



Newman-Watts Küçük Dünya Yaklaşımının İleri Yönlü Yapay Sinir Ağları Performansına Etkisi

Impact of Newman-Watts Small-World Approach on the Performance of Feed-Forward Artificial Neural Networks

Okan Erkamaz^{1*}, Mahmut Özer²

¹Bülent Ecevit Üniversitesi, Bilgisayar Mühendisliği Bölümü, Zonguldak, Türkiye

²Bülent Ecevit Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Zonguldak, Türkiye

Öz

İleri yönlü yapay sinir ağlarında, öğrenme performansı; öğrenme algoritması, ara katman yapısı ve katmanlardaki nöron sayısına bağlı olarak değişim göstermektedir. Bu nedenle, ağ performansını artırabilmek için araştırmalar yapılmakta ve farklı yaklaşımlar önerilmektedir. Bu çalışmada, Newman-Watts bağlantı yenileme yaklaşımı kullanılarak tasarlanan Küçük-Dünya (SW) ağ modelinin ileri yönlü yapay sinir ağı (FFANN) performansına etkisi incelenmiştir. Elde edilen sonuçlar düzenli ağ topolojisine göre SW ağ topolojisinin çıkış hata ve belirtme katsayısı değerlerinin daha iyi olduğunu, sonuç olarak, Newman-Watts SW ağının öğrenme performansının düzenli ağa göre daha iyi olduğunu göstermektedir. Böylece, Watts-Strogatz SW ağlarında olduğu gibi Newman-Watts SW ağlarının da, gelecekteki yapay sinir ağ çalışmalarının kara-kutu probleminde bir çözüm olarak kullanılabilceği vurgulanmıştır.

Anahtar Kelimeler: İleri yönlü yapay sinir ağları, Newman-Watts küçük dünya ağları, Öğrenme performansı, Topoloji, Yeni bağlantı ekleme

Abstract

In the Feed Forward Neural Network (FFANN), performance of the learning changes with training algorithm, structure of hidden layer and number of neurons within the layers. Therefore, many research are conducted to improve the performance of network, and different approaches are suggested to achieve it. In this study, we analyse the impact of Newman-Watts Small-World (SW) approach on the performance of the FFANN. The obtained results show that the values of output error and determination coefficient of the network by the Newman-Watts SW approach are the better than those of the regular network, leading to the fact that the performance of Newman-Watts network is better than the regular networks. In this way, similar to the Watts-Strogatz FFANNs, it is shown that the Newman-Watts FFANNs can be used to solve black-box problem of ANN studies in the future.

Keywords: Feed-forward artificial neural network, Newman-Watts small-world network, Learning performance, Topology, Rewiring network

1. Giriş

Yapay zekâ yaklaşımı lineer olmayan problemlerinin çözümünde düşünebilen bilgisayar sistemleri üretebilmek için kullanılan bir matematiksel model olup insan beyninin özellikleri ve fonksiyonlarına dayalı olarak geliştirilmektedir. Yapay sinir ağları (ANN), genetik algoritma, uzman sistemler, bulanık mantık denetleyiciler, ve destek vektör makine-leri gibi farklı yaklaşımlara dayalı olarak geliştirilen yapay

zekâ yaklaşımı önemli bir araştırma alanı haline gelmiş ve pek çok mühendislik problemini çözmek için önerilmiştir (Haykin 1999). Yıllar içerisinde pek çok yapay zekâ modeli ortaya konulmuştur. Bu modeller arasında, genelleme ve sınıflandırma yetenekleriyle ANN'ler en yaygın kullanılan matematiksel modeldir. ANN, biyolojik nöron yapısından esinlenerek geliştirilen matematiksel modele dayalı yapay nöronlar ve bu nöronlar arasında oluşturulan katmanlı bağlantılardan oluşmaktadır. ANN mimarisinin performansında en önemli etken öğrenme sürecidir. Öğrenme süreci, veri seti, öğrenme algoritması ve ağ topolojisine bağlı olarak değişmektedir. Ağ topolojisinin belirlenmesi son yıllarda

*Sorumlu yazarın e-posta adresi: okanerkamaz@yahoo.com

araştırmaların en çok yoğunlaştığı alanlardan birisidir. Bu bağlamda, ileri yönlü yapay sinir ağları (FFANN), Hopfield Ağları, SOM, Radyal Temelli Sinir Ağları ve Geri Beslemeli ANN topolojileri vb gibi ANN topolojileri önerilmiştir (Haykin 1999, Gurney 2002, Buhmann 2003). FFANN topolojisi katmansal yapısından dolayı analitik hesaplama hızına sahiptir ve bu özelliğiyle diğer topolojilerden ayrılmaktadır. Bu model topolojik sinaptik bağlantı farklılıkları nedeniyle performans değişikliği göstermektedir. (Sun vd. 1996, Magnitskii 2001).

