



Analysis of Voltage Stability in IEEE 14-Bus Power System with Extreme Learning Machine

Hakan AÇIKGÖZ^{1,*}, İlhami POYRAZ², Resul ÇÖTELİ³

¹Kilis 7 Aralık University, Vocational School of Technical Sciences, Department of Electricity and Energy, 79000, KİLİS

²Dicle University, Vocational School of Technical Sciences, Department of Electricity and Energy, 21830, DİYARBAKIR

³Firat University, Faculty of Technology, Department of Energy Systems Engineering, 23000, ELAZIĞ

Graphical/Tabular Abstract

In this study, the voltage stability of the IEEE 14-bus power system has been investigated under the different load conditions with the help of the line stability index values by using extreme learning machine (ELM) algorithms. For this purpose, IEEE 14-bus power system model is built in Matlab environment. The load flow analysis of the model is performed by using Newton-Raphson method.

Article Info:

Received: 01/04/2019

Revision 29/05/2019

Accepted: 13/07/2019

Highlights

- Use of ELM for voltage stability.
- Load flow analysis with Newton-Raphson Method.
- Comparison of different types of activation functions

Keywords

ELM
Newton-Raphson Method
Line Stability Index
Load Flow Analysis




Figure A. IEEE 14-Bus System

Purpose: The voltage stability indices in IEEE 14-bus power system are estimated using ELM. With the help of the superior properties of ELM, it is aimed to predict the voltage faults in the system.

Theory and Methods: The parameters related to IEEE 14-bus system are obtained for load flow analysis. With the help of these values, the line stability index is calculated. Then, comparison is made using different activation functions.

Results: From the obtained regression and estimation curves, it is observed that ELM is predicted the line stability index value with high accuracy.

Conclusion: In this study, ELM is presented for stability analysis of IEEE 14-bus power system. To test the validity of the proposed method, simulation studies are realized using different activation functions. According to the realized studies, it has been shown that ELM has very successful results in determination of voltage stability.

GU J Sci, Part C, 7(3): 564-575 (2019)

Gazi Üniversitesi

Fen Bilimleri Dergisi

PART C: TASARIM VE TEKNOLOJİ

<http://dergipark.gov.tr/gujsc>

IEEE 14-Baralı Güç Sisteminde Gerilim Kararlılığının Uç Öğrenme Makinesi ile Analizi

Hakan AÇIKGÖZ^{1,*}, İlhami POYRAZ², Resul ÇÖTELİ³¹Kilis 7 Aralık Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektrik-Enerji Bölümü, 79000, KİLİS²Dicle Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektrik-Enerji Bölümü, 21830, DİYARBAKIR³Fırat Üniversitesi, Teknoloji Fakültesi, Enerji Sistemleri Mühendisliği Bölümü, 23000, ELAZIĞ

Öz

Günümüzde elektrik enerjisi ihtiyacı, teknolojik gelişmeler sonucunda nüfusla orantılı olarak hızla artmaktadır. Artan bu talebi karşılamak için büyük güçlü üretim merkezleri kurulmuştur. Bu çalışmada, IEEE 14-baralı güç sisteminde gerilim kararlılığı Uç Öğrenme Makinesi (UÖM) yardımıyla incelenmiştir. Bu amaçla, IEEE 14-baralı güç sistemi modeli Matlab ortamında oluşturulmuş ve bu model kullanılarak Newton-Raphson Yöntemi (NRY) yardımı ile yük akış analizi yapılmıştır. Bu güç sisteminde gerilim kararlılığı Hat Kararlılık İndeksi (HKİ) hesaplanarak değerlendirilmiştir. Yük akış analizinde tüm baraların aktif ve reaktif güçleri 0.05 birim değer (pu) artırılmış ve her bir baraya ait toplam 1000 adet aktif güç, reaktif güç, ilgili baranın gerilimi ve faz açısı elde edilmiştir. Bu değerler kullanılarak HKİ değerleri hesaplanmıştır. UÖM'ye girişler; aktif güç, reaktif güç, ilgili baranın gerilimi ve faz açısı seçilmiştir. UÖM'nin çıkışı ise HKİ değerleri olarak belirlenmiştir. UÖM'nin test başarımı 5-kat çapraz doğrulama ile verilmiştir. Ayrıca UÖM'nin başarımı farklı sayıda gizli katman hücre sayısı ve farklı tip aktivasyon fonksiyonları için incelenmiştir. Önerilen yöntemin en iyi test başarımı gizli katman hücre sayısı 100 olan ve tanjant sigmoid aktivasyon fonksiyonu kullanan UÖM'den elde edilmiştir. Elde edilen sonuçlardan, IEEE 14-baralı güç sistemlerinde gerilim kararlılığının tespitinde UÖM'nin HKİ'yi oldukça yüksek bir başarımla tahmin ettiği görülmüştür.

Makale Bilgisi

Başvuru: 01/04/2019

Düzeltilme: 29/05/2019

Kabul: 13/07/2019

Anahtar Kelimeler

Gerilim Kararlılığı
Uç Öğrenme Makinesi
Hat Kararlılık İndeksi

Keywords

Voltage Stability
Extreme Learning Machine
Line Stability Index

Analysis of Voltage Stability in IEEE 14-Bus Power System with Extreme Learning Machine

Abstract

Nowadays, electrical energy needs are increasing rapidly as a result of technological developments. In order to meet this growing demand, power plants have been built. In this study, voltage stability in IEEE 14-bus power system was investigated by means of Extreme Learning Machine (ELM). For this purpose, the IEEE 14-bus power system model was built in Matlab environment and load flow analysis for this model was performed by using the Newton-Raphson Method (NRM). In this power system, the voltage stability was evaluated by calculating the Line Stability Index (LSI). In the load flow analysis, the active and reactive powers of all bus were increased by 0.05 step (pu) and a total of 1000 active power, reactive power, voltage, and phase angle of the respective bus were obtained for each busbar. These values were used to calculate the values of LSI. The inputs of ELM are selected as active power, reactive power, voltage and phase angle of the respective bus. The output of the NRM was determined as LSI values. The test performance of the NRM is given by 5-fold cross-validation. In addition, the ELM's performance was investigated for the different number of hidden layer cell numbers and different types of activation functions. The proposed method provides the best test performance in case of ELM with a hidden layer cell number of 100 and the tangent sigmoid activation function. From the obtained results, it is seen that ELM predicted LSI with a very high performance in determination of voltage stability in IEEE 14-bus power systems.

