i$  için bilgi sembolünü ve  $a_i$ ,  $a_1 < a_2$  ve  $a_1 + a_2 = 1$  olmak üzere, güç paylaşım katsayısını belirtmektedir. S ve R için iletim güçleri sırası ile  $P_S$  ve  $P_R$ , yol kaybı katsayısı  $\tau$  ile gösterilmektedir. S ile  $PU_{Rx}$  arasındaki kanal linki  $h_{SP}$ , R ile  $PU_{Rx}$  arasındaki link ise  $h_{RP}$  ( $N_T \times 1$ ) kanal vektörü ile ifade edilmektedir. R'deki verici hüzmleme vektörü  $w_t \in \mathbb{C}^{N_T \times 1}$  ile temsil edilmektedir. Kaynak ile  $CU_1$  ve kaynak ile  $CU_2$  hedef kullanıcıları arasındaki iletimin, R yardımıyla iki fazlı olduğu düşünüldüğünde, ilk fazda R'de alınan işaret,

$$y_R[n] = \mathbf{w}_r^\dagger \mathbf{h}_{SR} s[n] + \sqrt{P_R} \mathbf{w}_r^\dagger \mathbf{H}_{SI} \mathbf{w}_t s[n - \mu] + \sqrt{\frac{P_P}{d_{PR}^\tau}} \mathbf{w}_r^\dagger \mathbf{h}_{PR} x_P[n] + \mathbf{w}_r^\dagger n_R[n] \quad (2)$$

şeklinde ifade edilebilir. Burada,  $\mathbf{h}_{SR}$  ( $N_R \times 1$ ) S ile R arasındaki kanal vektörünü,  $\mathbf{H}_{SI} \sim \mathcal{CN}(0, \sigma_{SI}^2)$  rölenin alıcı ve verici antenleri arasında meydana gelen  $N_R \times N_T$  boyutunda, birbirinden bağımsız ve eş dağılımlı girişim kanal matrisini,  $P_P$ ,  $PU_{Tx}$  için iletim gücünü,  $\mathbf{h}_{PR}$  ( $N_R \times 1$ ),  $PU_{Tx}$  ile R arasındaki kanal vektörünü,  $\mathbf{w}_r \in \mathbb{C}^{N_R \times 1}$  röledeki alıcı hüzmleme vektörünü,  $x_P[n]$ ,  $PU_{Tx}$ 'in ilettiği bilgi sembolünü,  $\mu$ , DF röleme işleminin sebep olduğu zaman gecikmesini ve  $n_R[n] \sim \mathcal{CN}(0, \sigma_n^2)$  ise,  $\sigma_n^2$  gürültü varyansı olmak üzere, röledeki toplamsal beyaz Gauss gürültüsünü (Additive White Gaussian Noise, AWGN) tanımlamaktadır.  $(.)^\dagger$  matematiksel operatörü, eşlenik devriği (conjugate transpose) temsil etmektedir. R, S'den aldığı  $y_R[n]$  işaretinden, SIC yöntemini uygulayarak öncelikle  $x_2[n]$  bilgisini, ardından  $x_1[n]$  bilgisini çözer. Bu durumda,  $x_1[n]$  için R'deki işaret-girişim gürültü oranı (Signal-to-Interference Noise Ratio, SINR),

$$\gamma_{R,1} = \frac{\frac{P_S}{d_{SR}^{\alpha}} a_1 |\mathbf{w}_r^{\dagger} \mathbf{h}_{SR}|^2}{P_R |\mathbf{w}_r^{\dagger} \mathbf{H}_{S1} \mathbf{w}_t|^2 + \frac{P_P}{d_{PR}^{\alpha}} |\mathbf{w}_r^{\dagger} \mathbf{h}_{PR}|^2 + \sigma_n^2} \quad (3)$$

şeklinde ifade edilmektedir.  $x_1[n]$  ve  $x_2[n]$  bilgileri R tarafından çözüldükten sonra, iletimin ikinci fazında, yine R tarafından yeniden kodlanarak  $CU_k$ ,  $k \in \{1,2\}$  kullanıcılarına gönderilmektedir.  $CU_k$  kullanıcıları için alınan işaret,

$$y_k[n] = \sqrt{\frac{P_R}{d_1^{\alpha}}} a_1 \mathbf{h}_k^T \mathbf{w}_t x_1[n - \mu] + \sqrt{\frac{P_R}{d_2^{\alpha}}} a_2 \mathbf{h}_k^T \mathbf{w}_t x_2[n - \mu] + n_k[n] \quad (4)$$

şeklinde verilmektedir. Burada,  $(\cdot)^T$  matematiksel operatörü matris transpozunu,  $|\cdot|$  ise mutlak değer operatörünü tanımlamaktadır. Ayrıca,  $\mathbf{h}_k$ ,  $k \in \{1,2\}$  ( $N_T \times 1$ ) röle ile  $CU_k$  kullanıcıları arasındaki kanal vektörünü,  $n_k[n] \sim \mathcal{CN}(0, \sigma_n^2)$   $CU_k$  kullanıcılarında oluşan AWGN'yi belirtmektedir. Böylelikle,  $CU_1$  aldığı işaretten, kendi bilgisini girişim olarak kabul ederek,  $x_2[n]$  bilgisini çözer. Sonrasında SIC yöntemini uygulayan  $CU_1$ , kendi bilgisi olan  $x_1[n]$ 'i çözmektedir. Mükemmel SIC yöntemi uygulanıp,  $CU_1$ 'de  $x_1[n]$  bilgisi doğru olarak çözüldüğünde SINR,

$$\gamma_1 = \frac{\frac{P_R}{d_1^{\alpha}} a_1 |\mathbf{h}_1^T \mathbf{w}_t|^2}{\sigma_n^2} \quad (5)$$

şeklinde ifade edilebilir.  $x_1[n]$  ile ilişkilendirilen erişilebilir kapasite (3) ve (5) numaralı denklemler kullanılarak,

$$\bar{C}_{x_1} = \frac{1}{2} \log_2(1 + \min(\gamma_{R,1}, \gamma_1)) \quad (6)$$

ile hesaplanmaktadır. Gerekli temel matematiksel işlemlerin ardından, S ve  $CU_1$  arasındaki yaklaşık ergodik kapasite,

$$\bar{C}_{x_1}^{yaklaşık} \sim \frac{1}{2 \ln(2)} \left( \frac{A}{A - B} \left( \left( \frac{An}{B} - n \right) (E_c + \ln(n)) - \left( \frac{An}{B} + 1 \right) \ln \left( \frac{B}{A} \right) \right) \right) \quad (7)$$

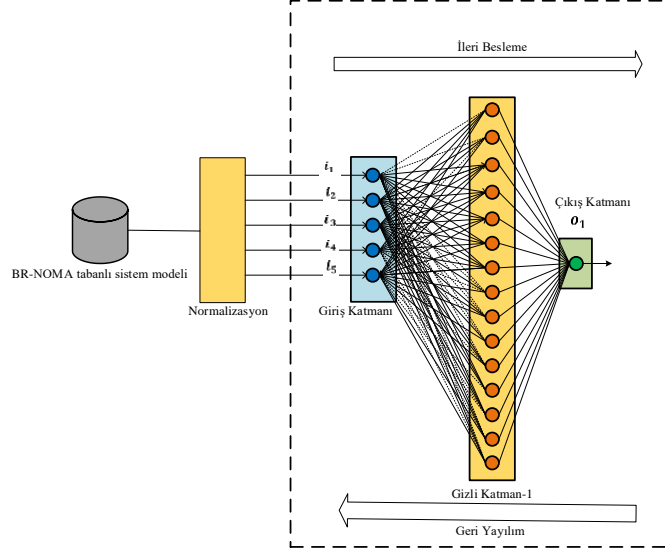
şeklinde elde edilmektedir. Burada,  $E_c$  Euler sabiti olarak tanımlanmaktadır (Gradshtey ve Ryzhik, 2007)

### 3. YSA VE NARX AĞLARI İÇİN ÖNERİLEN METOT

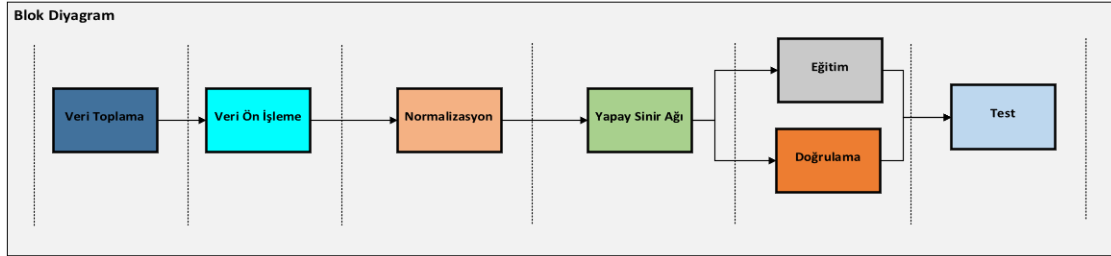
Bu çalışmada, gelecek nesil telsiz haberleşme uygulamalarının yoğun kullanımı ile ortaya çıkacak olan hız ihtiyacına cevap verilmesi, kapasite talebinin karşılanması, güvenilirlik gerektiren uygulamalar için düşük gecikme süresi gereksinimlerinin sağlanması amacıyla, 5G ve ötesi yeni nesil kablosuz haberleşme sistemlerinde kullanılabilecek aşağı yönlü BR-NOMA sisteminin yakın kullanıcıya ait ergodik kapasite değerinin farklı yapay sinir ağları ile kestirimine yönelik, ileri beslemeli geri yayımlı YSA ve NARX sistem modeli önerilmiştir.

