



İki Yeni Çok Katmanlı Aşırı Öğrenme Makinesi ve Rüzgar Hızı Tahmininde Kıyaslamalı Başarımı

Two New Multilayer Extreme Learning Machines and Comparative Performance on Wind Speed Forecasting

Cihan KARAKUZU^{1,*}

¹ Bilgisayar Mühendisliği, Bilecik Şeyh Edebali Üniversitesi, Bilecik, Türkiye, **Orcid:** 0000-0003-0569-098X

Araştırma Makalesi

Gönderilme Tarihi : 23/03/2020

Kabul Tarihi : 02/08/2020

Anahtar Kelimeler

Aşırı Öğrenme Makinesi
Çok Katmanlı ELM
Çok Katmanlı Kernel-ELM
Başarım Kıyaslama
Rüzgar Hızı Tahmini

Research Paper

Received Date : 23/03/2020

Accepted Date : 02/08/2020

Keywords

Extreme Learning Machine
Multilayer ELM
Multilayer Kernel-ELM
Performance Comparison
Wind Speed Forecasting

Özet

Türev tabanlı öğrenme algoritmalar ile ele alınan problemin doğasına bağlı olarak eğitim uzun zaman almaktadır. Aşırı öğrenme makine-leri (AÖM) bu bağlamda önemli ölçüde bir açılım getirmiştir. AÖMler, girdi-çıkış eğitim verilerinin mevcut olduğu problemler için yine-lemeli algoritmalara kıyasla çok hızlı öğrenme sağlayabilmektedir. AÖMlerin en belirgin sakıncası, bazı ağ parametrelerinin rastgele atanmasıdır. Bu nedenle, bu sakıncanın önlenmesi için çalışmalar devam etmektedir. Bu bağlamda, 2016 ve 2018 yıllarında sırasıyla çok katmanlı aşırı öğrenme makinesi (ÇK-AÖM) ve çekirdek tabanlı çok katmanlı aşırı öğrenme makinesi (ÇK-ÇAÖM) yapıları geliştirilmiştir. Bu makalede, bu iki yeni çok katmanlı AÖM yapılarının başarımı rüzgar hızı tahmini problemi üzerinde incelenmiştir. Bahse konu ağların yapısal ve eğitim parametrelerinin farklı değerleri için ağ eğitim algoritmaları çok kez çalıştırılarak elde edilen sonuçlar istatistiksel olarak değerlendirilmiştir. Bu istatistiksel verilere dayalı olarak, her bir ağın üstün ve sakıncalı tarafları belirlenmiştir.

Abstract

Training takes a long time depending on the nature of the problem using derivative based learning algorithms. Extreme learning machines (ELMs) have made a significant expansion in this context. ELMs are able to provide very fast learning compared to iterative algorithms for problems where input-output training data are available. The most obvious drawback of ELMs is the random assignment of some network parameters. For this reason, works on preventing this is still going on. In this context, multilayer extreme learning machine (ML-ELM) and kernel-based multilayer extreme learning machine (ML-KELM) structures have recently been developed in 2016 and 2018 respectively. In this paper, the performance of these new multilayered ELM structures has been examined on the wind speed forecasting problem. Performance indicators for the different values of structural and training parameters of the networks have been statistically evaluated by running the training algorithms many times in each case. Based on these statistical data, the advantages and disadvantages of each network are presented.

1. Giriş

Günümüzde yapay öğrenme çoğu problemin çözümünde yaygın olarak kullanılan kavram olmuştur. Bu kavram yapay sinir ağları (YSA) ile birlikte ortaya çıkmıştır. YSA, yüksek eğriselliğe sahip problemlerin çözümünde klasik yöntemlere göre önemli bir kolaylık sağlamıştır. Fakat bu yapıların eğitim süreci geriye yayılım gibi türev tabanlı öğrenme algoritmalarının özelliği

sebebiyle oldukça uzun sürebilmektedir. Bu sakıncanın üstesinden gelmek için aşırı öğrenme makinesi (AÖM) [1] adı verilen yeni bir öğrenme algoritması geliştirilmiştir. Bu algoritma başlangıçta tek katmanlı ileri beslemeli bir YSA için idi. Bu algortmada, YSA hücrelerine ait bağlantı ağırlıkları ve eşikler rasgele atanarak çıkış bağlantı ağırlıkları Moore-Penrose tersine dayalı bir formül ile belirlenmektedir.