1. GİRİŞ (INTRODUCTION)

Elektrik enerjisi, günümüzde en yaygın olarak kullanılan enerji türüdür. Enerji güç sistem planlayıcıları, minimum maliyet, sarfiyat ve tasarruf için her türlü araştırma ve geliştirmeyi yapmak zorundadır. Enerji güç sistemleri, sürekli değişen şartlarda çalışan doğrusal olmayan sistemlerdir. Yükler, generatör çıkışları ve sistem parametreleri sürekli değişir. Buna bağlı olarak da; doğrusal olmayan, zamanla değişen ve dinamik bir olgu olan gerilim kararlılığı analizi, güç sistemlerinin işletiminde önemli bir ölçüttür [1]. Bir güç sisteminin, en verimli, kabul edilebilir dengeli bir çalışma şartında bulunması ve bozulmaya maruz kaldıktan sonra da, yeniden kararlı ve dengeli bir duruma gelebilmesi için, sistemin gerilim kararlılığının incelenmesi ve değerlendirilmesi gerekir. Gerilim kararlılığı, bir güç sisteminin yük talebi ile üretilen ve yük merkezine iletilen güç arasındaki dengenin korunması yeteneğidir [2-3].

Gerilim kararlılık sınırının tahminini ne kadar doğru ve hızlı bir yöntemle sağlanırsa, sistem operatörü de gerekli kontrol eylemlerini o kadar doğru ve hızlı başlatır [4]. Literatürde güç sistemlerinde gerilim kararlılığı analizi için Karar Ağacı Tekniği [6] ve Bulanık Ağlar [7], Yapay Sinir Ağları (YSA) [8] gibi yapay zekâ tekniklerinin kullandığı yöntemler önerilmiştir. 1989'lardan sonra YSA enerji sistemlerinin birçok problemini çözmek için kullanılmaya başlamıştır [9]. İngiliz Enerji İletim Sistemlerinde YSA kullanılarak kararlılık analizlerinin çözümü gerçekleştirmiş ve YSA'nın pratik uygulamalarda da kullanılabilirliğini kanıtlanmıştır [10]. Bununla birlikte, YSA'ların öğrenme hızı gerekenden çok daha zaman alıcıdır. YSA'ların bu özelliği, uygulamalarında en önemli sınırlamadır. Bu durumun iki ana nedenden kaynaklandığı belirtilmiştir. Bunlardan biri sinir ağını eğitmek için kullanılan eğitim düşünüm tabanlı öğrenme algoritmasının yavaş olması ve bu öğrenme algoritması ile ağların parametrelerinin tekrarlı ayarlanmasıdır [11]. YSA'ların bu dezavantajlarını gidermek için, G. B. Huang tarafından tek katmanlı YSA'ların eğitimi için Uç Öğrenme Makinesi (UÖM) olarak bilinen yeni bir öğrenme algoritması önerilmiştir [12-13]. Hızlı öğrenme ve genelleme yapabilen UÖM'ler günümüzde güç sistemlerinde arıza yeri tespiti ve arıza sınıflandırma, rüzgâr gücünün tahmini ve yük tahmini gibi birçok alanda kullanılmaktadır [14-17]. YSA'ların eğitiminde kullanılan geleneksel öğrenme algoritmalarına göre UÖM tabanlı öğrenme algoritmasında sadece doğrusal çıkış denklemi çözülerek çıkış ağırlıkları hesap yolu ile bulunur. Ayrıca UÖM, geleneksel sınıflandırıcılara göre ağı eğitiminde kullanılan parametre sayısını indirger [14].


Bu çalışmada, IEEE 14-baralı güç sisteminde gerilim kararlılığı HKİ değerleri kullanılarak UÖM yardımı ile incelenmiştir. Bu amaçla, IEEE 14-baralı güç sistemi modeli MATLAB ortamında oluşturulmuş ve bu modelin yük akım analizi Newton-Raphson metodu kullanılarak gerçekleştirilmiştir. Yük akış analizinde tüm baraların aktif ve reaktif güç değerleri 0.05 birim değer (pu) artırılarak her bir bara için toplam 1000 adet aktif güç, reaktif güç, bara gerilimlerinin genliği ve ilgili gerilimin faz açısı elde edilmiştir. Elde edilen bu değerler kullanılarak Hat Kararlılık İndeksi (HKİ) hesaplanmıştır. IEEE 14-baralı güç sistemi modeli parametre değerlerinden elde edilen 1000 adet HKİ değeri, UÖM kullanılarak tahmin edilmiştir. UÖM algoritmasının girişleri; ilk gönderici baranın geriliminin genliği ve gerilimin faz açısı; son alıcı baranın reaktif gücü ve gerilimin faz açısı ve çıkışı HKİ değerleridir. UÖM'nin tahmin başarımı, gizli katmandaki hücre sayısı ve farklı tip aktivasyon fonksiyonları için incelenmiş ve elde edilen test sonuçları 5-çapraz doğrulama kullanılarak verilmiştir. Elde edilen sonuçlardan UÖM'nin HKİ değerini oldukça yüksek doğrulukta tahmin etmeyi başardığı görülmüştür. Çalışmanın diğer kısımları ise şu şekilde organize edilmiştir. Gerilim kararlılığı ile genel bilgiler 2.kısımda verilmiştir. 3. kısımda UÖM hakkında bilgiler sunulmuştur. 4. kısımda ise gerçekleştirilen çalışma ve bu çalışmadan elde edilen sonuçlar verilmiştir. Ayrıca, önerilen öğrenme makinası diğer yöntemlerle karşılaştırılmıştır. Sonuç kısmında ise önerilen yöntemden elde edilen bilgiler değerlendirilmiştir.