Son yıllarda biyolojik sinir ağları üzerine yapılan çalışmalar, biyolojik nöronal ağlarda topolojik farkların bilginin kodlanması ve iletimi üzerine etkilerine odaklanmıştır (Yılmaz vd. 2013, Yılmaz vd. 2016a, b, 2016). Bu bağlamda SW ağı (Watts ve Strogatz 1998, Newman ve Watts 1999) ve ölçeksiz ağ (Scale-free, SF) (Barabasi ve Albert 1999, Jeong vd. 2001, Camacho vd. 2002, Yılmaz vd. 2016) gibi gerçek ağların davranışlarını büyük doğrulukla yakınsayan rasgele ağ modelleri önerilmiştir. SF ve SW ağ modelleri biyolojik nöronal ağlarda bilginin nasıl kodlandığını anlamak için son zamanlarda yaygın olarak kullanılmaktadır (Ozer vd. 2008, Ozer vd. 2009a, b, 2009, Yılmaz vd. 2013, Yılmaz vd. 2016). Son zamanlarda önerilen ve gerçek nöral ağ modellerinde yaygın olarak kullanılan yeni ağ modellerini FFANN modelinde de kullanabilme ile ilgili topolojik deneme çalışmaları yapılmaya başlamıştır. Simard vd. (2005), FFANN'de temel nöronal bağlantı yapısını düzenli ağ kabul edip, var olan bağlantıları koparıp, yerine yeni bağlantılar ekleyerek SW ağ modelini elde etmişler ve SW ağ performansının diğer topolojiler kullanılarak elde edilen ağların performanslarından daha iyi olduğunu göstermişlerdir. Shuzhong vd. (2006), FFANN'lerde SW ağ topolojisinin öğrenme hatasını ve öğrenme zamanını azalttığını göstermişlerdir. Erkaymaz vd. (2014) ve

Erkaymaz ve Ozer (2016) FFANN'de Watt-Strogatz SW ağ yaklaşımını kullanarak SW ağ yapısı elde etmişler, ve gerçek problemlerinin eğitiminde, SW ağ performansının düzenli ağdan daha iyi olduğunu göstermişlerdir.


Bu çalışmada, Erkaymaz vd. (2014) ve Erkaymaz ve Ozer (2016) tarafından yapılan çalışmalarından farklı olarak FFANN'lerde SW ağ yapısı elde etmek için Watts-Strogatz yaklaşımı yerine Newman-Watts yaklaşımı kullanılmakta (Newman 1999), ve elde edilen ağın performansı analiz edilmektedir.

2. Gereç ve Yöntem

2.1. Newman-Watts Küçük-Dünya Ağı Modeli

SW ağ modeli düzenli ağ topolojisi (FFANN topolojisi) temel alınarak elde edilmektedir. FFANN topolojisi düzenli ağ kabul edilip, Newman-Watts bağlantı yenileme algoritması (Newman 1999) kullanılarak SW ağı elde edilmektedir. Ağ yapısının elde edilmesi, ilk olarak rastgele bağlı olmayan nöron çifti tespit edilip, bu nöron çifti arasına yeni sinaptik bağlantı eklenmesi ile gerçekleştirilmektedir. Bağlantı ekleme süreci olası maksimum bağlantı sayısı kadar devam etmektedir. Newman-Watts Bağlantı ekleme algoritmasının şematik gösterimi Şekil 1'de gösterilmiştir.

SW ağları, kümeleme katsayısı (C) ve karakteristik en kısa yol uzunluğu(L) olarak isimlendirilen iki katsayıya dayalı olarak karakterize edilmektedir. L, ağın bilgiyi taşıma kapasitesini ifade etmektedir. C ise bir ağın düğümlerinin kümeleme performansını ifade etmekte olup bir düğümün en yakın komşularının kendi aralarında var olan bağlantı sayısının, komşular arasında olası maksimum bağlantı sayısına oranı olarak tanımlanmaktadır (Watts ve Strogatz 1998, Newman ve Watts 1999). FFANN'lerin katmanlı yapısında, aynı katmanda bağlı olmayan nöronlar bulunmaktadır. Bu



Şekil 1. Newman-Watts SW ağ oluşturmada yeni bağlantılar ekleme.

nedenle, C ve L katsayıları hesaplanamamaktadır. Bu katsayılar yerine, Latora ve Marchiori (2001), Lokal ve Global verim olarak isimlendirilen katsayılar önermişlerdir. Bu yaklaşımda, Lokal verim (D_{Lokal}) $1/C$ ile eş değer, Global verim (D_{Global}) ise L parametresine eş değer kabul edilmiştir. Bu bağlamda, Küçük-Dünya ağlarını elde edebilmek için Lokal ve Global verimin minimum olması gerekmektedir (Latora ve Marchiori 2001, Latora ve Marchiori 2003, Erkaymaz vd. 2014, Erkaymaz ve Ozer 2016).

Bir ağda Global verim aşağıdaki gibi tanımlanmaktadır (Simard vd. 2005, Erkaymaz vd. 2014, Erkaymaz ve Ozer 2016):

$$D_{Global} = \frac{1}{E_{Global}} \quad (1)$$

$$E_{Global} = \frac{1}{N(N-1)} \sum_{i \neq j \in N} \frac{1}{d_{ij}} \quad (2)$$

Burada, N , ağdaki düğüm sayısını ifade etmekte, d_{ij} ise düğümler arası en kısa yol uzunluğunu ifade etmektedir. Lokal verim ise aşağıdaki gibi tanımlanmaktadır (Simard vd. 2005, Erkaymaz vd. 2014, Erkaymaz ve Ozer 2016):

$$D_{Local} = \frac{1}{E_{Local}} \quad (3)$$

$$E_{Local} = \frac{1}{N} \sum_{i \in N} E(G_i) \quad (4)$$

$$E(G_i) = \frac{1}{N_i(N_i-1)} \sum_{k \neq l \in N} \frac{1}{d_{kl}} \quad (5)$$

Burada N_i , i . düğümün bağlı olduğu komşu sayısını d_{kl} ise i . düğüm çıkarıldığında elde edilen çizgenin komşu düğümler arası en kısa yol uzunluğunu ifade etmektedir.