AÖM ilk kez tanımlandığından beri zayıf taraflarını kuvvetlendirmek adına [2]'deki gibi birkaç geliştirme yapılmıştır. Bu geliştirmeler genellikle mevcut sinir ağları

* Sorumlu Yazar (Corresponding Author): cihan.karakuzu@bilecik.edu.tr



ve onların mimarileri üzerine olmuştur. Buna en tipik örnek AÖM öğrenmenin ANFIS ağına uyarlaması (AÖM-ANFIS) olan [3, 4] çalışmalarıdır. Diğer bir dikkate değer gelişme ise Meta-ELM [5] adı verilen ağ mimarisidir. AÖM-ANFIS ve Meta-AÖM başarımları sırasıyla yazarın [4] ve [6]'deki çalışmalarında incelenmiştir. AÖM algoritmaları üzerine çalışmalar devam etmekte olup gelişmeler bilimsel camiada duyurulmaktadır. Yakın geçmişte, önemli bir gelişme olarak AÖMnin çok katmanlı yapılar için de uygun olduğu bildirilmiştir. Bu bağlamda, 2016 ve 2018 yıllarında sırasıyla çok katmanlı aşırı öğrenme makinesi (ÇK-AÖM) [7] ve çekirdek tabanlı çok katmanlı aşırı öğrenme makinesi (ÇK-ÇAÖM) [8] yapıları geliştirilmiştir.

Bu çalışmada, ÇK-AÖM ve ÇK-ÇAÖM yapılarının başarımları kısa vadeli rüzgar hızı tahmini problemi üzerinde incelenmiştir. Anılan iki AÖM mimarisinin öğrenmesi için bu çalışmada kullanılmak üzere eğitim ve test veri setleri [10]'da kullanıldığı gibi hazırlanmıştır. Eğitim seti kullanılarak ilgili eğitim algoritması ile ÇK-AÖM ve ÇK-ÇAÖM tahmin modelleri elde edilmiştir. Daha sonra, elde edilen her bir modelin genelleme başarımları test veri setleri kullanılarak incelenmiştir. Elde edilen rüzgar hızı tahmin modellerinin genel istatistiksel başarımlarını panoramasını elde etmek için ağların farklı parametreleriyle bahsedilen eğitim ve test işlemlerinin tekrarlanmasıyla birçok deney yapılmıştır.

2. Yöntem, Mimari ve Algoritmalar

Klasik AÖM [6] detaylıca tanımlandığından burada verilmeyecek olup bu bölümde sadece üzerinde çalışılan ÇK-AÖM ve ÇK-ÇAÖM'nin mimarisi ve eğitim algoritmaları tanımlanacaktır.

2.1. Çok katmanlı aşırı öğrenme makinesi (ÇK-AÖM)

ÇK-AÖM [7]'de hiyerarşik AÖM adıyla önerilmiş ve tanımlanmış bir çok katmanlı AÖM mimarisidir. Bu ağ yapısı birbirinden bağımsız iki (temsili ve final) öğrenme prosedüründen oluşan hiyerarşik bir öğrenme şemasını kullanır. Temsili öğrenme sadece giriş örnekleri ile katman katman ilerleyerek son katmana kadar icra edilir. Bu tür hiyerarşik öğrenme bir özellik çıkarımı olarak değerlendirilebilir. Final öğrenme ise son katmanda hiyerarşik olarak işlenmiş giriş ve çıkış örnekleri ile klasik AÖM yöntemi ile gerçekleşir. n harici giriş, m katmanlı ve \bar{o} harici çıkışlı bir ÇK-AÖMnin öğrenme aşamasındaki mimarisi Şekil 1'de verilmiştir. Şekilde, i ve j indisleri sırasıyla katman numarası ve o katmandaki hücre numaralarını göstermektedir.