2. GERİLİM KARARLILIĞI (VOLTAGE STABILITY)

Modern güç sistemleri ileri seviyede planlanmış, çok değişkenli, dinamik sistemlerdir. Genel olarak, sistem parametrelerindeki bozulmalar, sistem elemanlarının farklı karakteristiklerde olmasından kaynaklanmaktadır [1]. Gerilim kararlılığı, aslında güç sisteminin, geniş bir alan içinde, ne kadar küçük veya büyük olduğu önemli olmayan bir bozulmaya maruz kaldıktan sonra, sistem değişkenlerini kabul edilebilir bir dengede sürdürebilme yeteneğidir [2-3]. Gerilim kararsızlığı, sistemde meydana gelen olayların geniş bir kısmını içerirken; gerilim kararlılığı için ise farklı görüşler mevcuttur. Güç üretiminde azalma, talep edilen yükte artma veya generatör, iletim hattı, transformatör vb. cihazların elektriğinin

kesilmesi gibi bozulmalardan dolayı gerilim kontrol edilemediğinden güç sistemlerinde gerilim kararsızlığı meydana gelmektedir. Elektrik ve Elektronik Mühendisleri Enstitüsü'ne (IEEE) göre gerilim kararlılığı bir sistemin gerilimini koruyabilme yeteneğidir [3].

Gerilimin sürekli artmasına ve kontrol edilemeyen düşmesine neden olan yük talebindeki artış veya güç sisteminin durumundaki bir değişimin olması gibi bir bozucu etki olduğu zaman, güç sistemindeki gerilim kararsız duruma girer. Kararsızlığın nedeni, güç sisteminin artan reaktif güç talebini karşılayamamasıdır. Gerilim kararsızlığı normal olarak ağır biçimde yüklenen sistemlerde meydana gelir. Gerçekten gerilim kararsızlığı güç (P, Q) ve gerilim (V) arasındaki ilişkilere bağlıdır. Bu ilişkileri gösteren karakteristikler radyal hat için analitik olarak elde edilebilirken, daha büyük baralı karmaşık sistemler için yük akışı analizi kullanılarak belirlenebilir [18]. Ayrıca sistem yükü kritik yüklenme noktasına yaklaştıkça yani gerilim çökmesinin olduğu yüklenme durumuna yaklaştıkça güç akışı analizinin yapılması zorlaşmakta kullanılan güç akışı algoritmalarında yakınsama problemi görülmektedir. Bu nedenle birden fazla güç akışına ihtiyaç duymaksızın sistemlerdeki kritik baranın belirlenmesi için birçok kararlılık indeksi geliştirilmiştir. Bu indekslerden en yaygın kullanılanlar hat kararlılık indeksi (HKİ), hat kararlılık faktörü (HKF), gerilim çökmesi yakınlık göstergesi (GÇYG), hızlı hat kararlılık indeksi (HHKİ) ve L-indeksidir. HKİ hesaplanırken Şekil 1'de gösterildiği gibi tüm sistem iki baraya indirgenir. Baralardan biri salınım barası, diğeri yük barası olarak seçilir [19]. Şekil 1'de; Bara-1 salınım barası, Bara-2 ise yük barası olarak seçilmiştir. Ayrıca bu şekilde V_1 ; salınım barasının gerilimi, V_2 ; yük barasının gerilimi, P_1 ; salınım barasının aktif gücü, Q_1 ; salınım barasının reaktif gücü, P_2 ; yük barasının aktif gücü, Q_2 ; yük barasının reaktif gücü, S_1 ; salınım barasının görünür gücü, S_2 ; yük barasının görünür gücü, I ; hat akımı, θ ; iletim hattı empedansı, δ ; baralar arasındaki gerilim açısı farkı ($\delta_1 - \delta_2$).



Şekil 1. İki baralı güç sistemi modeli

M. Moghavammi vd. [20], bir güç sistemi iletim hattının gerilim kararsızlığına olan yakınlığını gösteren bir kararlılık kriteri oluşturmuşlardır. Güç sisteminde bir gerilim çökmesi meydana gelirse HKİ indeksi maksimum değeri 1, sistemde yük olmadığında minimum değeri 0 olabilir. Bu indeks, güç aktarım kavramına dayanır ve burada gerilim ikinci dereceden denkleminin ayırt edici özelliği, kararlılık elde etmek için sıfırdan büyük veya sıfır olarak ayarlanmalıdır. HKİ tek bir hattaki bir güç iletimine göre denk. 1'e göre hesaplanabilir:

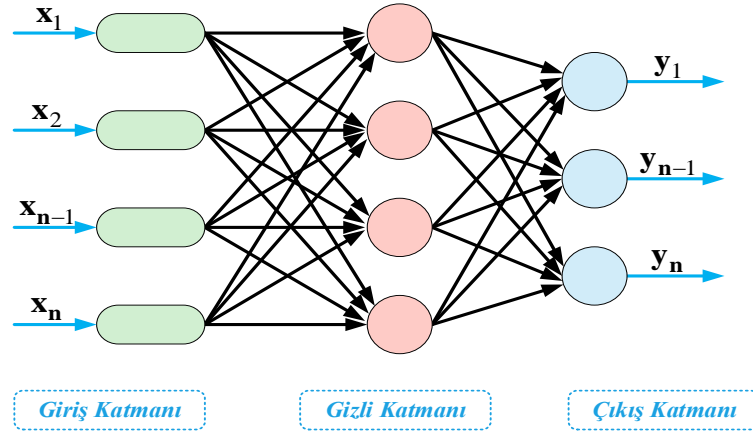
$$HKİ = \frac{4XQ_j}{(V_i - \sin(\theta - \delta))^2} \quad 1$$

Burada X ; hattın reaktansını, Q_j ; son alıcı reaktif gücünü, V_i ; ilk gönderici gerilimi, θ ; faz açısını, δ ise besleme gerilimi ve alıcı gerilimi arasındaki açı farkını göstermektedir. Gerilimi kararlı olan sistemi korumak için HKİ değeri 1'den küçük olmalıdır [21-22].