Küçük-Dünya ağ yapısı oluşturulduktan sonra elde edilen ağın eğitim süreci gerçekleştirilmektedir. Eğitim sürecinde geriye yayılım algoritması kullanılarak sinaptik bağlantı ağırlıkları güncellenmektedir. Her bir nöronun aktivasyon süreci ise bipolar-sigmoidal fonksiyon kullanılarak gerçekleştirilmiştir. Geriye yayılım algoritması ağırlık uzayında minimum çıkış hatasını tespit etmeye çalışmakta olup çıkış ve ara katman nöronlarının ağırlıkları sırasıyla aşağıdaki gibi ifade edilmektedir (Erkaymaz vd. 2014, Erkaymaz ve Ozer 2016):

Çıkış katmanı:

$$\delta_o(t) = y_o(1 - y_o)(d_o - y_o) \quad (6a)$$

$$\Delta W_{no}(t) = \alpha y_n \delta_o(x) \quad (6b)$$

$$W_{no}(t+1) = W_{no}(t) + \Delta W_{no}(t) + m \Delta W_{no}(t) \quad (6c)$$

Ara katmanlar:

$$\delta_n(t) = y_n(t)(1 - y_n(t)) \sum_{o=1}^l \delta_o(t) w_{no}(t) \quad (6d)$$

$$\Delta w_{in}(t) = \alpha x_i(t) \delta_n(t) \quad (6e)$$

$$W_{in}(t+1) = W_{in}(t) + \Delta W_{in}(t) + m \Delta W_{in}(t) \quad (6f)$$

Burada, y ağ çıkışı, d beklenen çıkışı, W ve ΔW parametreleri sırasıyla sinaptik ağırlıkları ve ağırlıklardaki değişimi göstermektedir. α öğrenme katsayısını, m momentum katsayısını ve son olarak, δ hatanın türevini ifade etmektedir. Belirlenen ağların eğitim performanslarını ölçmek amacıyla ortalama karesel hata (MSE) performans kriteri olarak seçilmiş ve aşağıdaki gibi hesaplanmıştır (Erkaymaz vd. 2014, Erkaymaz ve Ozer 2016):

$$MSE = \frac{1}{2CN} \sum_{i=1}^{CN} (y_i - d_i)^2 \quad (7)$$

Burada, CN , çıkış katmanı nöron sayısını, y_i ağ çıkışını ve d_i beklenen çıkışı ifade etmektedir.

Eğitim sürecinde ezberleme ve aşırı öğrenme problemlerinin önüne geçebilmek amacıyla 10 kat çapraz doğrulama metodu kullanılmıştır (Stone 1974). Ağın performansının ölçümü için, MSE parametresinin yanında, kök ortalama karesel hata (RMSE), ortalama karesel hata (MAE) ve determinasyon katsayı parametreleri hesaplanarak ağın istatistiksel performans analizi yapılmıştır. İstatistiksel performans analizi için kullanılan parametreler aşağıdaki gibi hesaplanmıştır (Erkaymaz vd. 2014, Erkaymaz ve Ozer 2016):

$$MAE = \frac{1}{CN} \sum_{i=1}^{CN} |y_i - d_i| \quad (8)$$

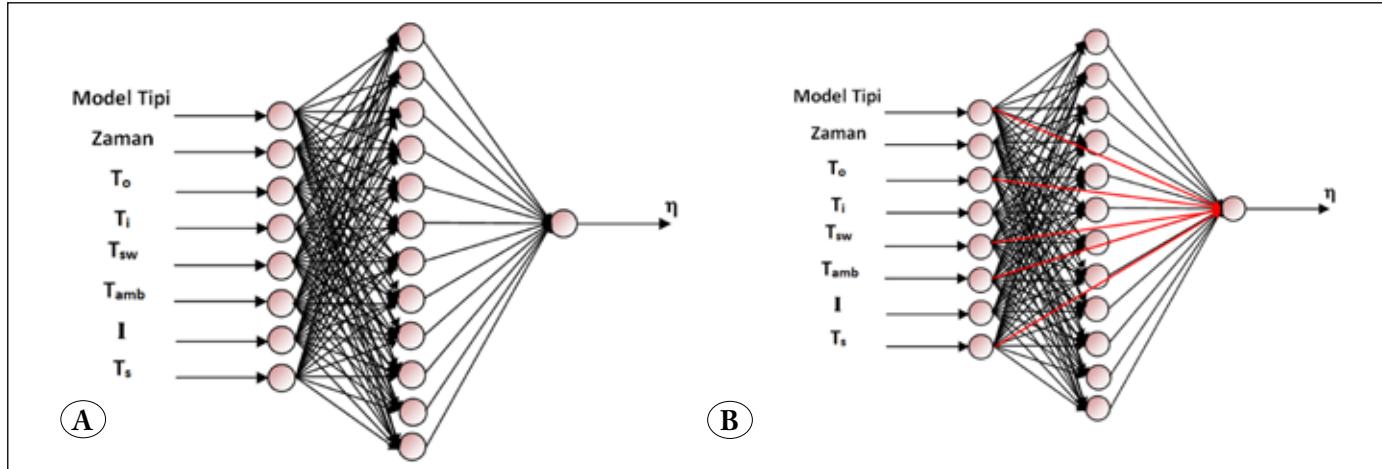
$$RMSE = \sqrt{\frac{1}{2CN} \sum_{i=1}^{CN} (y_i - d_i)^2} \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^{CN} (y_i - d_i)^2}{\sum_{i=1}^{CN} d_i^2} \quad (10)$$