Ağ eğitmek amaçlı S adet giriş-çıkış örneğimiz olduğunu varsayalım $\{(\mathbf{x}_s, \mathbf{t}_s), s=1, \dots, S\}$. $\mathbf{X}^{(i)} = [\mathbf{x}_1^{(i)}, \dots, \mathbf{x}_S^{(i)}]$, i nci katman çıkışındaki veri temsili matrisini gösterir. Bu veri temsili Eş.(1) ile elde edilir. Eşitliğin solundaki ilk terim ($\mathbf{H}^{(i)}$) i nci katmanın girişindeki giriş örnekleri matrisi ile elde edilen hücre çıkışlarının hesaplanıp toplu olarak tutulduğu matrisi, ikinci terim ($\boldsymbol{\gamma}^{(i)}$) ise hücre çıkışlarından katman çıkış düğümlerine bağlantı ağırlıklarını göstermektedir.

$$\mathbf{H}^{(i)} \boldsymbol{\gamma}^{(i)} = \mathbf{X}^{(i)} \quad (1)$$

Mimarideki son katman hariç her bir katman oto-kodlayıcı olarak adlandırılır. Ağdaki her bir katman, ortogonal rasgele atanmış kendi giriş bağlantı ve eşik parametrelerine ($\mathbf{W}^{(i)}, b^{(i)}$) sahiptir. Bu parametreler ile Eş. (1)'deki katman çıkış matrisi hesabı Eş.(2-4) ile yapılır. Eşitliklerdeki g hücre aktivasyonunu, L_i ise i nci katmandaki hücre/düğüm sayısını göstermektedir.

$$\mathbf{H}^{(i)} = [\mathbf{h}^{(i)}(\mathbf{x}_1), \dots, \mathbf{h}^{(i)}(\mathbf{x}_S)]' \quad (2)$$

$$\mathbf{h}^{(i)}(\mathbf{x}_s) = g(\mathbf{x}_s \mathbf{W}^{(i)} + b^{(i)}) \quad (3)$$

$$\mathbf{h}^{(i)}(\mathbf{x}_s) = [h_1^{(i)}(\mathbf{x}_s), \dots, h_{L_i}^{(i)}(\mathbf{x}_s)] \quad (4)$$

Bu hesap sonrası, oto-kodlayıcı katmanlar için Eş. (1)'den Moore-Penrose genelleştirilmiş ters ile kararlılığı arttırmak için λ düzenleme faktörü eklenmiş halde Eş. (5) [8] kullanılarak dönüşüm matrisi belirlenir. Son katman için bu hesaplama istenen çıkış örnek matrisi (\mathbf{T}) ile Eş. (6) kullanılarak yapılır.

$$\boldsymbol{\gamma}^{(i)} = (\mathbf{H}^{(i)})' \left(\frac{1}{\lambda} + \mathbf{H}^{(i)} (\mathbf{H}^{(i)})' \right)^{-1} \mathbf{X}^{(i)} \quad (5)$$

$$\boldsymbol{\gamma}^{(m)} = (\mathbf{H}^{(m)})' \left(\frac{1}{\lambda} + \mathbf{H}^{(m)} (\mathbf{H}^{(m)})' \right)^{-1} \mathbf{T} \quad (6)$$

Böylece ÇK-AÖMnin öğrenme aşaması tamamlanır. Ağ eğitildikten sonra Şekil 2'de verilen mimari ile kullanılır. Şekil 2'den de anlaşılacağı üzere eğitim aşamasında belirlenen oto-kodlayıcı katmanların dönüşüm matrisleri, doğrudan giriş matrisini kodlayarak dönüştürmek amacıyla kullanılırlar. Yukarıda hem grafiksel hem de matematiksel olarak tanımlanan ÇK-AÖMnin eğitim ve eğitim sonrası kullanımını gösteren yazar tarafından yazılan kaynak koda[†] verilen bağdan ulaşılabilir.