3. UÇ ÖĞRENME MAKİNESİ (EXTREME LEARNING MACHINE)

UÖM, tek katmanlı ileri beslemeli YSA'lar için geliştirilmiş bir öğrenme algoritmasıdır [10, 23-24]. UÖM'de, eğitim düşüm tabanlı öğrenme algoritmalarından farklı olarak giriş ağırlıkları ve biasları rastgele atanır ve çıkış ağırlıkları matematiksel olarak elde edilir [24]. İleri beslemeli normal bir YSA'da sinir ağının eğitilmesi tekrarlamayı gerektirirken, bu tekrarlı durum UÖM'de matematiksel bir denkleme dönüştürülmüştür. Bu nedenle, UÖM hızlı öğrenme kabiliyetinin yanında geleneksel geri yayılım algoritması ile eğitilen ileri beslemeli bir sinir ağına kıyasla genelleme yeteneği daha iyidir [23-25]. Ayrıca, UÖM'nin çıkış ağırlıkları genelleştirilmiş ters Moore-Penrose matrisi ile hesaplandığından, yerel minimuma takılma veya optimum öğrenme parametre belirlenmesi gibi performansı doğrudan etkileyen problemleri yoktur [22-25]. Fakat UÖM sinir ağı verilerin dağılımına göre transfer fonksiyonu, eğitim düşüm tabanlı

öğrenme algoritmalarında olduğu gibi belirlenmesi için birçok deneme gerektirmektedir. UÖM’de eğitim düşünüm tabanlı öğrenme algoritmalarından farklı olarak sürekli olmayan aktivasyon fonksiyonlarını da kullanabilmektedir [23]. Şekil 2’de UÖM ile eğitilen tek gizli katmanlı ağ yapısı gösterilmiştir.



Şekil 2. Tek gizli katmanlı sinir ağı yapısı

Burada, x_N ve y_N sırası ile giriş ve çıkışları göstermektedir. Girişler $x_N = [x_1, x_2, \dots, x_N]^T \in R^N$ matrisi, çıkışlar ise $y_N = [y_1, y_2, \dots, y_N]^T \in R^N$ matrisleri ile ifade edilir. Ara katmanda M tane sinir hücresi içeren standart bir ağıın çıkışı matematiksel olarak denk. 2’deki gibi yazılabilir [10].

$$\sum_{i=1}^M \beta_i g(w_i \cdot x_j + b_i) = t_j, j=1, \dots, N \quad 2$$

Burada $w_i = [w_{i1}, w_{i2}, \dots, w_{iN}]^T$; i. gizli sinir hücresine ve giriş sinir hücresine bağlı olan giriş ağırlık vektörünü, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{iM}]^T$; i. gizli sinir hücresine ve çıkış sinir hücrelerine bağlı olan çıkış ağırlık vektörünü, $g(\cdot)$; gizli katmanda kullanılan aktivasyon fonksiyonunu. b_j ise i. gizli sinir hücresinin bias değerini gösterir. $w_i \cdot x_j$ ise w_i ve x_j ’nin noktasal çarpımını belirtir. $t_j = [t_1, t_2, \dots, t_j]^T$ ise UÖM ağının beklenen ya da olması istenen çıkışı olmak üzere, N tane gizli sinir hücresine ve $g(\cdot)$ aktivasyon fonksiyonuna sahip standart tek gizli katmanlı ileri beslemeli ağ yapısında hedef değer t_j ile ağın çıkış değeri y_j birbirine eşit olursa hata sıfır olur. Yani, $\sum_{j=1}^N \|t_j - y_j\| = 0$ ’ı sağlayacak çıkış ağırlıkları vardır. Bu durumda t_j hedef değer y_j ağın gerçek çıkışına eşitlenirse [22]:

$$\sum_{i=1}^M \beta_i g(w_i \cdot x_j + b_i) = y_j, j=1, \dots, N \quad 3$$

elde edilir [10]. Eğer denk. 3’te $H = g(w_i \cdot x_j + b_i)$ olarak ifade edilirse denk.(4) yazılabilir.

$$y = H \cdot \beta \quad 4$$

Denklem 4’teki H matrisi denklem 5’de verilmiştir [10].

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_N \cdot x_1 + b_N) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_M + b_1) & \dots & g(w_N \cdot x_M + b_N) \end{bmatrix}_{N \times M} \quad 5$$

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_M \end{bmatrix}_{M \times 1}; y = \begin{bmatrix} y_1 \\ \vdots \\ y_N \end{bmatrix}_{N \times 1} \quad 6$$


Bu durumda, w_i giriş katmanı ağırlıkları ve b_i gizli katman bias değerleri rastgele seçilerek H analitik olarak hesaplanır. Geleneksel tek gizli katmanlı ileri beslemeli ağlarda ağın eğitilmesi gerekirken UÖM’de denklem 4’te belirtilen doğrusal bir denklemin tek seferde çözülmesiyle eğitim tamamlanır. Çıkış ağırlıkları olan β değerleri denklem 7’de çözümlenerek elde edilir;

$$\beta = H^+ \cdot y \quad 7$$

Yukarıdaki denklemde; H^+ , H çıkış matrisinin genelleştirilmiş tersi “Moore-Penrose matrisi olarak tanımlanmıştır [10].

4. YAPILAN ÇALIŞMA (REALIZED STUDY)

Bu çalışmada IEEE 14-baralı güç sisteminde gerilim kararlılığı farklı yük şartları altında HKİ değerleri yardımı ile UÖM algoritmaları kullanılarak incelenmiştir. Bu amaçla Şekil 3'te verilen IEEE 14-baralı güç sistemi modeli Matlab'ta oluşturulmuştur. Oluşturulan modelin yük akış analizi Newton-Raphson yöntemi kullanılarak gerçekleştirilmiştir. Yük akış analizi yapılırken tüm baraların aktif ve reaktif güç değerleri 0.05 birim değer (pu) artırılarak her bir bara için 1000 adet aktif güç, reaktif güç, gerilim genliği ve gerilimin faz açısı elde edilmiştir. Bu değerler kullanılarak hesaplanan HKİ değerleri ile IEEE 14-baralı güç sisteminin en kritik hattı belirlenmiştir. Tablo 1'de baralar arası iletim hatlarına ait farklı güç artırımlarından elde edilen HKİ değerleri verilmiştir.