Veri toplama sürecinde, ileri beslemeli geri yayımlı YSA'da ve NARX sinir ağında kullanılacak olan eğitim, doğrulama ve test için kullanılacak olan veriler röle yardımcı aşağı yönlü BR-NOMA tabanlı sistem modelinden elde edilmiştir. Veri ön işleme aşamasında, veri seti içerisinde yer alan değerlerden aşırı sapmaya uğramış olan aykırı değerler tespit edilmiş ve veri

temizleme işlemi gerçekleştirilmiştir. Elde edilen veriler, çeşitli değer aralıklarındaki salınımları ölçeklendirmek ve modelin performansı artırmak amacıyla normalizasyon işlemi ile ölçeklendirilmiştir. Ölçeklendirilen değerler Şekil 2’de verilen sinir ağına eğitilmiştir. Eğitim işlemi sonrasında geliştirilen model performansını değerlendirmek için doğrulama ve test aşaması gerçekleştirilmiştir. Sinir ağına ait blok diyagramı Şekil 3’te görülmektedir.



**Şekil 2:**  
İleri beslemeli geri yayımlı yapay sinir ağı modeli.



**Şekil 3:**  
Yapay sinir ağı tahmin algoritması blok diyagramı.

Girdi verisi; güç paylaşım katsayısı  $i_1$ , BA-röle arası uzaklığın, kaynak-röle arası uzaklığına oranı  $i_2$ , yol kaybı katsayısı  $i_3$ , ikinci kullanıcıya ait güç değerinin, BK'ya ait güç değerine oranı  $i_4$  ve yakın kullanıcıya ait SNR  $i_5$  değerlerinden oluşmaktadır. Çıktı verisi, toplam ergodik kapasite  $o_1$  değeridir. Girdi ve çıktı değer aralıklarına ilişkin detaylar Tablo 1’de verilmektedir.

**Tablo 1. Yapay Sinir Ağı Girdi ve Çıktı Parametreleri.**

Girdi ve Çıktı İfadeleri	Açıklama	Girdi ve Çıktı Değerleri	Veri Aralığı
$i_1$	Güç paylaşım katsayısı	$a_1$	[0,2-0,8]
$i_2$	BA-röle arası uzaklığın, kaynak-röle arası uzaklığına oranı	$d_{PR}/d_{SR}$	[1,25:4,25]
$i_3$	Yol kaybı katsayısı	$\tau$	[2,2-4,7]
$i_4$	İkinci kullanıcıya ait güç değerinin, birinci kullanıcıya ait güç değerine oranı	$P_{sec}/P_{pri}$	[1-3]
$i_5$	Yakın kullanıcıya ait SNR	$\min(\gamma_{R,1}, \gamma_1)$	[0-50]
$o_1$	Toplam ergodik kapasite	$C$	

Veri seti içerisinde yer alan veriler, ağı aşırı öğrenme ve eksik öğrenmeye uğramaması, eğitim verisi ile öğretilen modelin doğrulama ve test verisi olarak ayrılan veri ile test edilerek tahmin performansının artırılması amacıyla %70 eğitim, %15 doğrulama ve %15 test aşamasında kullanılmak üzere rastgele olarak ayrılmıştır. Veri setinde; 7473 eğitim, 1601 doğrulama ve 1601 test kullanılmak üzere toplam 10675 adet veri bulunmaktadır. Veri setine ilişkin detaylar Tablo 2’de verilmektedir.

**Tablo 2. Veri Seti Dağılım Oranı.**

	Veri seti bölme oranı	Veri Sayısı
<b>Training (Eğitim)</b>	% 70	7473
<b>Validation (Doğrulama)</b>	% 15	1601
<b>Test</b>	% 15	1601
<b>Toplam</b>	% 100	10675

### 3.1. Yapay Sinir Ağları

YSA, temel olarak birbirine nöron adı verilen paralel sinaptik ağırlıklarla birbirine bağlanan bloklardan oluşmaktadır. YSA, dışarıdan gelen bilgileri bir toplama fonksiyonuna tâbi tutarak toplam sonucunu aktivasyon fonksiyonundan geçirmesi ile çıktı değerini elde etmektedir. Elde edilen çıktı değeri, ağı sahip olduğu bağlantılar üzerinden diğer bloklara gönderilir. Bloklar arasındaki her bağlantının bir ağırlık değeri vardır. YSA’nın sahip olduğu bu bilgi, bu ağırlık değerlerinde saklı olup tüm ağı yayılmaktadır (Seyman ve Taspınar, 2013). Öğrenme, ilişkilendirme, genelleme ve optimizasyon gibi çalışmalarda oldukça başarı gösteren YSA, en genel formda, giriş katmanı, gizli katman ve çıkış katmanı olmak üzere birbirine paralel 3 katmanın bir araya gelerek oluşturduğu bir ağı yapısıdır. Giriş katmanı, öğrenilmesi istenen verilerin ağı girdi olarak verildiği katmandır. Gizli katman veya katmanlar (Hidden Layers), giriş katmanı ile çıkış katmanı arasında yer alan, problemin karmaşıklığına göre katman ve nöron sayısının değişebildiği ve hesaplamaların ileri yönlü, hataların ise geri yönlü yayılım yapıldığı katmandır (Sendonaris ve diğ., 1998). Çıkış katmanı ise, yapay sinir ağlarının girdi verilerine gösterdiği tepkidir. Ağı verilen girdiler için doğru çıktılar üretebilmesi, ağırlık değerlerinin tekrar tekrar ayarlanarak sistemin öğrenmesi ile mümkün olmaktadır. Derin Öğrenme (Deep Learning) yöntemleri en temel anlamda ağı verilecek Denetimli Öğrenme (Supervised Learning), Denetimsiz Öğrenme (Unsupervised Learning) ve Pekiştirmeli Öğrenme (Reinforcement Learning) yöntemlerine dayanmaktadır. Denetimli öğrenme yöntemi ile sınıflandırma (Classification) ve tahminleme (Regression) problemlerine, denetimsiz öğrenme yöntemi ile kümeleme (Clustering) problemlerine çözüm üretilmektedir. Pekiştirmeli öğrenme yöntemi,

denetimli ve denetimsiz öğrenme yönteminin aksine YSA ağına herhangi bir girdi verisi verilmeksizin ödül, ceza ilişkisine dayalı çevre ve model etkileşimi ile ağı öğrenilmesi gerçekleştirilmektedir (Naemm ve diğ., 2020).