[†] <http://web.bilecik.edu.tr/cihan-karakuzu/kaynak-kodlar-source-codes/>

2.2. Çok katmanlı çekirdek aşırı öğrenme makinesi (ÇK-ÇAÖM)


Önceki alt bölümden görüleceği üzere, ÇK-AÖM'de ağırlık başarımını etkileyen çok sayıda rasgele atanmış parametre ($W^{(i)}$, $b^{(i)}$) mevcuttur. Çekirdek öğrenme yöntemi $W^{(i)}$ ve $b^{(i)}$ gibi ağırlık parametrelerinin ayarlanmasına ihtiyaç duymaksızın optimal başarımlar sağlayan öğrenme olarak bilinir. ÇK-ÇAÖM'nin kaşifine [8] göre, çok katmanlı AÖM'de hücrede çekirdek fonksiyonu kullanılırsa ağırlık genelleştirme yeteneği optimal olur. Çekirdek fonksiyonunun hücre aktivasyon fonksiyonu olarak kullanılması her bir katmanda $W^{(i)}$ $b^{(i)}$ rasgele atanmış ağırlık

parametrelerini gerektirmez. Çekirdek fonksiyon kullanımının diğer bir getirisi de genelleştirilmiş Moore-Penrose tersi yerine doğrudan tersi alınabilir kare katman çıkış matrisi elde etmeye imkan vermesidir. ÇK-ÇAÖM mimarisinde, $X^{(i)}$ girişi bir çekirdek fonksiyonu aracılığı ile bir çekirdek $\Omega^{(i)}$ matrisine dönüştürülür. Bu çalışmada çekirdek fonksiyonu olarak Eş. (7)'de tanımlanan radyal tabanlı fonksiyon kullanılmıştır.

$$K^{(i)}(x_k, x_j) = \exp\left(-\frac{\|x_k - x_j\|}{2\sigma_i^2}\right) \quad (7)$$




Şekil 1. n harici giriş ve o harici çıkışlı m katmanlı bir ÇK-AÖM'nin eğitim aşaması kullanım mimarisi.



Şekil 2. n harici giriş ve o harici çıkışlı m katmanlı bir ÇK-AÖM'nin eğitim sonrası kullanım mimarisi.

ÇK-ÇAÖM'nin mimarisi ÇK-AÖM ile benzerdir. İkisi arasındaki temel fark, katmanlarda hücelere ilişkin giriş bağlantı ağırlık eşiklerinin ($W^{(i)}$, $b^{(i)}$) olmayışıdır. ÇK-ÇAÖM'nin bir gizli katmanına ilişkin mimari Şekil 3'te gösterilmiştir. Ağırlık eğitim aşamasında her bir katman için $\gamma^{(i)}$ dönüşüm matrisi Eş. (8)'de verildiği üzere katman girişi ve kare çekirdek matrisi kullanılarak hesaplanır. Dönüşüm matrisi bulunduğundan sonra ÇK-AÖM'deki gibi son katman hariç oto-kodlayıcı olarak adlandırılan ara katmanların çıkışı da Eş. (9) ile hesaplanır. m katmanlı bir ağda son katmana ilişkin dönüşüm matrisi ise Eş. (10) ile belirlenir. Ağ çıkışı ise ara katmanlardakine benzer bir şekilde Eş. (11) ile hesaplanır.



Şekil 3. ÇK-ÇAÖM'nin ara katman mimarisi.

$$\gamma^{(i)} = \left(\frac{1}{\lambda} + \Omega^{(i)} \right)^{-1} \mathbf{X}^{(i)} \quad (8)$$

$$\mathbf{X}^{(i+1)} = \mathbf{X}^{(i)} \gamma^{(i)}, \quad (9)$$

$$\gamma^{(m)} = \left(\frac{1}{\lambda} + \Omega^{(m)} \right)^{-1} \mathbf{T} \quad (10)$$

$$\hat{\mathbf{T}} = \Omega^{(m)} \gamma^{(m)} \quad (11)$$

Yukarıda kısaca tanımlanan ÇK-ÇAÖM'nin kaynak kodu[‡] [8]'de verilen bağdan indirilerek bu çalışmadaki amaca uyarlanmıştır.