Şekil 3. IEEE 14-baralı güç sistemi

Tablo 1'den, 12-13 nolu baralara ait iletim hattın güç artırımı yapıldıkça HKİ değeri diğer iletim hatlarından daha büyük ve 1'e en yakın olduğu için bu hat en kritik hat olarak belirlenmiştir. 12-13 nolu baralar ve bu baralara bağlı iletim hattı verileri UÖM algoritmasında giriş ve çıkış verileri olarak kullanılmıştır. UÖM algoritması için giriş parametreleri; ilk gönderici baranın gerilim genliği ve gerilim faz açısı; son alıcı baranın reaktif gücü ve gerilimin faz açısı ve çıkış parametresi olarak HKİ değerleri alındı. UÖM'nin tahmin edeceği hedef HKİ değerleridir. UÖM'nin başarımını etkileyen en önemli faktörler gizli katman hücre sayısı (GKHS) ve gizli katmanda kullanılan aktivasyon fonksiyon tipidir. Bu nedenle, UÖM algoritması farklı GKHS değerleri (20, 60 ve 100) ve gizli katmanda farklı tip aktivasyon fonksiyonları (radyal tabanlı, logaritmik sigmoid ve tanjant sigmoid) için test edilerek bu parametrelerin en uygun değeri ve tipi belirlenmeye çalışılmıştır. Bu parametreler kullanılarak UÖM'den elde edilen eğitim - test süreleri ve test doğruluğu (TD) ve karesel ortalama hata (RMSE) parametreleri farklı tip aktivasyon fonksiyonu ve GKHS sayıları için verilmiştir. Tablo 2'de verilen sonuçlar incelendiğinde, tanjant sigmoid aktivasyon fonksiyonu kullanan UÖM'den elde edilen RMSE değerlerinin radyal tabanlı ve logaritmik sigmoid aktivasyon fonksiyonu kullanan UÖM'ye göre daha düşük olduğu görülmektedir. RMSE, iki veri kümesi arasında ne kadar hata olduğunu ölçer. Başka bir deyişle, öngörülen bir değer ile gözlenen veya bilinen bir değeri karşılaştırır. Bir RMSE değeri ne kadar küçükse, öngörülen ve gözlenen değerler birbirine o kadar yakındır ve ağırlık tahmin başarımı o kadar yüksektir. Ayrıca GKHS artıkça UÖM'nin başarımının iyileştiği, bunun yanında eğitim-test sürelerinin arttığı görülmektedir.

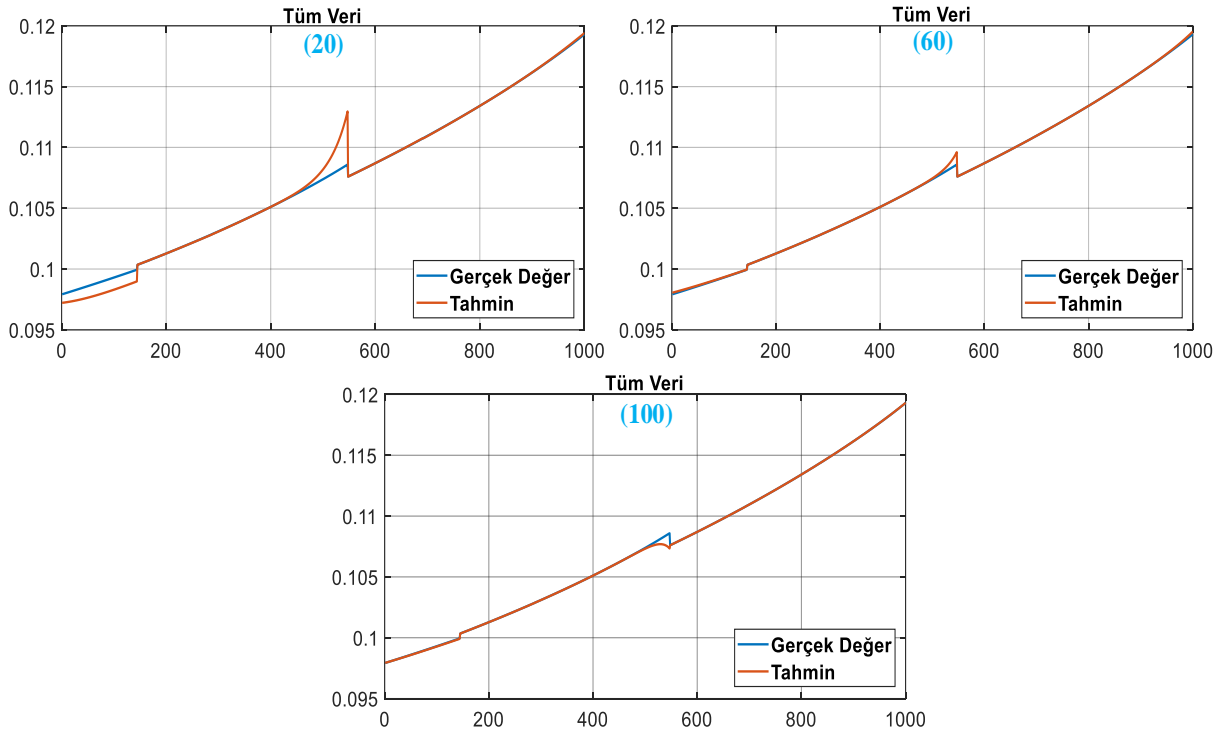
Tablo 1. İletim hatlarına ait farklı güç artırımından elde edilen HKİ değerleri