Bu çalışmada, doğrusal olmayan problemlere verdikleri başarılı tahmin değerlerinden dolayı ileri beslemeli geri yayımlı YSA ve doğrusal olmayan otoregresif dışsal ağ modeli kullanılmıştır. Giriş katmanında 5 nöron, birinci gizli katmanda 15 nöron ve çıkış katmanı bir nöron olarak tasarlanan YSA’da denetimli öğrenme gerçekleştirilmek üzere ağa tanıtılan veri seti BR-NOMA tabanlı sistem modelinden üretilmiştir. Giriş katmanı, YSA’da eğitilecek olan girdi değerlerini gizli katmanlara aktarmaktadır. Eğitim ve öğrenme süreci gizli katmanlar ile gerçekleştirilen YSA’da, çıkış katmanı ile yakın kullanıcıya ait maksimum ergodik kapasite tahmini yapılmıştır. Tasarlanan YSA geri yayılım algoritması ile her iterasyon için nöronlara gelen ağırlıklar güncellenerek, global minimuma ulaşılmıştır. Eğitim fonksiyonu olarak Levenberg-Marquardt, Bayesian ve Scaled-Conjugate algoritması kullanılmıştır. Veri setinde yer alan çeşitli değer aralıklarındaki verilerin, salımlarını  $[0,1]$  aralığında ölçeklendirmek ve modelin performansını artırmak amacıyla normalizasyon işlemi yapılmıştır. Normalizasyon işleminde, max-min normalizasyon fonksiyonu kullanılmıştır. Ağı performansının değerlendirilmesi için, gerçek değerler ile tahmin edilen değerler arasındaki ilişkiyi anlamlandırmak amacıyla performans fonksiyonu olarak ortalama karesel hata (Mean Square Error, MSE), fonksiyonu kullanılmıştır. Tasarlanan YSA Levenberg-Marquardt, Bayesian ve Scaled-Conjugate algoritmalarına ait ağ tipi, katman sayısı, nöron sayısı ve hiperparametlere ilişkin değerler Tablo 3’te sunulmaktadır.

**Tablo 3. YSA Eğitim Parametreleri.**

YSA Parametreleri			
Parametre	Levenberg-Marquardt	Bayesian	Scaled-Conjugate
Ağ Tipi	İleri beslemeli geri yayımlı ağ	İleri beslemeli geri yayımlı ağ	İleri beslemeli geri yayımlı ağ
Data Bölüm İşlemi	Rastgele	Rastgele	Rastgele
Performans Fonksiyonu	Ortalama karesel hata	Ortalama karesel hata	Ortalama karesel hata
Öğrenme Fonksiyonu	Gradyan iniş ağırlığı ve taraflılık öğrenme fonksiyonu	Gradyan iniş ağırlığı ve taraflılık öğrenme fonksiyonu	Gradyan iniş ağırlığı ve taraflılık öğrenme fonksiyonu
Öğrenme Oranı	0,001	0,001	0,001
Öğrenme Süresi	2 sn	13 sn	4 sn
Epoch	32/1000	497/1000	160/1000
Normalizasyon	max-min	max-min	max-min
Girdi Katmanı Nöron Sayısı	5	5	5
Çıktı Katmanı Nöron Sayısı	1	1	1
Gizli Katman Sayısı	1	1	1
Gizli Katman-1 Nöron Sayısı	15	15	15

### 3.2. Doğrusal Olmayan Otoregresif Dışsal Model (NARX)

NARX ağı, doğrusal olmayan çok çeşitli dinamik problemlere verdikleri yüksek tahmin oranlarından dolayı sıklıkla kullanılan geri yayımlı tekrarlayan YSA modelidir (Tatlı ve diğ., 2017). NARX ağları, çok katmanlı algılayıcı yapılarına ek olarak çıkış katmanından elde edilen



sonucun giriş katmanına tekrardan besleme olarak verilmesi ile modellenen ağ yapılarıdır (Boussaada ve diğ., 2018). NARX ağları zaman serilerinde tahminleme problemlerinde kullanılan ARX tabanlı bir yöntemdir. NARX ağlarının matematiksel ifadesi seri ve paralel mimariler için iki ayrı eşitlikle ele alınmaktadır (19). Seri mimari Eşitlik (8)'de, paralel mimari Eşitlik (9)'da verilmektedir. Burada,  $F(\cdot)$  sinir ağına haritalama fonksiyonunu,  $\tilde{y}(t+1)$ ,  $t+1$  zamanı için  $t$  anındaki çıkış değerini,  $y(t), y(t-1), \dots, y(t-n_y)$  zaman serisinin geçmiş değerlerini,  $x(t+1), x(t), \dots, x(t-n_x)$  NARX'in giriş değerlerini,  $n_x$  giriş gecikmesini ve  $n_y$  çıkış gecikmesini göstermektedir.


$$\tilde{y}(t+1) = F(y(t), y(t-1), \dots, y(t-n_y), x(t+1), x(t), x(t-1), \dots, x(t-n_x)) \quad (8)$$

$$\tilde{y}(t+1) = F(\tilde{y}(t), \tilde{y}(t-1), \dots, \tilde{y}(t-n_y), x(t+1), x(t), x(t-1), \dots, x(t-n_x)) \quad (9)$$

Zaman serisi modelleme yöntemlerinden olan NARX modelinde geçmiş değerler ile seriye etkisi olduğu düşünülen harici diğer veriler, regresyon işlemine dahil edilerek tahminleme yapılmaktadır. NARX modeli en temel anlamda Şekil 4'te yer alan blok diyagramı ile gösterilebilir. NARX modeline denetimli öğrenme gerçekleştirilmek üzere ağa tanıtılan veri seti BR-NOMA tabanlı sistem modelinden üretilmiştir. Eğitim fonksiyonu olarak Levenberg-Marquardt, Bayesian ve Scaled Conjugate algoritması kullanılmıştır. Veri setinde yer alan çeşitli değer aralıklarındaki verilerin, salınımlarını [0-1] aralığında ölçeklendirmek ve modelin performansını artırmak amacıyla normalizasyon işlemi max-min fonksiyonu kullanılarak yapılmıştır. Ağın performansının değerlendirilmesi için, gerçek değerler ile tahmin edilen değerler arasındaki ilişkiyi anlamlandırmak amacıyla performans fonksiyonu olarak ortalama karesel hata (MSE) fonksiyonu kullanılmıştır. Tasarlanan NARX ağında Levenberg-Marquardt, Bayesian ve Scaled-Conjugate algoritmalarına ait ağ tipi, katman sayısı, nöron sayısı, gecikme değeri ve hiperparametrelere ilişkin değerler Tablo 4'te gösterilmektedir.

**Tablo 4. NARX Eğitim Parametreleri.**

NARX Parametreleri			
Parametre	Levenberg-Marquardt	Bayesian	Scaled-Conjugate
Ağ Tipi	İleri beslemeli geri yayımlı ağ	İleri beslemeli geri yayımlı ağ	İleri beslemeli geri yayımlı ağ
Data Bölüm İşlemi	Rastgele	Rastgele	Rastgele
Performans Fonksiyonu	Ortalama karesel hata	Ortalama karesel hata	Ortalama karesel hata
Öğrenme Fonksiyonu	Gradyan iniş ağırlığı ve taraflılık öğrenme fonksiyonu	Gradyan iniş ağırlığı ve taraflılık öğrenme fonksiyonu	Gradyan iniş ağırlığı ve taraflılık öğrenme fonksiyonu
Öğrenme Oranı	0,001	0,001	0,001
Öğrenme Süresi	3 sn	222 sn	1 sn
Epoch	27/1000	1000/1000	106/1000
Gecikme	5	5	5
Normalizasyon	max-min	max-min	max-min
Girdi Katmanı Nöron Sayısı	5	5	5
Çıktı Katmanı Nöron Sayısı	1	1	1
Gizli Katman Sayısı	1	1	1
Gizli Katman-1 Nöron Sayısı	15	15	15



**Şekil 4:**  
NARX ağ modeli.

#### 4. YSA ve NARX AĞ MODELLERİNİN PERFORMANS KARŞILAŞTIRMASI

Bilişsel ağlar için röle destekli aşağı yönlü NOMA haberleşme sistem modelinden elde edilen yakın kullanıcıya ait ergodik kapasitesi değerinin ileri beslemeli geri yayımlı YSA ve NARX yapıları ile tahminine ilişkin, Levenberg-Marquardt, Bayesian, Scaled-Conjugate öğrenme algoritmaları performans karşılaştırmasının sunulduğu bu bölümde, eğitim, doğrulama ve test veri seti girdileri için regresyon analizi, hata histogram grafikleri, en uygun epok değeri ele alınmaktadır. Eğitim işlemi için, rastgele bölünecek şekilde 7473 veri YSA'ya girdi olarak verilmiştir. Önerilen aşağı yönlü BR-NOMA sistem modeline göre tanımlanan parametreler, girdi veri seti yol kaybı katsayısı ( $\tau$ ), güç paylaşım katsayısı ( $a_1$ ), yakın kullanıcıya ait SNR  $\min(\gamma_{R,1}, \gamma_1)$ , kaynak-röle-hedef arasındaki uzaklık ve İK'ya ait güç değerinin, BK'ya ait güç değerine oranından ( $P_{sec}/P_{pri}$ ) oluşmaktadır.