3. Çok Katmanlı AÖM ile Rüzgar Hızı Tahmini Modellemesi

Bu bölümde yukarıda önceki bölümde tanımlanan çok katmanlı iki yeni AÖM ağ mimarisi ile kısa dönem rüzgar hızı tahmin modeli oluşturması ve bu modellerin başarımlarını analizinde odaklanılmıştır. Çalışmanın ana amacı, rüzgar hızı tahmini problemi üzerinde iki ağın başarımlarını analiz ederek ağların üstün ve zayıf taraflarının belirlenmesidir.

Çalışmada kullanılan rüzgar hızı verisi [9]'da da kullanılan veri olup Bilecik ili gözlem istasyonundan alınan saatlik bazda kaydedilmiş veridir. Bu veri Temmuz ayında alınmış toplamda 744 örnek içermektedir. Bu çalışmada da [9]'daki gibi ilk 518 örnek ağ eğitimi, kalan diğer örnekler de eğitilen ağın genelleme yeteneğini test etmek amaçlı seçilmiştir. Tüm veri [0,1] aralığına normalize edilerek kullanılmıştır. Model girişleri olarak mevcut rüzgar hızı ölçümü ve bu ölçümün 3 öncesi ölçümleri alınmış olup çıkış olarak da bir saat sonraki rüzgar hızı tahmini alınmıştır. Yani, k örnek indeksini, $y(k)$ da k örneklemedeki rüzgar hızı olmak üzere yapılacak modelleme Eş. (12) ile tanımlanabilir. Eşitlikteki f giriş-çıkış eşleştirme işlevi ÇK-AÖM ve ÇK-ÇAÖM ağları yerine getirecektir.

$$y(k+1) = f(y(k), y(k-1), y(k-2), y(k-3)) \quad (12)$$

3.1. Deneysel kurgu

Bu çalışmada, deneyler 2.5-GHz i5 CPU, 8 GB RAM temel özelliklere sahip bilgisayar üzerinde kurulu MATLAB 2014a ortamında yapılmıştır. Tüm deneylerde her iki ağın katman sayısı ilgili literatürde önerildiği üzere üç alınmıştır. Deneyler ağların kendine özgün yapısal ve

eğitimi ile ilgili farklı parametreler için yapılmıştır.

ÇK-AÖM için katmanlardaki hücre sayısı Li ($i = 1, 2, 3$) $\{5, 10, 15, 30, 50\}$ kümesi dahilinde değerlendirilmiş olup hücre aktivasyon fonksiyonu olarak log-sigmoidal fonksiyonu kullanılmıştır. ÇK-ÇAÖM için katman hücre sayısı (Li) gerekmemekte, çekirdek fonksiyonu olarak EŞ. (5)'de verilen radial tabanlı fonksiyon kullanılmıştır. Her iki ağ için, her bir katman için düzenleme parametresi λ_i ($i = 1, 2, 3$) $\{1, 5, 10, 50, 100\}$ kümesi dahilinde değerlendirmeye alınmıştır. ÇK-ÇAÖM için, çekirdek parametresi σ_i ($i = 1, 2, 3$) her bir katman için $\{0.1, 0.25, 0.5, 0.75, 1\}$ kümesi dahilindeki değerlere kurulmuştur. ÇK-AÖM'nin MATLAB kodu yazar tarafından yazılmış olup ÇK-ÇAÖM için kaynak kod [8]'de verilen bağdan elde edilerek bu çalışmada ele alınan probleme uyarlanmıştır.

3.2. Deneysel sonuçlar

Bu çalışmada önceki alt bölümde bahsedilen olası farklı parametreler için her bir ağ ikinci bölümde tanımlanan eğitim süreci eğitim örnekleri kullanılarak 30'ar kez tekrarlanmış, her bir eğitim sonunda elde edilen ağın genelleme yeteneği de test örnekleri kullanılarak test edilmiştir. Elde edilen ağların modelleme başarımlarının ölçümünde RMSE metriği kullanılmıştır.