<i>Baralar</i>	1	2	3	4	5	6	7
<i>1-2</i>	0.0874	0.0884	0.2004	0.7605	0.8621	1.0154	1.2988
<i>1-5</i>	0.0149	0.0156	0.0253	0.0350	0.0447	0.0544	0.0641
<i>2-3</i>	0.0737	0.0738	0.1967	0.3196	0.4425	0.5654	0.1006
<i>2-4</i>	0.0299	0.0326	0.1536	0.2746	0.3956	0.5166	0.6376
<i>2-5</i>	0.0117	0.0122	0.1342	0.2562	0.3782	0.5002	0.6222
<i>3-4</i>	0.0291	0.0323	0.1518	0.2713	0.3908	0.5103	0.6298
<i>4-5</i>	0.0284	0.0316	0.1498	0.2680	0.3862	0.5044	0.6226
<i>4-7</i>	0.0010	0.0011	0.1634	0.7074	0.8205	1.001	1.3102
<i>4-9</i>	0.0348	0.0393	0.1245	0.6453	0.7604	1.0207	1.1233
<i>5-6</i>	0.0337	0.0344	0.1561	0.7653	0.8603	1.0074	1.2049
<i>6-11</i>	0.0154	0.0162	0.1387	0.2612	0.3837	0.5062	0.6287
<i>6-12</i>	0.0179	0.0217	0.1421	0.2625	0.3829	0.5033	0.6237
<i>6-12</i>	0.0335	0.0340	0.1547	0.2754	0.3961	0.5168	0.6375
<i>7-8</i>	0.0248	0.0293	0.1114	0.6757	0.5677	1.0177	1.1133
<i>7-9</i>	0.0437	0.0544	0.1676	0.7653	0.4604	1.0074	1.0144
<i>9-10</i>	0.0215	0.0216	0.1418	0.2620	0.3822	0.5024	0.6226
<i>9-14</i>	0.0634	0.0647	0.1941	0.3235	0.4529	0.5823	0.9917
<i>10-11</i>	0.0333	0.0601	0.1894	0.3187	0.4480	0.5773	0.9961
<i>12-13</i>	0.0929	0.0943	0.2175	0.7814	0.8846	1.1051	1.4159
<i>13-14</i>	0.0804	0.0807	0.2036	0.7653	0.8686	1.0275	1.3049


Tablo 2. Farklı aktivasyon fonksiyonu ve GKHS değerine göre elde edilen sonuçlar

<i>Aktivasyon Fonksiyonu</i>	GKHS	Süre (sn)			
		Test	Eğitim	TD (%)	RMSE
<i>Radyal tabanlı</i>	20	0.0312	0.0468	48.89	0.44044
	60	0.0781	0.1092	53.75	0.32179
	100	0.1392	0.1404	57.77	0.28748
<i>Logaritmik sigmoid</i>	20	0.0132	0.4836	78.46	0.37746
	60	0.0468	0.0468	83.47	0.22147
	100	0.1092	0.1248	88.04	0.19986
<i>Tanjant sigmoid</i>	20	0.0156	0.1872	80.03	0.29127
	60	0.0568	0.1248	84.09	0.21147
	100	0.1248	0.3276	98.98	0.17371

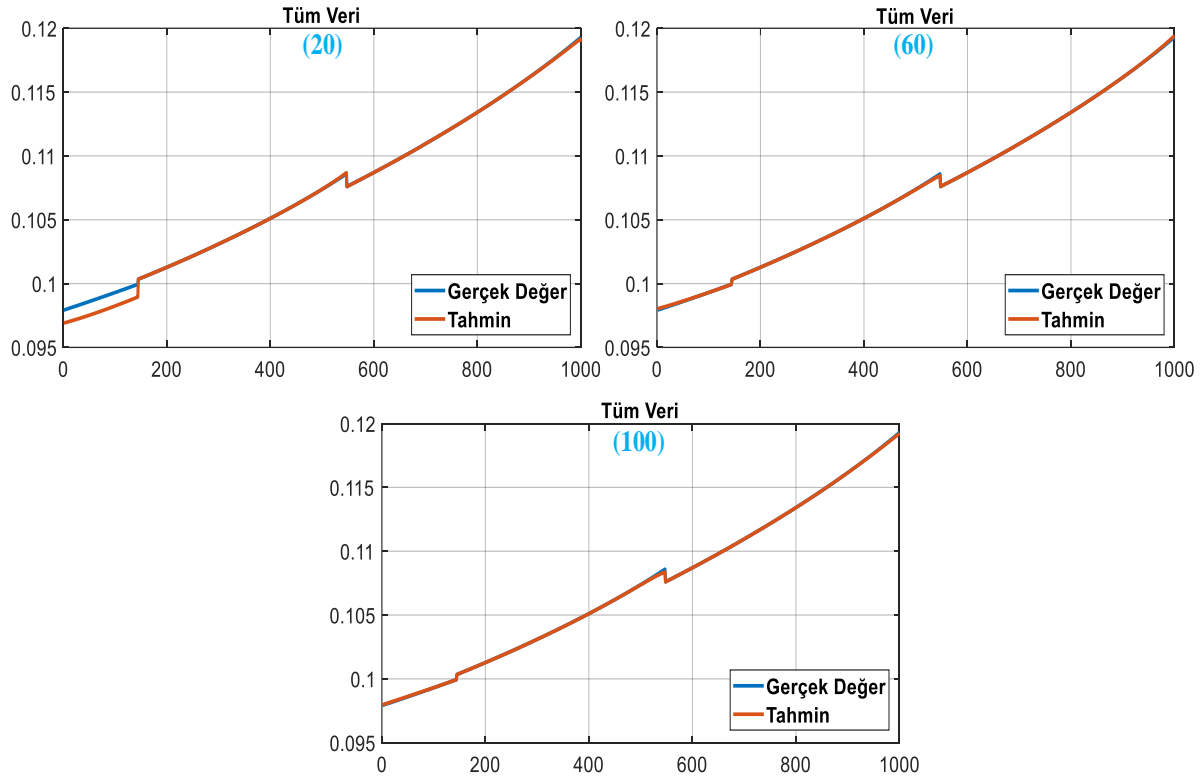
Şekil 4-6-8'de sırasıyla verilen radyal tabanlı, logaritmik sigmoid ve tanjant sigmoid aktivasyon fonksiyonları ile farklı GKHS değerleri (20, 60, 100) için UÖM algoritmaları ile tahmin edilen HKİ'lerin, GKHS değeri artırıldıkça gerçek değer HKİ eğrileriyle daha iyi bir eğim oluşturduğu görülmektedir. Şekil 8'de verilen tanjant sigmoid aktivasyonlu UÖM algoritmaya ait tahmin eğrisi, Şekil 4'te ve Şekil 6'da verilen radyal tabanlı ve logaritmik sigmoid UÖM algoritmalarının oluşturduğu tahmin eğrilerinden gerçek değer eğrisine olan paralellığı daha fazladır. Şekil 5-7-9'da sırasıyla verilen radyal tabanlı, logaritmik sigmoid ve tanjant sigmoid aktivasyon fonksiyonlarını kullanan UÖM algoritmalarının farklı GKHS değerleri (20, 60, 100) için regresyon eğrilerinde görüldüğü gibi GKHS değeri artıkça UÖM algoritmaları tarafından tahmin edilen HKİ değerlerinin gerçek HKİ değerleri ile regresyon doğrusu üzerinde daha fazla yoğunlaştığı görülmektedir. Şekil 9'da verilen regresyon eğrisinin Şekil 5 ve 7'deki regresyon eğrilerine göre regresyon değerinin 1'e olan yakınlığı daha fazla olduğundan tanjant sigmoid aktivasyon fonksiyonlu UÖM algoritmasının diğer algoritmalara göre tahmin başarımının daha iyi olduğu söylenebilir.