Çıktı değeri olarak etiketlenmiş olan ergodik kapasite ( $C$ ) değeri YSA'ya tanıtılmıştır. İlave olarak sistem, tüm eğitim algoritmalarında kullanılan ileri beslemeli geri yayımlı YSA modeli bir gizli katmanda 15 nörona sahip olarak tasarlanmıştır. Aynı zamanda, NARX tekniği ile kullanılan tüm eğitim algoritmaları bir gizli katmanda 15 nörona sahip ve gecikme katsayısı 5 seçilerek modellenmiştir.

İleri beslemeli geri yayımlı YSA sinir ağı, Levenberg-Marquardt (LM) eğitim algoritması ile eğitildiğinde eğitim verisi için gerçek kapasite değerleri ile tahmin edilen kapasite değerleri arasındaki hata değeri 0,95934, doğrulama verisi için hata değeri 0,9583 ve test verisi için hata değeri 0,95511 olarak bulunmuştur. Bayesian eğitim algoritması ile eğitildiğinde gerçek kapasite değerleri ile tahmin edilen kapasite değerleri arasındaki hata değeri 0,96581, test verisi için hata değeri 0,96085 ve Scaled-Conjugate (SC) eğitim algoritması ile eğitildiğinde eğitim verisi için hata değeri 0,96007, doğrulama verisi için hata değeri 0,95081 ve test verisi için hata değeri 0,92068 olarak elde edilmiştir. NARX sinir ağı ile Levenberg-Marquardt eğitim verisi için gerçek kapasite değerleri ile tahmin edilen kapasite değerleri arasındaki hata değeri 0,95839, doğrulama verisi için hata değeri 0,95335 ve test verisi için hata değeri 0,95511, Bayesian eğitim algoritması eğitim verisi hata değeri 0,96225, test verisi hata değeri 0,95041 ve Scaled-Conjugate eğitim algoritması ile eğitildiğinde eğitim verisi için hata değeri 0,94073, doğrulama verisi için hata değeri 0,9255 ve test verisi için hata değerinin 0,9368 sonucuna ulaşılmıştır.

İleri beslemeli geri yayımlı YSA sinir ağı için eğitim işlemi Levenberg-Marquardt eğitim algoritması ile 2 saniyede, Bayesian eğitim algoritması ile 13 saniyede ve Scaled-Conjugate algoritması ile 4 saniyede, NARX sinir ağı ile eğitim işlemi Levenberg-Marquardt eğitim algoritması ile 3 saniyede, Bayesian eğitim algoritması ile 222 saniyede ve Scaled-Conjugate algoritması ile 1 saniyede tamamlanmıştır. İleri beslemeli geri yayımlı YSA sinir ağı için Levenberg-Marquardt eğitim algoritması ile eğitim 32 epokta, Bayesian eğitim algoritması ile 497 epokta ve Scaled-Conjugate algoritması ile 160 epokta tamamlanmıştır. Öte yandan NARX sinir ağı kullanılarak Levenberg-Marquardt eğitim algoritması ile eğitim 27 epokta, Bayesian

eğitim algoritması ile 1000 epokta ve Scaled-Conjugate eğitim algoritması ile 106 epokta tamamlanmıştır. NARX ve ANN ağına ilişkin öğrenme süresi, epok, eğitim, doğrulama ve test verisi doğruluğu Tablo 5'te verilmektedir.

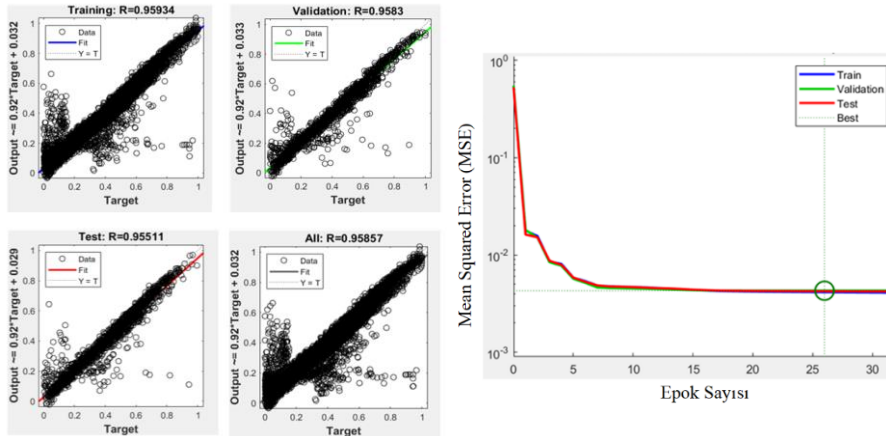
**Tablo 5. YSA ve NARX Performans Karşılaştırması.**

Parametre	YSA			NARX		
	LM	Bayesian	SC	LM	Bayesian	SC
Öğrenme Süresi (sn)	2	13	4	3	222	1
Epok	32	497	160	27	1000	106
Eğitim Verisi Doğruluğu	0,95934	0,96581	0,96007	0,95839	0,96226	0,94073
Doğrulama Verisi Doğruluğu	0,95830	UD	0,95081	0,95335	UD	0,92550
Test Verisi Doğruluğu	0,95511	0,96085	0,92068	0,95397	0,95041	0,93680

#### 4.1. Levenberg-Marquardt Algoritması


Levenberg-Marquardt eğitim algoritması ile eğitilen YSA'ya ilişkin eğitim, doğrulama ve test verisi regresyon analizi Şekil 5'te verilmektedir. YSA'nın eğitimi sonrasında eğitim verisi için gerçek kapasitesi değerleri ile tahmin edilen kapasite değerleri arasındaki hata değerinin 0,95934, doğrulama verisi için hata değerinin 0,9583 ve test verisi hata değeri 0,959511 olarak elde edilmiştir. Regresyon analizinde eğitim ve test verisi arasındaki korelasyon incelendiğinde YSA'nın eksik öğrenmeye (underfitting) ve aşırı öğrenmeye (overfitting) uğramadığı görülmektedir. İleri beslemeli geri yayımlı YSA 32 epok sonucunda eğitilmiştir. Eğitim işlemi sonucunda en optimum hata değeri 26. epokta elde edilmiştir.

YSA için ortalama kare hatası performansı ve aykırı değerler Şekil 6'da hata histogram analizinde ele alınmaktadır. Grafikte mavi ile gösterilen kısımlar eğitim hatasını, yeşil ile gösterilen kısımlar doğrulamayı ve kırmızı ile gösterilen kısımlar ise test hatasını ifade etmektedir. Hatanın -0,0715 ile 0,07313 arasında yoğunlaştığı grafik üzerinde görülmektedir. Eğitim istatistikleri incelendiğinde, gradient değerinin 26. epokta 0,000837 değerinde yerel minimum alt sınır değerine ulaştığı görülmektedir. 26. epoktan sonra hata değerinin arttığı gözlemlenmektedir.



**Şekil 5:**

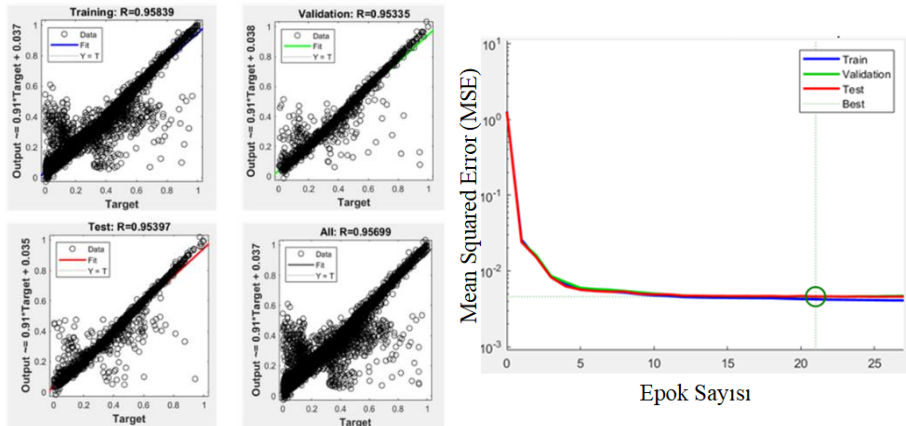
Levenberg-Marquardt eğitim algoritması ile eğitilen tek gizli katman 15 nöronlu YSA, eğitim, doğrulama ve test verisi regresyon analizi ve en uygun epok değeri.