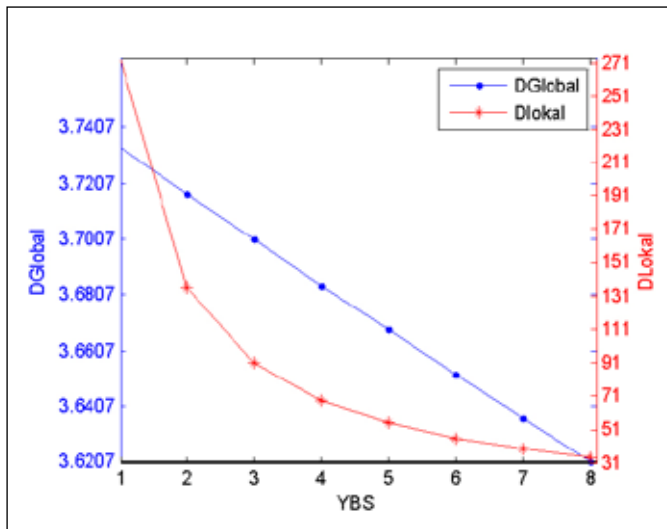
MSE, MAE ve RMSE değerlerinin sıfıra, R^2 değerinin de 1'e yakın olması oluşturulan ağın güvenilir sonuçlar ürettiğini gösterecektir.

3. Sonuçlar ve Tartışma

Bu çalışmada, geleneksel bir FFANN'de Newman-Watts yaklaşımı kullanılarak elde edilen SW ağ performansını analiz etmek için daha önce Erkaymaz vd. (2014) tarafından kullanılan iki farklı problem: "havalı güneş kollektörlerinin



Şekil 2. Havalı güneş kolektörü termal performansını ölçmek için kullanılan ağ topolojileri; (A) FFANN topolojisi, (B) FFANN SW ağ topolojisi.



Şekil 3. D_{Global} ve D_{Lokal} parametrelerinin ağa eklenen yeni bağlantılarla değişimleri.

termal performanslarının tahmini” ve “yönlendirilmiş levhaların eğilme dirençlerinin tahmini” kullanılmıştır. Her iki problem için, optimum FFANN topolojisi belirlenip düzenli ağ olarak kabul edilmiştir. Bu ağ yapısına Newman-Watts yaklaşımı kullanılarak yeni bağlantı ekleme süreci uygulanmış ve SW ağları elde edilmiştir. Elde edilen ağ topolojilerinin performansları karşılaştırmalı olarak analiz edilmiştir.

3.1. Havalı güneş kolektörlerinin termal performanslarının tahmini

Havalı güneş kolektörlerinin termal performansı Caner vd. (2011) tarafından deneysel ve bir ANN model kullanılarak araştırılmıştır. Çalışmada, deneysel olarak performansı

ölçülen havalı güneş kolektörünün termal performansının ANN tabanlı bir modelle tahmini gerçekleştirilmiştir. Söz konusu çalışmada 3 katmanlı ve her katmanında sırasıyla, 8, 20 ve 1 nöron bulunan FFANN topolojisi kullanılmıştır. Bu çalışmada, Caner vd. (2011) tarafından yapılan çalışmanın veri seti, düzenli ağ ve SW ağlarının termal performansının ölçülmesi için kullanılmıştır. Öncelikle, FFANN topolojisi yapılan denemeler sonucunda 8-12-1 olarak belirlenmiştir. Bu problem için oluşturulan FFANN topolojisi ve Newman-Watts yaklaşımı uygulandığında elde edilen SW ağın topolojisi Şekil 2.'de verilmiştir.

Caner vd. (2011) tarafından kullanılan giriş ve çıkışlar aynen kullanılmıştır. T_i kolektör giriş sıcaklığını, T_o kolektör çıkış sıcaklığını, T_{sw} depolanmış su sıcaklığını, T_{amb} ortam sıcaklığını, T_s kolektör yüzey sıcaklığını, I güneş ışınım yoğunluğunu, Zaman ölçüm zamanını, ve Model Tipi ise tasarlanan 2 farklı kolektörü ifade etmektedir. h çıkışı ışınım şiddetini göstermektedir. Bir sonraki adımda, 8-12-1 şeklinde topolojisi belirlenen FFANN modelinin olası maksimum yeni bağlantı sayısı (YBS) hesaplanmış ve 8 olarak elde edilmiştir. Mevcut ağa olası maksimum bağlantı sayısı kadar yeni bağlantı eklenmiş ve her bağlantı eklendiğinde D_{Lokal} ve D_{Global} parametreleri hesaplanmıştır. Elde edilen sonuçlar Şekil 3'te gösterilmiştir.