Şekil 4. Radyal tabanlı aktivasyon fonksiyonu ile farklı GKHS değerleri için UÖM tarafından tahmin edilen HKİ'ler



Şekil 5. Radyal tabanlı aktivasyon fonksiyonu kullanan UÖM'nin farklı GKHS için regresyon eğrileri




Şekil 6. Logaritmik sigmoid aktivasyon fonksiyonu ile farklı GKHS değerleri için UÖM tarafından tahmin edilen HKİ'ler

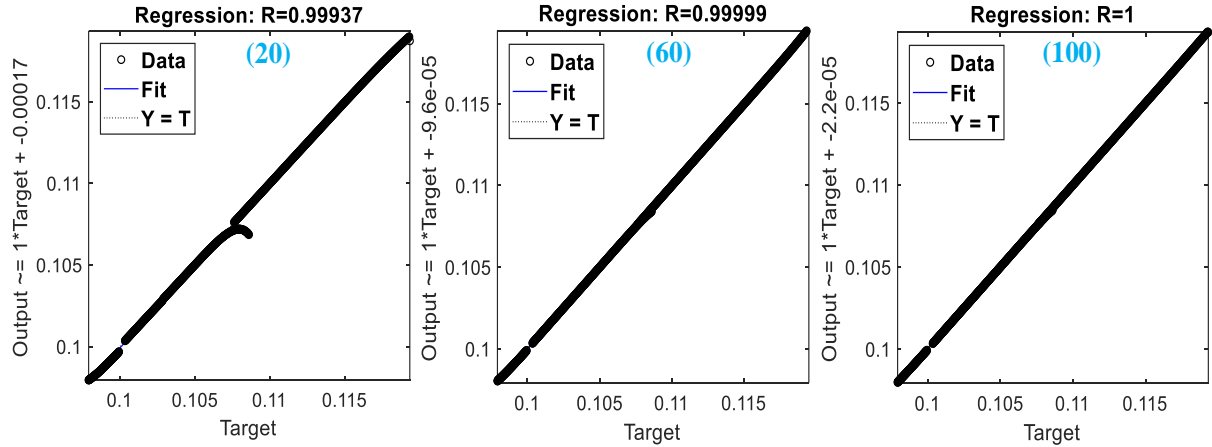


Şekil 7. Logaritmik sigmoid aktivasyon fonksiyonu kullanan UÖM'nin farklı GKHS için regresyon eğrileri

Tablo 3'te UÖM algoritmalarından en iyi tahmin başarımını gösteren tanjant sigmoid aktivasyon fonksiyonlu GKHS'si 100 olan algoritma ile Matlab uygulamalarından Regression Learning araç kutusu kullanılarak farklı regresyon yöntemlerinden elde edilen test-egitim süreleriyle hata değerlerinin karşılaştırılması verilmiştir. Tablo 3'te yer alan *LR*; lineer regresyon, *SVMR*; destek vektör makine regresyonu, *GR*; gauss regresyon, R^2 ; korelasyon katsayısı, *MSE*; ortalama karesel hata, *RMSE*; ortalama karekök hata, *MAE*; ortalama mutlak hatayı ifade etmektedir. Tablo 3'te verilen tanjant sigmoid aktivasyon fonksiyonlu UÖM algoritmasının diğer regresyon yöntemlerine göre hem test-egitim süresinin çok kısa olması hem de hata değerlerinin diğer yöntemlerden az olmasından dolayı UÖM algoritmasının HKİ değerlerini tahmin etmede tercih edilebileceği değerlendirilebilir.



Şekil 8. Tanjant sigmoid aktivasyon fonksiyonu ile farklı GKHS değerleri için UÖM tarafından tahmin edilen HKİ'ler



Şekil 9. Tanjant sigmoid aktivasyon fonksiyonu kullanan UÖM'nin farklı GKHS için regresyon eğrileri

Tablo 3. UÖM algoritması ile farklı regresyon yöntemlerinin karşılaştırılması

	UÖM	LR	SVMR	GR
Eğitim-Test Süresi (sn)	0.4524	13.9	136.32	91.43
R^2	1	1	0.99	1
MSE	0.0301	3.4849	11.4724	0.0014
RMSE	0.1737	1.8668	3.3871	0.0121
MAE	0.1407	1.5152	3.0401	0.0092