**Şekil 6:**

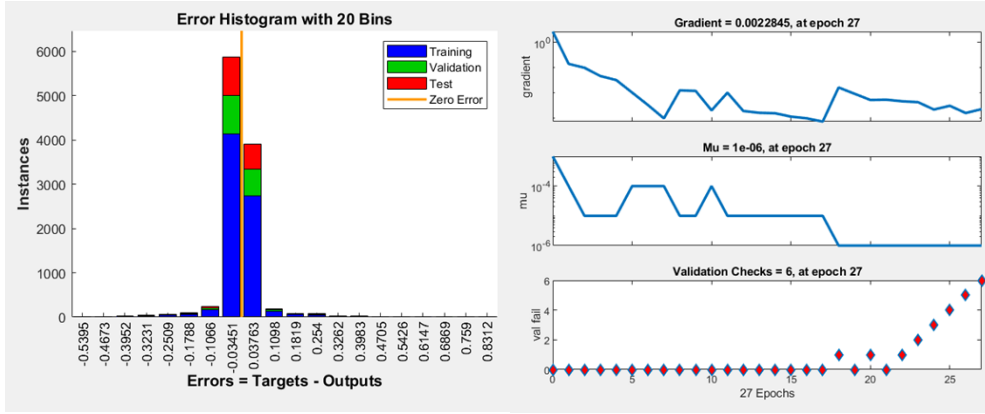
*Levenberg-Marquardt eğitim algoritması ile eğitilen tek gizli katman 15 nöronlu YSA, hata histogram analizi ve eğitim durum grafiği.*

NARX ile modellenen Levenberg-Marquardt eğitim algoritması kullanılarak eğitilen ağa ilişkin eğitim, doğrulama ve test verisi regresyon analizi Şekil 7’de sunulmaktadır. Eğitim sonucunda eğitim veri seti için gerçek kapasitesi değerleri ile tahmin edilen kapasite değerleri arasındaki hata değerinin 0,95839, doğrulama verisi hata değerinin 0,95335 ve test verisi hata değeri 0,95397 olarak elde edilmiştir. Regresyon analizinde eğitim ve test verisi arasındaki korelasyon incelendiğinde NARX ağının eksik öğrenmeye ve aşırı öğrenmeye uğramadığı görülmektedir. NARX ağı, 27 epok sonucunda eğitilmiş ve en optimum hata değeri 21. epokta elde edilmiştir. NARX ağının ortalama karesel hatası performansı ve aykırı değerler Şekil 8’de ele alınmaktadır. Grafikte mavi ile gösterilen kısımlar eğitim hatasını, yeşil ile gösterilen kısımlar doğrulamayı ve kırmızı ile gösterilen kısımlar test hatasını ifade etmektedir. Hatanın, -0,03451 ile 0,03763 arasında yoğunlaştığı ve gradient değerinin 21. epokta 0,00228 değerinde yerel minimum alt sınır değerine ulaştığı görülmektedir.



**Şekil 7:**

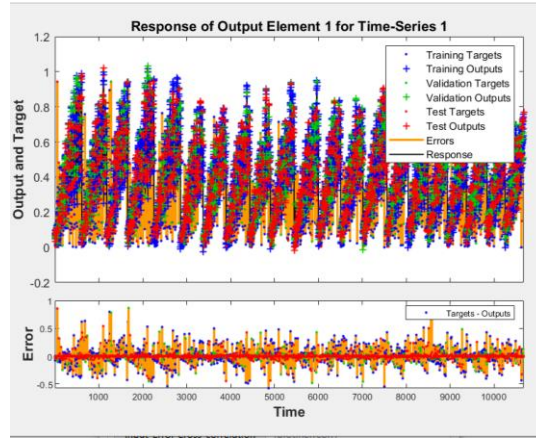
*Levenberg-Marquardt eğitim algoritması ile eğitilen 1 gizli katmanlı 15 nöron, gecikme=5 değerine sahip NARX sinir ağı eğitim, doğrulama ve test verisi regresyon analizi ve en uygun epok değeri.*



**Şekil 8:**

*Levenberg-Marquardt eğitim algoritması ile eğitilen 1 gizli katmanlı 15 nöron, gecikme=5 değerine sahip NARX sinir ağı eğitim verisi hata histogram analizi ve eğitim durum grafiği.*

Gerçek ergodik kapasite değeri ve Levenberg-Marquardt eğitim algoritması ile eğitilen NARX ağının ürettiği ergodik kapasite değerinin, eğitim, doğrulama ve test değerlerinin zaman içerisindeki hata değerinin bulunduğu response grafiği Şekil 9’da verilmektedir. Grafikte, mavi noktalar eğitim hedef çıktı değerini, mavi artı işareti eğitim çıktı değerini, yeşil noktalar doğrulama hedef çıktı değerini, yeşil artı işareti doğrulama çıktı değerini, kırmızı noktalar test hedef çıktı değerini, kırmızı artı işareti test çıktı değerini, turuncu çizgi hata değerini ve kırmızı çizgi response değerini ifade etmektedir. Zaman-hata grafiğinden, hata değerinin, -0,5 ile ~0.8 değeri arasında yayılım gösterdiği görülmektedir.

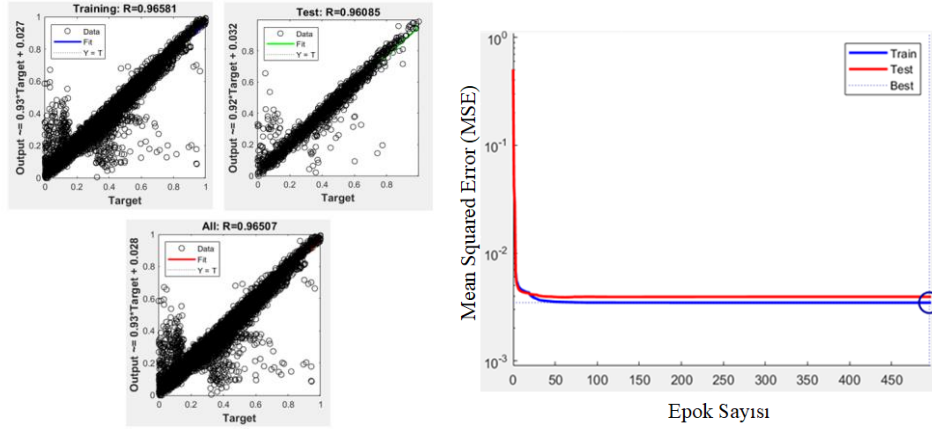


**Şekil 9:**

*Levenberg-Marquardt eğitim algoritması ile eğitilen 1 gizli katmanlı 15 nöron, delay=5 değerine sahip NARX sinir ağı response grafiği.*

#### 4.2. Bayesian Algoritması

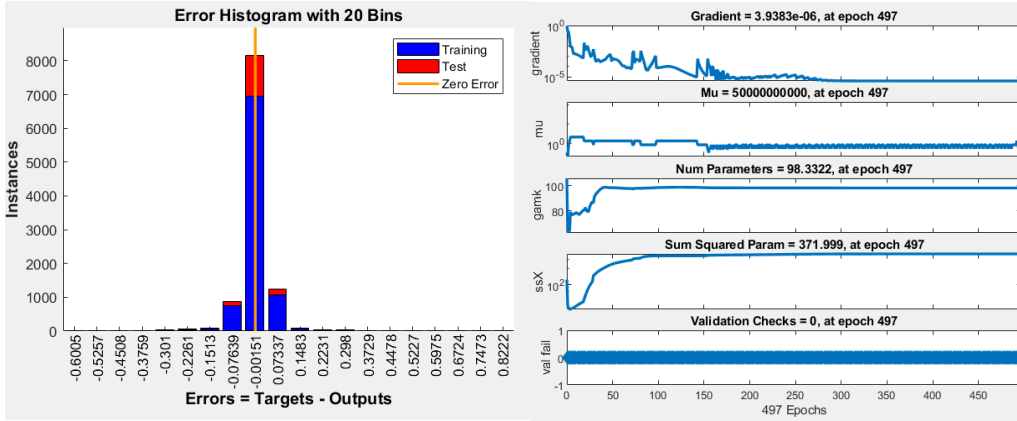
Bayesian eğitim algoritması ile eğitilen YSA’ya ilişkin eğitim verisi regresyon analizi Şekil 10’da verilmektedir. Eğitim işlemi için rastgele bölünecek şekilde 7473 veri YSA’ya girdi olarak verilmiştir. YSA’nın eğitimi sonrasında eğitim veri seti için gerçek kapasitesi değerleri ile tahmin edilen kapasite değerleri arasındaki hata değerinin 0,96581 doğrulama veri seti için hata değerinin 0,96058 ve test veri seti hata değerinin 0,96507 olarak elde edilmiştir. Regresyon analizinde eğitim ve test verisi arasındaki korelasyon incelendiğinde, YSA’nın eksik öğrenmeye ve aşırı öğrenmeye uğramadığı görülmektedir. İleri beslemeli geri yayımlı YSA 497 epok sonucunda eğitilmiş ve en optimum hata değeri 495. epokta elde edilmiştir.