Her bir ağ için hazırlanan programlar vasıtasıyla 30'ar kez tekrarlanan eğitim ve test sürecinin her birine ait hem işletim süresi hem de eğitim ve test veri setleri için ayrı ayrı olmak üzere modelleme başarımlarını metrikleri kaydedilmiştir. Tablo 1'de eğitim aşaması için farklı parametrelerle iki ağa ait eğitim süreleri verilmiştir. Ağların modelleme başarımlarına ilişkin RMSE cinsinden metrikler ise hem eğitim hem de test veri seti için Tablo 2'de verilmiştir. Şekil 4'de ise elde edilen modelleme başarımlarını grafiksel olarak göstermesi açısından ÇK-ÇAÖM ile elde edilen başarımların gerçek değerler ile kıyaslamalı olarak verilmiştir.

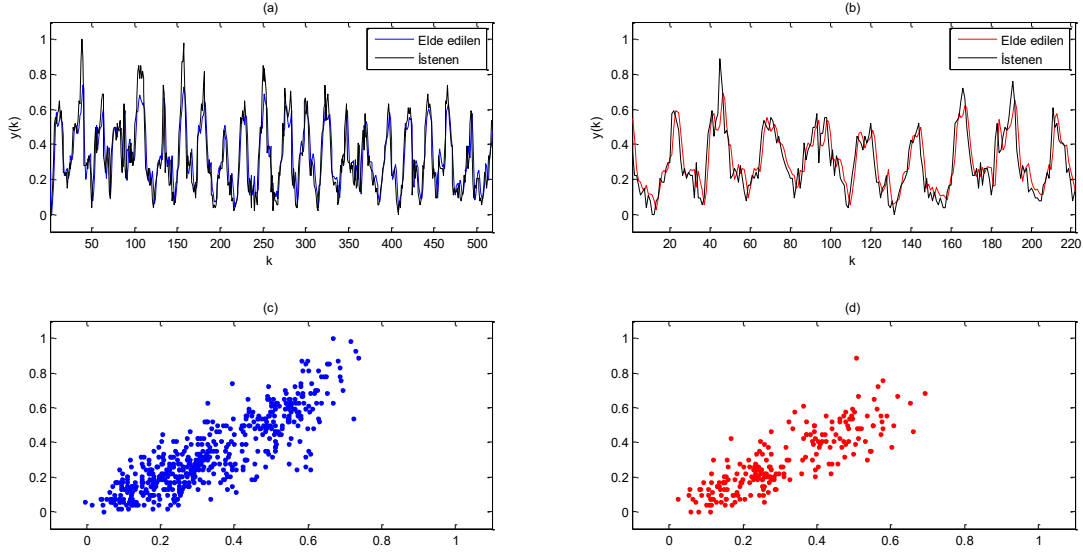
4. Sonuç ve Yorumlar

Bu çalışmada iki yeni çok katmanlı aşırı öğrenme makinesi ağı tanıtılmış olup bu ağların farklı yapısal ($\#Li$, σ_i) ve eğitim (λ_i) parametreleri ile başarımlarını kısa dönem rüzgar hızı tahmin modeli elde edilmesi problemi çerçevesinde incelenmiştir. Bu ağların bu alanda kullanımı ve bu farklı parametreler için başarımlarını incelemesi çalışmanın temel özgünlüğüdür. İnceleme sonucu elde edilen sonuçlar Tablo 1'de eğitim süresi açısından, Tablo 2'de de hem eğitim hem de test veri seti için modelleme başarımlarını metrikleri RMSE cinsinden topluca verilmiştir.