Şekil 3'de görüldüğü gibi Newman-Watts yaklaşımı kullanıldığında, yeni bağlantı eklendikçe D_{Global} ve D_{Lokal} değerlerini azalmaktadır. Dolayısıyla, eklenen bağlantılar arttıkça SW ağ davranışının görülme olasılığı da yükselmektedir. Ancak, bağlantı sayısı değişimi ile D_{Global} deki değişimin oldukça küçük olduğu görülmektedir. Şekil-3 FFANN'nin SW ağ yapısına sahip olabilmesi için

YBS değerinin 2-8 arasında olabileceğini göstermektedir. Ağ topolojileri elde edildikten sonra ağ performanslarını analiz edebilmek için veri setinin %80'i eğitim, %20'si test için ayrılmış ve 10 kat çapraz doğrulama yöntemiyle eğitim süreci gerçekleştirilmiş ve test datasıyla ağın çıkış performansı hesaplanmıştır. İstatistiksel parametre (R^2 , MSE , $RMSE$, MAE) değerleri 50 deneme ortalaması ile elde edilmiştir. 50 deneme için en küçük karesel hata değerine sahip deneme seçilmiş ve gözlemlenen istatistiksel parametre değerleri Çizelge 1'de verilmiştir.

Çizelge 1'de görüldüğü gibi en iyi performansa sahip SW ağ topolojisi YBS=5 değeri için elde edilmiştir. Ayrıca, ağ çıkışlarının deneysel, düzenli (YBS=0) ve Newman-Watts Küçük-Dünya ağı (YBS=5) için performansları Şekil 4'te verilmiştir. Caner vd. (2011) yapmış oldukları çalışmada, bu çalışmadan farklı olarak daha fazla ara katman nöron sayısı, Levenberg-Marquart algoritması kullanmışlar ve tüm veri seti ile test ettikleri ağ için ortalama R^2 , RMSE ve MAE ağ performans parametrelerini sırasıyla 0.9967, 0.0173 ve 0.9879 olarak hesaplamışlardır. Bu çalışmada ise veri setinin %20'i eğitim sürecine katılmamasına rağmen daha küçük RMSE MAE değerleri ve yaklaşık R^2 değeri elde edilmiştir. Dolayısıyla, Newman-Watts SW ağ yaklaşımının düzenli FFANN'nin performansını artırdığı görülmektedir.

3.2. Yönlendirilmiş levhaların eğilme dirençlerinin (MOR) tahmini

Bu çalışmada, düzenli FFANN yapısından SW ağ yapısına sahip FFANN elde etmek ve performansını karşılaştırabilmek için Yapıcı (2008) tarafından çalışılan yönlendirilmiş levhaların kırılma katsayılarının (MOR) bulunması problemi ikinci problem olarak ele alınmıştır. Yapıcı (2008) çalışmasında deneysel olarak, sarı çam kullanılarak yönlendirilmiş levha üretimini araştırmış ve elde edilen ürünün eğilme dirençlerini ölçmüştür. Farklı oranlarda yapıştırıcı madde karışımı ile sarı çam liflerinden yönlendirilmiş levha üretilmeye çalışılmıştır. Üretilen bu levhalar farklı süre ve sıcaklık koşulları altında, sıkıştırılmıştır. TS EN 310 1999 standardına uygun olarak elde edilen 27 farklı yönlendirilmiş levha farklı sıkıştırma oranlarında test edilerek eğilme dirençleri ölçülmüştür.

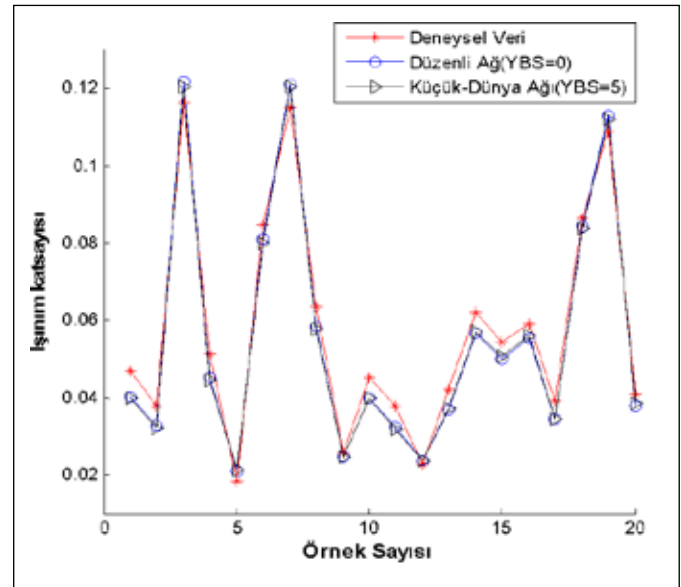
Ölçülen verilerden yapıştırıcı madde oranı, süre ve sıkıştırma oranı giriş olarak kullanılmış, yatay ve dikey eğilme direnci değerleri çıkış olarak kullanılmıştır. İlk olarak optimum düzenli FFANN topolojisi 3-8-8-2 olarak elde edilmiştir. Bu problemde giriş sayısı az olması nedeniyle 2 ara katmanlı bir mimari tercih edilmiştir. Tasarlanan düzenli FFANN

ağ yapısı ve Newman-Watts yaklaşımıyla elde edilen SW FFANN ağ yapısı Şekil 5'te gösterilmiştir.