**Şekil 10:**

Bayesian eğitim algoritması ile eğitilen tek gizli katman 15 nöronlu YSA, eğitim, doğrulama ve test verisi regresyon analizi ve en uygun epok değeri.

YSA, ortalama karesel hatası performansı ve aykırı değerler Şekil 11’de ele alınmaktadır. Grafikte mavi ile gösterilen kısımlar eğitim hatasını, kırmızı ile gösterilen kısımlar test hatasını ifade etmektedir. Hatanın -0,07639 ile 0,07337 arasında yoğunlaştığı ve gradient değerinin 495. epokta  $3,94 \cdot 10^{-6}$  değerinde yerel minimum alt sınır değerine ulaştığı gözlemlenmektedir.

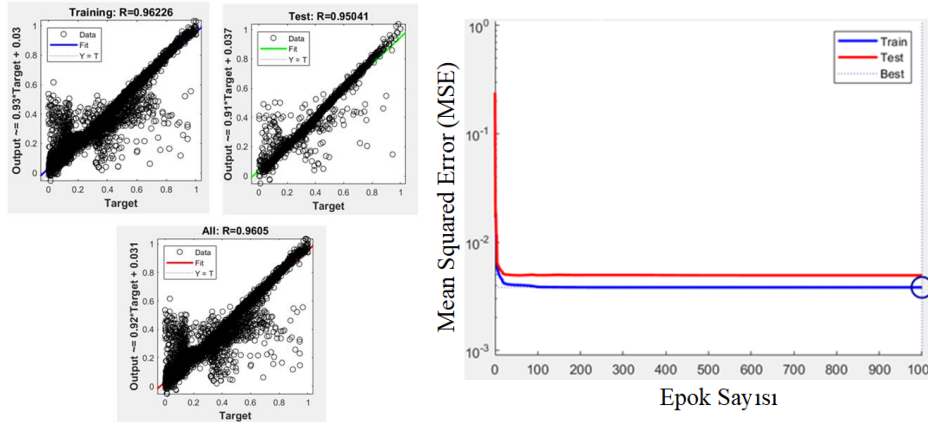


**Şekil 11:**

Bayesian eğitim algoritması ile eğitilen tek gizli katman 15 nöronlu YSA, hata histogram analizi ve eğitim durum grafiği.

NARX modellenen Bayesian eğitim algoritması kullanılarak eğitilen ağa ilişkin eğitim, doğrulama ve test verisi regresyon analizi Şekil 12’de verilmektedir. Eğitim sonucunda eğitim veri seti için gerçek kapasitesi değerleri ile tahmin edilen kapasite değerleri arasındaki hata değerinin 0,96226 ve test veri seti hata değeri 0,95041 olarak elde edilmiştir. Regresyon analizinde eğitim ve test verisi arasındaki korelasyon incelendiğinde, NARX ağının eksik öğrenmeye ve aşırı öğrenmeye uğramadığı görülmektedir. NARX ağı, 1000 epok sonucunda eğitilmiştir ve en optimum hata değeri 1000. epokta elde edilmiştir.






**Şekil 12:**

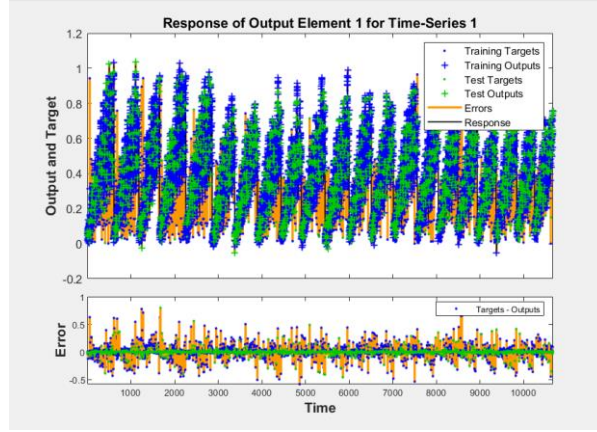
Bayesian eğitim algoritması ile eğitilen 1 gizli katmanlı 15 nöron, gecikme=5 değerine sahip NARX sinir ağı eğitim verisi regresyon analizi ve en uygun epok değeri.

NARX ağının ortalama kare hatası performansı ve aykırı değerler Şekil 13'te ele alınmaktadır. Grafikte mavi ile gösterilen kısımlar eğitim hatasını ve kırmızı ile gösterilen kısımlar test hatasını ifade etmektedir. Hatanın, -0,0644 ile 0,07362 arasında yoğunlaştığı ve gradient değerinin 1000. epokta  $2,62 \cdot 10^{-5}$  değerinde yerel minimum alt sınır değerine ulaştığı görülmektedir. Gerçek ergodik kapasite değeri ile Bayesian eğitim algoritması ile eğitilen NARX ağının ürettiği ergodik kapasite değerinin eğitim, doğrulama ve test değerlerinin zaman içerisindeki hata değerinin bulunduğu response grafiği Şekil 15'te verilmektedir. Zaman-hata grafiğinden hata değerinin, -0,5 ile ~0,8 değeri arasında yayılım gösterdiği görülmektedir.



**Şekil 13:**

Bayesian eğitim algoritması ile eğitilen 1 gizli katmanlı 15 nöron, gecikme=5 değerine sahip NARX sinir ağı hata histogram analizi ve eğitim durum grafiği.

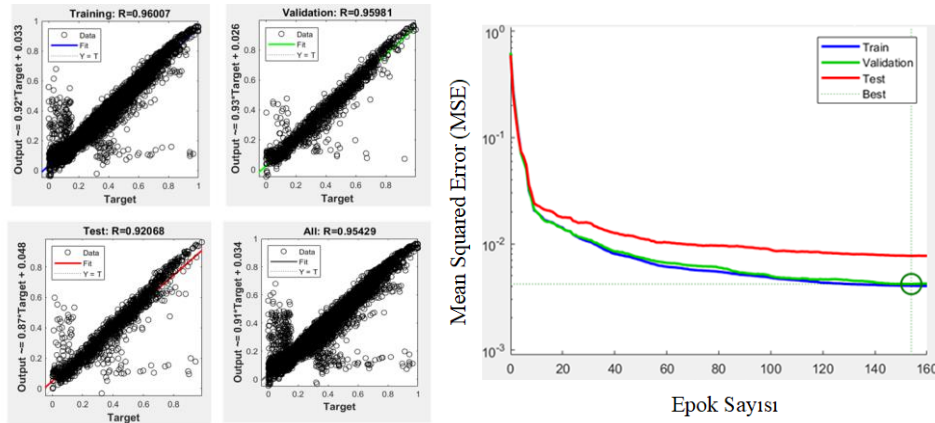


**Şekil 14:**

*Bayesian eğitim algoritması ile eğitilen 1 gizli katmanlı 15 nöron, gecikme=5 değerine sahip NARX sinir ağı response grafiği.*

#### 4.3.Scaled-Conjugate Algoritması

Scaled-Conjugate eğitim algoritması ile eğitilen YSA'ya ilişkin eğitim verisi regresyon analizi Şekil 15 kapsamında verilmektedir. Eğitim işlemi için rastgele bölünecek şekilde 7473 veri YSA'ya girdi olarak verilmiştir. YSA'nın eğitimi sonrasında eğitim veri seti için gerçek kapasitesi değerleri ile tahmin edilen kapasite değerleri arasındaki hata değerinin 0,96007, doğrulama veri seti hata değerinin 0,95981 ve test veri seti hata değeri 0,92068 olarak elde edilmiştir. Regresyon analizinde eğitim ve test verisi arasındaki korelasyon incelendiğinde, YSA'nın eksik öğrenmeye ve aşırı öğrenmeye uğramadığı görülmektedir. İleri beslemeli geri yayımlı YSA 160 epok sonucunda eğitilmiştir. Eğitim işlemi sonucunda en optimum hata değeri 154. epokta elde edilmiştir.