[‡] <http://www.fst.umac.mo/en/staff/fstcmv.html#software>

Tablo 1. Eğitim süresi kıyaslama tablosu

λ_i	ÇK-AÖM					ÇK-ÇAÖM				
	#Li	Ort. [s]	En iyi [s]	En kötü [s]	Std. sapma.	Ort. [s]	En iyi [s]	En kötü [s]	Std. sapma.	σ_i
1	5	0.1047	0.0618	0.3202	0.0615	0.0905	0.0648	0.1161	0.0139	0.1
	10	0.1475	0.0474	0.5805	0.1453	0.0680	0.0618	0.0778	0.0049	0.25
	15	0.1064	0.0574	0.3259	0.0499	0.0693	0.0604	0.0940	0.0088	0.5
	30	0.2318	0.0449	4.9678	0.8947	0.0738	0.0605	0.1462	0.0166	0.75
	50	0.0708	0.0582	0.1219	0.0154	0.0686	0.0595	0.0782	0.0055	1
5	5	0.0681	0.0425	0.1226	0.0171	0.1110	0.0738	0.1684	0.0304	0.1
	10	0.0478	0.0420	0.0677	0.0062	0.0928	0.0673	0.1442	0.0197	0.25
	15	0.0503	0.0432	0.0677	0.0054	0.0930	0.0708	0.1295	0.0167	0.5
	30	0.0510	0.0444	0.0634	0.0046	0.1221	0.0673	0.1598	0.0277	0.75
	50	0.0539	0.0468	0.0641	0.0055	0.0884	0.0650	0.1256	0.0158	1
10	5	0.0475	0.0418	0.0597	0.0043	0.1127	0.0757	0.1772	0.0349	0.1
	10	0.0472	0.0424	0.0571	0.0051	0.1199	0.0751	0.1549	0.0266	0.25
	15	0.0477	0.0426	0.0559	0.0042	0.1038	0.0669	0.1543	0.0274	0.5
	30	0.0499	0.0438	0.0580	0.0048	0.0806	0.0657	0.1174	0.0153	0.75
	50	0.0567	0.0472	0.0825	0.0072	0.0857	0.0653	0.1116	0.0137	1
50	5	0.0508	0.0411	0.0779	0.0099	0.1205	0.0683	0.1766	0.0244	0.1
	10	0.0477	0.0420	0.0573	0.0043	0.1361	0.0665	0.6715	0.1088	0.25
	15	0.0497	0.0426	0.0632	0.0049	0.0735	0.0636	0.0870	0.0076	0.5
	30	0.0605	0.0440	0.1482	0.0231	0.0738	0.0654	0.0947	0.0072	0.75
	50	0.0536	0.0466	0.0619	0.0047	0.0750	0.0663	0.0942	0.0060	1
100	5	0.0490	0.0412	0.0687	0.0075	0.0695	0.0627	0.0783	0.0047	0.1
	10	0.0491	0.0419	0.0704	0.0068	0.0688	0.0613	0.0845	0.0064	0.25
	15	0.0482	0.0425	0.0550	0.0039	0.0703	0.0615	0.0831	0.0064	0.5
	30	0.0524	0.0441	0.0614	0.0046	0.0691	0.0615	0.0850	0.0065	0.75
	50	0.0560	0.0467	0.1111	0.0116	0.0738	0.0612	0.1607	0.0178	1

**Şekil 4.** ÇK_AÖM ağına ait eğitim (sol) ve test (sağ) seti için başarımlar (a ve b örneksel, c ve d dağılım)

Tablo 2. RMSE cinsinden eğitim (1. satır) ve test (2. satır) veri seti için başarımların metrikleri