5. SONUÇ (CONCLUSION)

Bu çalışmada, IEEE 14-baralı güç sistemlerinde gerilim kararlılığının bir ölçütü olan HKİ değeri UÖM yardımıyla tahmin edilmeye çalışılmıştır. Bu amaçla öncelikle IEEE 14-baralı güç sisteminin Newton Raphson metoduyla yük akış modeli MATLAB ortamında oluşturulmuştur. Yük akış analizinde tüm baraların aktif ve reaktif güçleri 0.05 birim değer (pu) artırılmış ve her bir baraya ait toplam 1000 adet aktif güç, reaktif güç, gerilim genliği ve gerilimin faz açısı değerleri hesaplanmıştır. IEEE 14-baralı güç sistemi modeli parametre değerlerinden elde edilen 1000 adet HKİ değeri, yine Matlab ortamında oluşturulan UÖM kullanılarak tahmin edilmeye çalışılmıştır. UÖM'nin test başarımı 5-kat çapraz doğrulama kullanılarak verilmiştir. Ayrıca UÖM'nin başarımı, GKHS 20, 60 ve 100 olacak şekilde ve radyal tabanlı, logaritmik sigmoid ile tanjant sigmoid aktivasyon fonksiyonları kullanılarak sunulmuştur. Bu regresyon ile tahmin eğrilerinden ve farklı regresyon yöntemlerinden elde edilen sonuçlara göre GKHS 100, aktivasyon fonksiyonu tanjant sigmoid olan UÖM algoritmasının HKİ değerini daha iyi tahmin ettiği görülmüştür. Bu sonuçlar UÖM'nin güç sistemlerinde gerilim kararlılığının analizinde bir araç olarak kullanılabileceğini göstermiştir.

KAYNAKLAR (REFERENCES)

- [1] W.D. Stevenson, Elements of power system analysis (Fourth edition). New York: McGraw-Hill (1982).
- [2] P. Kundur, Power System Stability and Control. EPRI Power System Engineering Series, McGraw Hill, (1994).
- [3] P. Kundur, et al. Definition and classification of power system stability IEEE/CIGRE joint task force on stability terms and definitions. IEEE Trans. Power Syst. 19(3): (2004) 1387-1401.
- [4] M. Yeşilbudak, R. Bayındır, Ü. Çetinkaya, Güç Sistemlerinde Gerilim Kararlılığını Etkileyen Faktörler. Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji, 3(4): (2016) 595-602.
- [5] V. Balamourougan, T.S. Sidhu and M.S. Sachdev, Technique for online prediction of voltage collapse. IEEE Proc. Gener. Transm. Distrib., 151: (2004) 454-460.
- [6] B.C. Bernardes, W.D. Oliveira, J.P.A. Vieira, I. Ohana, U.H. Bezerra, Decision Tree-Based Power System Static Security Assessment Using PMU Measurements. In: IEEE PES Trondheim Power Tech, Trondheim, (2011).
- [7] M. Ramaswamy, K.R. Nayar, On-line estimation of bus voltages based on fuzzy logic. Int. J. Electr. Power Energy Syst., 26(9): (2004) 681-684.
- [8] O.P. Rahi, A.K. Yadav, H. Malik, A. Azeem, B. Kr, Power system voltage stability assessment through artificial neural network. Procedia Eng., 30: (2012) 53-60.
- [9] V.S. Vankayala, N.D. Rao, Artificial neural networks and their applications to power systems-a bibliographical survey. Electr. Power Syst. Res., 27: (1993) 67-79.
- [10] M.J. Short, K.C. Hui, J.F. Macqueen, A.O.R. Ekwue, Application of artificial neural networks for NGC voltage collapse monitoring. Inter. Conf. On Large High Voltage Electric Systems, Cigre, Paris, (1994).
- [11] G.B. Huang, Q.Y. Zhu, C.K. Siew, Extreme learning machine: theory and applications. Neurocomputing, 70(1): (2006) 489-501.
- [12] G.B. Huang, Q.Y. Zhu, C.K. Siew, Extreme Learning Machine: A New Learning Scheme of Feedforward Neural Networks. IEEE International Joint Conference on Neural Networks, Budapest, Hungary, pp. 985-990, (2004).

- [13] Ucar F., et al. Power quality event detection using a fast extreme learning machine. *Energies* 11(145) (2018) 1-14.
- [14] Ö.F. Ertuğrul, M.E. Tağluk, Y. Kaya, Fault Detection at Power Transmission Lines by Extreme Learning Machine, 21st Signal Processing and Communications Applications Conference (SIU), Haspolat, Turkey, (2013).
- [15] C. Wan, Z. Xu, P. Pinson, Z.Y. Dong, K.P. Wong, Optimal Prediction Intervals of Wind Power Generation, *IEEE Trans. Power Syst.*, 29: (2014) 1166-1174.
- [16] R. Zhang, Z.Y. Dong, Y. Xu, K. Meng, K.P. Wong, Short term load forecasting of Australian National Electricity Market by an ensemble model of extreme learning machine. *IET Gener. Transm. Distrib.*, 7(4): (2013) 391-397.
- [17] A. Öztürk, B. Bozali, S. Tosun, Güç Sistemi Kararlılığını İyileştirecek Facts Cihazlarının Bağlantı Noktasının Belirlenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi* 4(2): (2016) 812-825.
- [18] C. Subramani, S.S. Dash, M.A. Bhaskar, M. Jagdeshkumar, Simulation technique for voltage stability Analysis and contingency ranking in power systems. *International Journal of Recent Trends in Engineering*, 2(5): (2009) 263-267.
- [19] I. Musirin, T.A. Rahman, Estimating maximum loadability for weak bus identification using FVSI. *IEEE Power Eng. Rev.*, 22(11): (2002) 50-52.
- [20] M. Moghavvemi, F.M. Omar, Technique for contingency monitoring and voltage collapse prediction. *IEE Proceedings-Generation, Transmission and Distribution*, 145(6): (1998) 634-640.
- [21] I. Musirin, T.K. Abdul Rahman, On-Line Voltage Stability Index for Voltage Collapse Prediction in Power System. *Brunei International Conference on Engineering and Technology 2002 (BICETZOOI)*, Brunei, pp. 1118-1121, (2002).
- [22] G.B. Huang, D.H. Wang, Y. Lan Extreme learning machines: a survey. *Int. J. Mach. Learn. Cybern.*, 2(2): (2011) 107-122.
- [23] F. Uçar, B. Dandıl, F. Ata Classification of power quality events using extreme learning machine, 23th Signal Processing and Communications Applications Conference (SIU), (2015).
- [24] A. Ben-Israel, T.N.E. Greville, *Generalized Inverses: Theory and Applications*, Springer-Verlag, (2003).
- [25] A. Ethem, *Yapay Öğrenme (2.baskı)*, Boğaziçi Üniversitesi Yayınevi, 278-281, (2011).