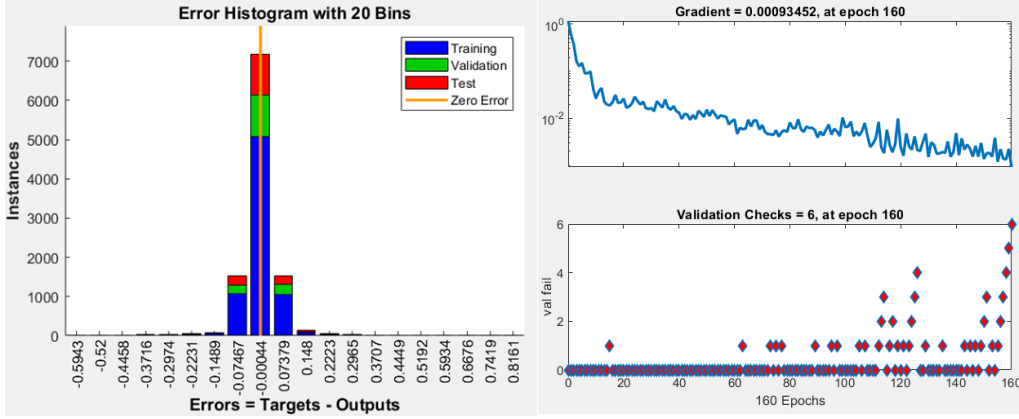
**Şekil 15:**

*Scaled-Conjugate eğitim algoritması ile eğitilen tek gizli katmanlı 15 nöronlu YSA için eğitim, doğrulama ve test verisi regresyon analizi ve en uygun epok değeri.*

YSA ortalama karesel hatası performansı ve aykırı değerler Şekil 16'da hata histogram analizinde ele alınmaktadır. Grafikte mavi ile gösterilen kısımlar eğitim hatasını, yeşil ile görülen kısımlar doğrulama hatasını ve kırmızı ile gösterilen kısımlar ise test hatasını ifade etmektedir.



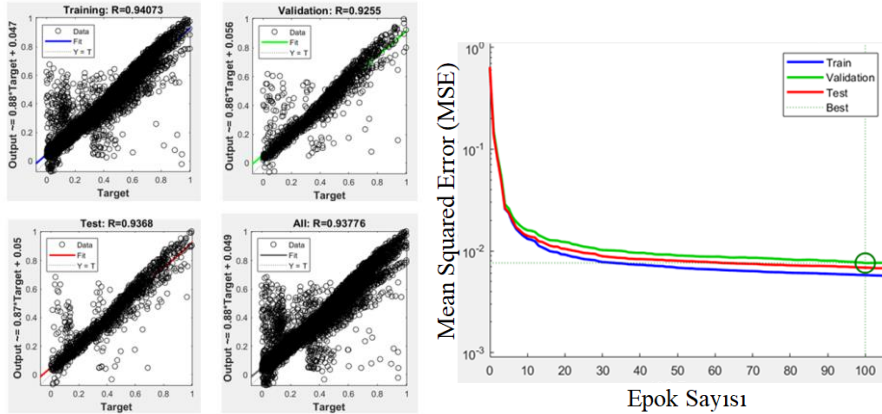
Hatanın,  $-0,07467$  ile  $0,07379$  arasında yoğunlaştığı grafik üzerinde görülmektedir. Eğitim istatistikleri incelendiğinde, gradient değerinin 154. epokta  $0,000935$  değerinde yerel minimum alt sınır değerine ulaştığı görülmektedir.



**Şekil 16:**

*Scaled-Conjugate eğitim algoritması ile eğitilen tek gizli katman 15 nöronlu YSA, hata histogram analizi ve eğitim durum grafiği.*

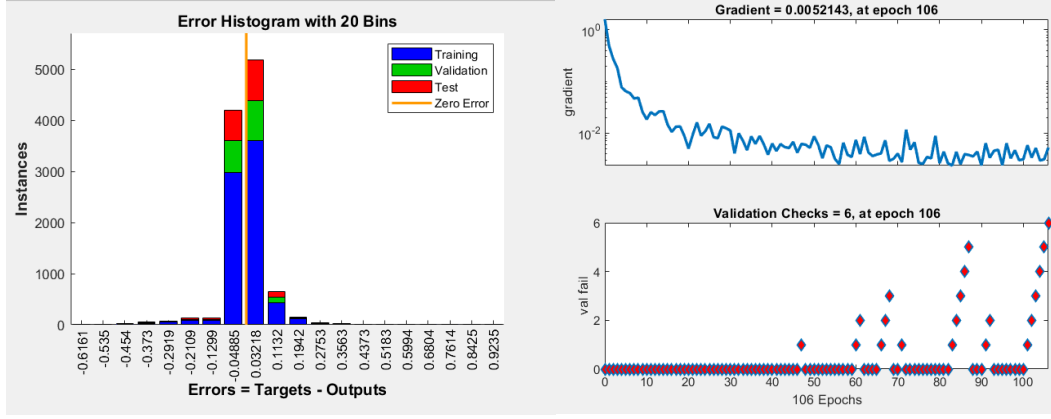
NARX ile modellenen Scaled-Conjugate eğitim algoritması kullanılarak eğitilen ağa ilişkin eğitim, doğrulama ve test verisi regresyon Şekil 17’de verilmektedir. Eğitim sonucunda eğitim veri seti için gerçek kapasitesi değerleri ile tahmin edilen kapasite değerleri arasındaki hata değeri  $0,94073$  doğrulama veri seti hata değeri  $0,9255$  ve test veri seti hata değeri  $0,9368$  olarak elde edilmiştir. Regresyon analizinde eğitim ve test verisi arasındaki korelasyon incelendiğinde NARX ağının aşırı öğrenmeye yakınsadığı görülmektedir. NARX ağı, 106 epok sonucunda eğitilmiştir. En optimum hata değeri 100. epokta elde edilmiştir.



**Şekil 17:**

*Scaled-Conjugate eğitim algoritması ile eğitilen 1 gizli katmanlı 15 nöron, gecikme=5 değerine sahip NARX sinir ağı eğitim verisi regresyon analizi ve en uygun epok değeri.*

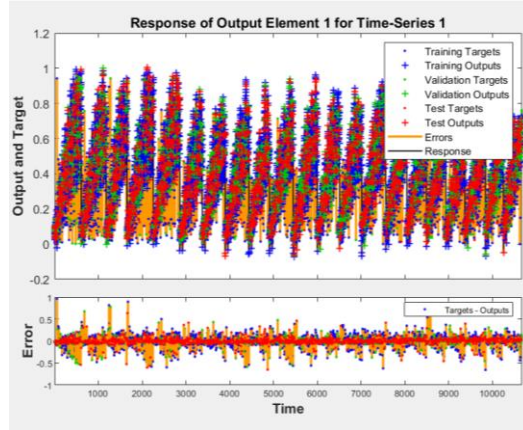
NARX ağının ortalama kare hatası performansı ve aykırı değerler Şekil 18’de hata histogram analizinde ele alınmaktadır. Grafikte mavi ile gösterilen kısımlar eğitim hatasını ve kırmızı ile gösterilen kısımlar test hatasını ifade etmektedir. Hatanın,  $-0,044885$  ile  $0,01132$  arasında yoğunlaştığı grafik üzerinde görülmektedir. Eğitim istatistikleri incelendiğinde, gradient değerinin 100. epokta  $0,00570$  değerinde yerel minimum alt sınır değerine ulaştığı görülmektedir.



**Şekil 18:**

*Scaled-Conjugate eğitim algoritması ile eğitilen 1 gizli katmanlı 15 nöron, gecikme=5 değerine sahip NARX sinir ağı hata histogram analizi ve eğitim durum grafiği.*

Gerçek ergodik kapasite değeri ile Bayesian eğitim algoritması ile eğitilen NARX ağının ürettiği ergodik kapasite değerinin eğitim, doğrulama ve test değerlerinin zaman içerisindeki hata değerinin bulunduğu response grafiği Şekil 19’da verilmektedir. Zaman-hata grafiğinden hata değerinin, -0,5 ile ~1 değeri arasında yayılım gösterdiği görülmektedir.