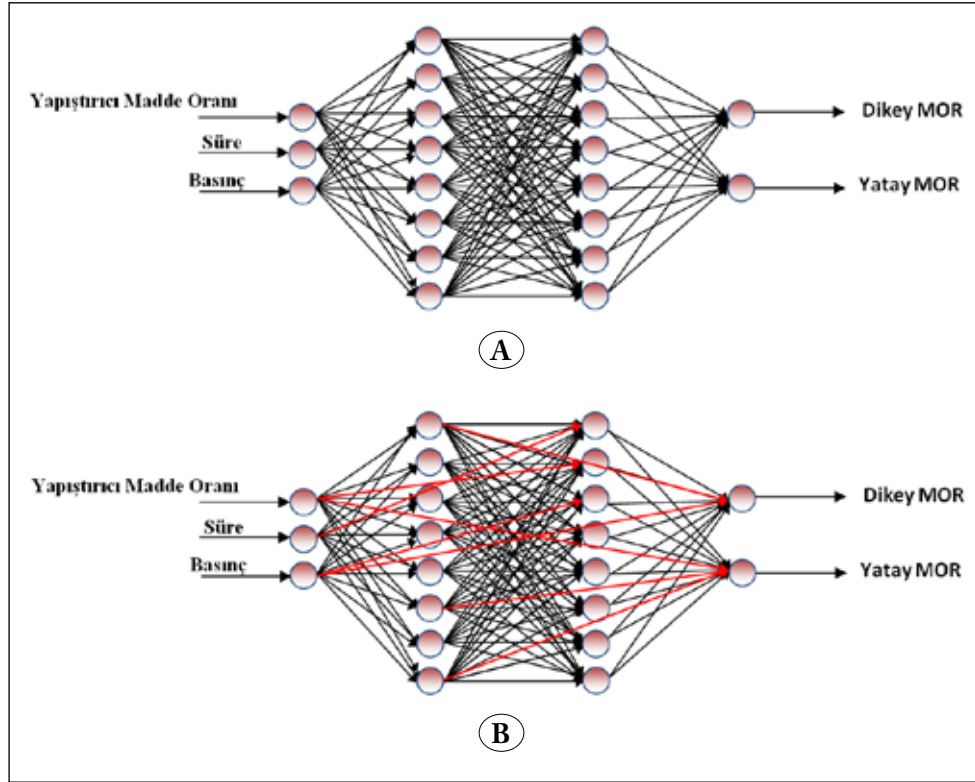
Bir sonraki adımda, 3-8-8-2 şeklinde topolojisi belirlenen FFANN modelinin olası maksimum yeni bağlantı sayısı (YBS) hesaplanmış ve 46 olarak elde edilmiştir. Mevcut ağa olası maksimum bağlantı sayısı kadar yeni bağlantı eklenmiş ve her bağlantı eklendiğinde D_{Lokal} ve D_{Global} parametreleri hesaplanmıştır. Elde edilen sonuçlar Şekil 6'da gösterilmiştir. Bir önceki problem için gözlemlendiği gibi burada da, yeni bağlantı eklendikçe D_{Global} ve D_{Lokal} değerlerinin azaldığı gözlemlenmektedir. YBS değeri arttıkça, düzenli FFANN ağ yapısından SW FFANN ağ yapısına geçiş yapılmakta olup SW ağ davranışının görülme olasılığı da yükselmektedir. $D_{Lokal} \approx 5$ değeri için lokal verimdeki değişim minimum

Çizelge 1. Havalı güneş kolektörlerinin termal performanslarının tahmini için topolojik performans analizleri.


YBS	R^2	RMSE	MAE
0	0.99389	0.005049	0.004513
1	0.824403	0.020357	0.016706
2	0.814726	0.020742	0.016968
3	0.99348	0.005188	0.004607
4	0.897413	0.016819	0.014115
5	0.994024	0.005001	0.004467
6	0.993518	0.005176	0.004596
7	0.716968	0.029966	0.022561
8	0.797862	0.025744	0.019443



Şekil 4. Düzenli FFANN ve SW ağlarının termal performanslarının deneysel verilerle karşılaştırılması.



Şekil 5. Eğilme direncinin tahmini için kullanılan ağ topolojileri; (A) düzenli FFANN ağ yapısı, (B) SW FFANN ağ yapısı.



Şekil 6. D_{Global} ve D_{Lokal} parametrelerinin ağa eklenen yeni bağlantılarla değişimleri.

olmaktadır. Dolayısıyla, SW ağ yapısının 5-46 arası YBS değerleri ile gözlemlenebileceği tespit edilmiştir.