**Şekil 19:**

*Scaled-Conjugate eğitim algoritması ile eğitilen 1 gizli katmanlı 15 nöron, gecikme=5 değerine sahip NARX sinir ağı response grafiği.*

## 5. SONUÇLAR

Bu çalışmada, aşağı yönlü BR-NOMA sisteminde yakın kullanıcıya ait ergodik kapasite değerinin kestirimi için denetimli öğrenme yöntemi temelli ileri beslemeli geri yayımlı YSA ve NARX sinir ağları önerilmiştir. Kullanılacak olan etiketlenmiş girdi ve çıktı veri seti üstel sönümlenme kanalı karakteristiği ile modellenen BR-NOMA sistem modelinden elde edilmiştir. YSA ve NARX sinir ağları sistem başarımı değerlendirilirken ağın hızlı eğitim süresi, ağ karmaşıklığının az olması, epok sayısı, ağın aşırı öğrenme durumu ve ağın eksik öğrenme durumu dikkate alınmıştır. Gerçek ergodik kapasite değerleri ile ileri beslemeli geri yayımlı YSA ve NARX ağları ile tahmin edilen ergodik kapasite değerleri arasındaki hata değeri, eğitim, doğrulama ve test verisi için karşılaştırılmıştır. Sinir ağlarının Levenberg-Marquardt, Bayesian

ve Scaled-Conjugate eğitim algoritmaları altındaki performans analizi, hatanın minimuma ulaştığı epok değer grafiği, histogram analizi ve eğitim durum analizi incelenmiştir. Eğitim, doğrulama ve test performans analiz sonuçları incelendiğinde, ileri beslemeli geri yayılım YSA modelinin eğitim algoritmalarının hiperparametreleri için uygun olarak seçildiği, ağırlık aşırı öğrenme ve eksik öğrenmeye uğramadığı sonucuna ulaşılmıştır. İleri beslemeli geri yayımlı YSA modeli yakın kullanıcıya ait ergodik kapasite değerinin kestirimi en yüksek doğruluk oranı Bayesian algoritması ile elde edilmiştir. Ayrıca eğitim süreleri göz önüne alındığında, Levenberg-Marquardt algoritmasının modeli, Bayesian ve Scaled-Conjugate algoritmalarına göre hızlı eğittiği sonucuna ulaşılmıştır. NARX modelinde, yakın kullanıcıya ait ergodik kapasite değerinin kestirimi en yüksek doğruluk oranı, eğitim veri seti için Bayesian algoritması ile test veri seti için Levenberg-Marquardt algoritması ile elde edilmiştir. Bayesian algoritmasının, diğer algoritmalara göre çok yavaş eğitim gerçekleştirdiği sonucuna ulaşılmıştır. Doğrusal olmayan problemlere karşı verdiği başarılı sonuçlar, hızlı hesaplama süreleri ve işlem gücünü düşürmesinden dolayı ergodik kapasite kestiriminin en uygun sonucunun ileri beslemeli geri yayımlı YSA ile Levenberg-Marquardt eğitim algoritması ile elde edildiği sonucuna ulaşılmıştır. Bu eğitim algoritması ile ağırlık aşırı öğrenmeye uğramadığı, algoritmanın hızlı çalıştığı, eğitim veri seti için gerçek kapasite değerleri ile tahmin edilen kapasite değerleri arasındaki korelasyon incelendiğinde hata değerinin 0,95934, doğrulama veri seti hata değerinin 0,95830 ve test veri seti hata değerinin 0,95511 olarak elde edildiği tespit edilmiştir. Elde edilen sonuçlar incelendiğinde sinir ağı yöntemleri kullanılarak NOMA tabanlı bilişsel radyo haberleşme sistemlerinde kapasite kestirimi yapılabileceği sonucuna ulaşılmıştır.

## ÇIKAR ÇATIŞMASI

Yazarlar, bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

## YAZAR KATKISI

Mustafa Namdar tasarladı, makale yazımına destek verdi ve proje yürütücülüğü yaptı. Abdulkadir Güney programları oluşturdu, çözümü kurguladı ve makaleyi yazdı. Fatma Kebire Bardak makalenin yazımına destek verdi. Arif Başgümüş tasarladı, makale yazımına destek verdi ve şekilsel olarak makalenin son halini değerlendirdi. Yazarlar son halini okudu ve onayladı.

## KAYNAKLAR

1. Bardak, F. K. Namdar, M. and Basgumus A. (2021) Ergodic Capacity Analysis of the Relay Assisted Downlink NOMA Systems in Cognitive Radio Networks, *Journal of Engineering Sciences and Design*, 9(3), 992-1002, doi:10.21923/jesd.826084
2. Bardak, F.K., Namdar, M., ve Basgumus, A. (2020) Performance analysis of noma systems in relay-assisted cognitive radio networks, *28th Signal Processing and Comm. Applications Conference (SIU)*, Medipol Üniversitesi, İstanbul, doi:10.1109/SIU49456.2020.9302392
3. Bhatt, A., vd. (2022) Analysis of the Fifth Generation NOMA System using LSTM Algorithm, *Int. J. of Comp. and Digital Sys.*, 11(1), 1367-1376, doi:10.12785/ijcds/120119
4. Boussaada, Z., Curea, O., Ahmed, R., Najiba, M.B. (2018) A Nonlinear Autoregressive Exogenous (NARX) Neural Network Model for the Prediction of the Daily Direct Solar Radiation, *Energies*, 11(3), 620, doi:/10.3390/en11030620
5. Dai, L., vd. (2018) A Survey of Non-Orthogonal Multiple Access for 5G, *IEEE Comm. Surveys & Tutorials*, 20(3), 2294-2323, doi:10.1109/COMST.2018.2835558

6. Emir, A., Kara, F., ve Kaya H. (2022) CNN Aided Alternative Detector Design for Uplink and Downlink NOMA Communications Systems, *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 70(24), 341-349, doi:/10.21205/deufmd.2022247030
7. Gradshteyn, I. S., ve Ryzhik I. M. (2007) Table of integrals, series and products, *7th edn.*, Academic Press, New York.
8. Gui, G., vd. (2018) Deep Learning for An Effective Non-Orthogonal Multiple Access Scheme, *IEEE Trans. on Veh. Tech.*, 67(9), 8440-8450, doi:10.1109/TVT.2018.2848294
9. Lin, C., Chang, Q., ve Li, X. (2019) A Deep Learning Approach for MIMO-NOMA Downlink Signal Detection, *Sensors Journal*, 19(11), 2526, doi:10.3390/s19112526
10. Liu, M., Song, T., ve Gui, G. (2018) Deep Cognitive Perspective: Resource Allocation for NOMA based Heterogeneous IoT with Imperfect SIC, IEEE, *Internet of Things Journal*, 6(2), 2885-2894, doi:10.1109/JIOT.2018.2876152
11. Naeem, M., Rizvi, S.T.H., ve Coronato, A. (2020) A Gentle Introduction to Reinforcement Learning and its Application in Different Fields, *IEEE Access*, 8(0), 209320–209344, doi:10.1109/ACCESS.2020.3038605
12. Namdar, M., and Basgumus, A. (2017) Outage Performance Analysis of Underlay Cognitive Radio Networks with Decode-and-Forward Relaying, in *Cognitive Radio, London, United Kingdom: IntechOpen*, ISBN: 978-953-51-3338-4, 25-37, doi:10.5772/intechopen.69244
13. Namdar, M., and Ilhan, H. (2018) Exact Closed-Form Solution for Detection Probability in Cognitive Radio Networks with Switch-and-Examine Combining Diversity, *IEEE Transactions on Vehicular Technology*, 67(9), 8215-8222, doi:10.1109/TVT.2018.2840227
14. Narengerile, ve Thompson, J. (2019) Deep learning for signal detection in non-orthogonal multiple access wireless systems, *UK/ China Emerging Technologies (UCET)*, (1-4). Glasgow, UK, doi:10.1109/UCET.2019.8881888
15. Sendonaris, A., Erkip, E., ve Aazhang, B. (1998) Increasing uplink capacity via user cooperation diversity. *IEEE Int. Symposium on Information Theory*, (156), Cambridge, MA, United States, doi:10.1109/ISIT.1998.708750
16. Seyman, M.N. (2022) Symbol Detection Based on Back Tracking Search Algorithm in MIMO-NOMA Systems, *Computer Systems Science and Engineering*, 40(2), 795-804, doi:10.32604/csse.2022.019734
17. Seyman, M.N., ve Taspınar, N. (2013) Radial Basis Function Neural Networks for Channel Estimation in MIMO-OFDM Systems, *Arabian Journal for Science and Engineering*, 38(8), 2173-2178, doi:10.1007/s13369-013-0586-1
18. Sim, I., vd. (2020) Deep Learning Based Successive Interference Cancellation Scheme in Non Orthogonal Multiple Access Downlink Network, *Energies Journal*, 13(23), 6237, doi:10.3390/en13236237
19. Tatlı, A. and Kahvecioğlu S. (2017) Amount of Airworthiness Time Estimation Using TDNN Model in Time Series, *IATS2017: 8th Int. Advanced Technologies Symposium*.