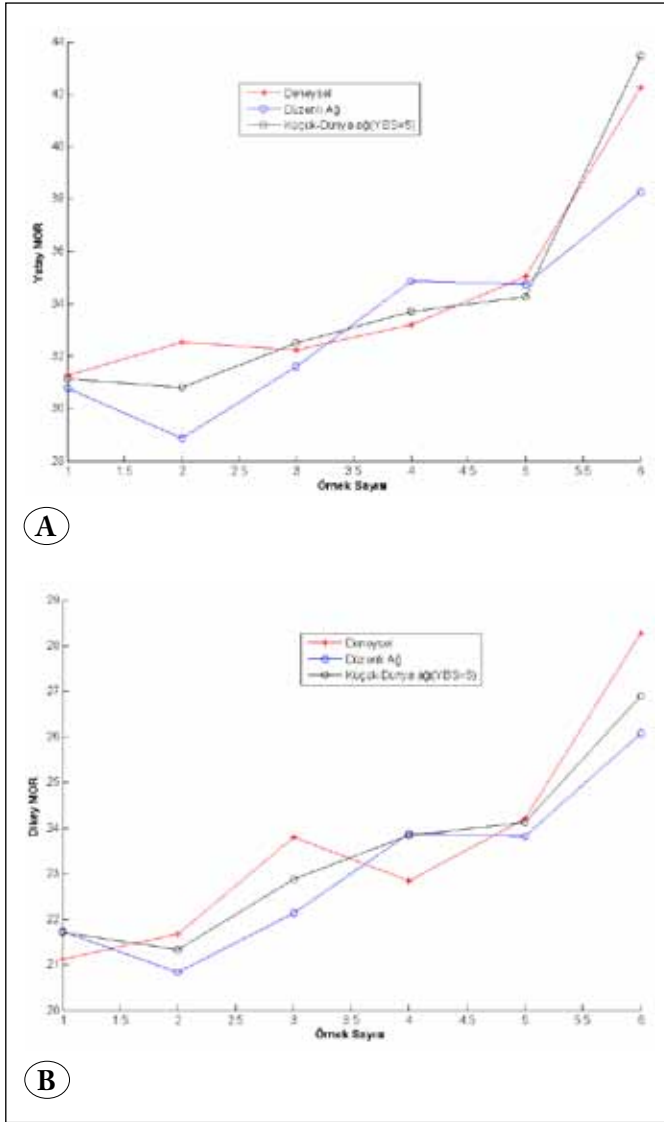
Benzer şekilde ağ performanslarını analiz edebilmek için veri setinin %80'ni eğitim, %20'si test için ayrılmış ve 10 kat çapraz doğrulama yöntemiyle eğitim süreci gerçekleştirilmiş ve test verisiyle ağın çıkış performansı hesaplanmıştır. İstatistiksel parametre (R^2 , MSE , $RMSE$, MAE) değerleri

Çizelge 2. Yönlendirilmiş levha eğilme direncinin tahmini için topolojik performans analizleri.

YBS	Çıkış 1- R^2	Çıkış 2- R^2	RMSE	MAE
0	0.995518	0.99598	1.85029	1.3158
5	0.999515	0.998646	0.798195	0.605511
10	0.999072	0.996762	1.173301	0.888898
15	0.995376	0.99626	1.869465	1.332427
20	0.996048	0.996638	1.748248	1.295876
25	0.995998	0.99607	1.793905	1.3473
30	0.995467	0.996822	1.806345	1.296931
35	0.995119	0.99668	1.880329	1.449603
40	0.995122	0.996688	1.87938	1.449586
45	0.995122	0.996693	1.878771	1.448881

50 deneme ortalaması ile elde edilmiştir. 50 deneme için en küçük karesel hata değerine sahip deneme seçilmiş ve gözlemlenen istatistiksel parametre değerleri Çizelge 2'de verilmiştir.

Çizelge 2'de görüldüğü gibi en iyi performansa sahip SW ağ topolojisi YBS=5 değeri için elde edilmiştir. Ayrıca, ağ çıkışlarının deneysel, düzenli (YBS=0) ve Newman-Watts



Şekil 7. Ağ çıkış performanslarının karşılaştırmalı gösterimi (A) Yatay MOR, (B) Dikey MOR.

Küçük-Dünya ağı (YBS=5) için performansları Şekil 7'de verilmiştir. Performans parametreleri, Çıkış 1- R^2 , Çıkış 2- R^2 RMSE ve MAE ağ performans parametrelerini sırasıyla 0.9995, 0.9986, 0.7981, 0.6055 olarak hesaplamışlardır. Düzenli FFANN ağı için (YBS=0) elde edilen değerlerle karşılaştırıldığında, SW FFANN için R^2 değerlerinde iyileştirmeler nispeten az olsa da daha küçük RMSE ve MAE değerlerinin elde edilebildiği görülmektedir. Dolayısıyla, Newman-Watts SW ağ yaklaşımının düzenli FFANN'nin performansını artırdığı görülmektedir.

Sonuç olarak bu çalışmada, daha önce Erkaymaz vd. (2014) ve Erkaymaz ve Ozer (2016) tarafından düzenli FFANN

ağ yapılarının performansını artırmaya yönelik yapılan çalışmalarından farklı olarak, FFANN'lerde SW ağ yapısı elde etmek için Watts-Strogatz yaklaşımı yerine Newman-Watts yaklaşımının da kullanılacağı, ve bu yaklaşımla da düzenli FFANN'lere göre daha iyi performans elde edilebileceği gösterilmiştir. Bundan sonraki çalışmalarda, SW ağ yapısına sahip FFANN'lerde Newman-Watts ile Watts-Strogatz yaklaşımlarının performansları karşılaştırılacak ve hangi yaklaşımın düzenli FFANN'lerin performansını daha fazla artırabileceği ve bunun nedenleri araştırılacaktır.

4. Kaynaklar

- Barabasi, AL., Albert, R. 1999.** Emergence of Scaling in Random Networks. *Science*, 286: 509-512.
- Bassett, DS., Bullmore, E. 2006.** Small-world brain networks. *The Neuroscientist* 12: (6): 512-523.
- Buhmann, Martin D. 2003.** Radial Basis Functions: Theory and implementations, Cambridge University Press, 259 pp.
- Camacho, J., Guimerà, R., Nunes Amaral LA. 2002.** Robust patterns in food web structure. *Phys. Rev. Let.*, 88: 228102-1-4.
- Caner, M., Gedik, E., Keçebaş, A. 2011.** Investigation on thermal performance calculation of two type solar air collectors using artificial neural network. *Exp. Sys. W. App.*, 38(3): 1668-1674.
- Erkaymaz O., Ozer M, Yumusak N. 2014.** Impact of small-world topology on the performance of a feed-forward artificial neural network based on 2 different real-life problems. *Turk. J. Elec. Eng. and Comp. Sci.*, 22: 708-718.
- Erkaymaz, O., Ozer, M. 2016.** Impact of small-world network topology on the conventional artificial neural network for the diagnosis of diabetes. *Chaos Sol. and Fract.*, 83: 178-185.
- Gurney, K. 2002.** An Introduction to Neural Networks, Routledge, UCL Press, 248 pp.
- Haykin, S. 1999.** Neural Networks—A Comprehensive Foundation, 2nd Edition, Prentice-Hall, Englewood Cliffs, NJ, 936 pp.
- Jeong, H., Mason, SP., Barabási, AL., Oltvai, ZN. 2001.** Lethality and centrality in protein networks. *Nature*, 411:41-42.
- Latora, V., Marchiori, M. 2001.** Efficient behavior of small-world networks. *Phys. Rev. Let.*, 87:198701.
- Latora, V., Marchiori, M. 2003.** Economic small-world behavior in weighted networks. *Eur. Phys J. B*, 32: 249-263.
- Magnitskii, NA. 2001.** Some New Approaches to the Construction and Learning of Artificial neural Networks. *Comp. Math. and Mod.*, 12(4):293-304.
- Newman, ME.J, Watts. DJ. 1999.** Scaling and percolation in the small-world network model. *Phys. Rev. E*, 60: 7332-7342.

- Ozer, M., Uzuntarla, M., Kayıkçıoğlu, T., Graham, L.J. 2008.** Collective temporal coherence for subthreshold signal encoding on a stochastic small-world Hodgkin-Huxley neuronal network. *Phys. Let. A*, 372: 6498-6503.
- Ozer, M., Perc, M., Uzuntarla, M. 2009.** Controlling the spontaneous spiking regularity via channel blocking on Newman-Watts Networks of Hodgkin-Huxley neurons. *Eur. Phys. Let.*, 86 (4): 40008.
- Ozer, M., Perc, M., Uzuntarla, M. 2009.** Stochastic resonance on Newman-Watts networks of Hodgkin-Huxley neurons with local periodic driving. *Phys. Let. A*, 373: 964-968.
- Shuzhong, Y., Siwei, L., Jianyu, Li. 2006.** Building Multi-layer Small World Neural Network. *Lect. Note in Comp. Sci. Ser.*, 3971: 695-700.
- Simard, D., Nadeau, L., Kröger H. 2005.** Fastest learning in small-world neural networks. *Phys. Let. A*, 336:1, 8-15.
- Sporns, O., Chialvo, DR., Kaiser, M., Hilgetag, CC. 2004.** Organization, development and function of complex brain networks. *Trends in Cogn. Sci.*, 8(9): 418-425.
- Stone, M. 1974.** Cross-validation choice and assessment of statistical predictions. *J. Roy. Stat. Soc.*, 36: 111-1474.
- Sun, M., Stam, A., Steuer, RE. 1996.** Solving Multiple Objective Programming Problems Using Feed-Forward Artificial Neural Networks: The Interactive FFANN Procedure. *Man. Sci.*, 42(6):835-849,
- TSEN 310 1999.** Wood-Based panels-Determination of modulus of elasticity and of bending strength, TSE, Ankara.
- Watts, DJ., Strogatz, SH. 1998.** Collective dynamics of small-world networks, *Nature*, 393: 409-10.
- Watts, DJ. 2003.** Small Worlds: The Dynamics of Networks Between Order and Randomness, Princeton, Princeton University Press, NJ, 280 pp.
- Yapıcı, F. 2008.** The effect of some production factors on the properties of osb made from scotch pine (pinus sylvestris l.) wood. *Doktora Tezi*, Zonguldak Karaelmas Üniversitesi, 143 s.
- Yılmaz, E., Uzuntarla, M., Ozer, M., Perc, M. 2013.** Stochastic resonance in hybrid scale-free neuronal networks. *Phys. A*. 392(22): 5735-5741.
- Yılmaz, E., Baysal, V., Ozer, M., Perc, M. 2016.** Autaptic pacemaker mediated propagation of weak rhythmic activity across small-world neuronal Networks. *Phys. A*, 444:538-546.
- Yılmaz, E., Baysal, V., Perc, M., Ozer, M. 2016.** Enhancement of pacemaker induced stochastic resonance by an autapse in a scale-free neuronal network. *Sci. China Tech. Sci.*, 59(3):364-370.