λ_i	#Li	ÇK-AÖM				ÇK-ÇAÖM				
		Ort.	En iyi	En kötü	Std. sapma	Ort.	En iyi	En kötü	Std. sapma	σ_i
1	5	0.1536 0.1305	0.1135 0.0978	0.1917 0.1609	0.0217 0.0181	0.0985 0.0951	0.0985 0.0951	0.0985 0.0951	0.0000 0.0000	0.1
	10	0.1215 0.1057	0.1047 0.0966	0.1478 0.1241	0.0126 0.0087	0.1265 0.1119	0.1265 0.1119	0.1265 0.1119	0.0000 0.0000	0.25
	15	0.1145 0.1008	0.1064 0.0965	0.1385 0.1170	0.0071 0.0045	0.1311 0.1155	0.1311 0.1155	0.1311 0.1155	0.0000 0.0000	0.5
	30	0.1080 0.0973	0.1058 0.0966	0.1151 0.1003	0.0019 0.0007	0.1320 0.1161	0.1320 0.1161	0.1320 0.1161	0.0000 0.0000	0.75
	50	0.1070 0.0968	0.1050 0.0966	0.1091 0.0973	0.0009 0.0002	0.1311 0.1153	0.1311 0.1153	0.1311 0.1153	0.0000 0.0000	1
5	5	0.1808 0.1526	0.1361 0.1170	0.2641 0.2131	0.0247 0.0208	0.0650 0.1130	0.0650 0.1130	0.0650 0.1130	0.0000 0.0000	0.1
	10	0.1235 0.1073	0.0942 0.0909	0.1787 0.1459	0.0211 0.0136	0.0815 0.0987	0.0815 0.0987	0.0815 0.0987	0.0000 0.0000	0.25
	15	0.1056 0.0965	0.0939 0.0916	0.1337 0.1147	0.0092 0.0049	0.0864 0.0939	0.0864 0.0939	0.0864 0.0939	0.0000 0.0000	0.5
	30	0.0948 0.0924	0.0928 0.0911	0.0986 0.0934	0.0014 0.0006	0.0899 0.0931	0.0899 0.0931	0.0899 0.0931	0.0000 0.0000	0.75
	50	0.0942 0.0921	0.0928 0.0915	0.0956 0.0927	0.0007 0.0003	0.0916 0.0931	0.0916 0.0931	0.0916 0.0931	0.0000 0.0000	1
10	5	0.1743 0.1484	0.1168 0.1111	0.2048 0.1755	0.0222 0.0182	0.0370 0.2254	0.0370 0.2254	0.0370 0.2254	0.0000 0.0000	0.1
	10	0.1302 0.1133	0.0935 0.0930	0.1779 0.1548	0.0199 0.0131	0.0465 0.1224	0.0465 0.1224	0.0465 0.1224	0.0000 0.0000	0.25
	15	0.1018 0.0955	0.0943 0.0899	0.1215 0.1055	0.0061 0.0036	0.0614 0.1053	0.0614 0.1053	0.0614 0.1053	0.0000 0.0000	0.5
	30	0.0924 0.0919	0.0906 0.0910	0.0950 0.0930	0.0011 0.0006	0.0682 0.1010	0.0682 0.1010	0.0682 0.1010	0.0000 0.0000	0.75
	50	0.0915 0.0918	0.0906 0.0913	0.0927 0.0924	0.0005 0.0003	0.0731 0.0976	0.0731 0.0976	0.0731 0.0976	0.0000 0.0000	1
50	5	0.1812 0.1583	0.1134 0.1077	0.2077 0.1849	0.0232 0.0191	0.0076 0.3365	0.0076 0.3365	0.0076 0.3365	0.0000 0.0000	0.1
	10	0.1510 0.1316	0.1167 0.1061	0.1894 0.1629	0.0192 0.0148	0.0075 0.3323	0.0075 0.3323	0.0075 0.3323	0.0000 0.0000	0.25
	15	0.1113 0.1036	0.0912 0.0914	0.1487 0.1293	0.0145 0.0083	0.0074 0.3309	0.0074 0.3309	0.0074 0.3309	0.0000 0.0000	0.5
	30	0.0913 0.0926	0.0894 0.0907	0.0969 0.0948	0.0015 0.0009	0.0074 0.3295	0.0074 0.3295	0.0074 0.3295	0.0000 0.0000	0.75
	50	0.0898 0.0919	0.0891 0.0909	0.0909 0.0927	0.0005 0.0005	0.0074 0.3278	0.0074 0.3278	0.0074 0.3278	0.0000 0.0000	1
100	5	0.1842 0.1612	0.1369 0.2074	0.2074 0.1928	0.0205 0.0166	0.0039 0.3412	0.0039 0.3412	0.0039 0.3412	0.0000 0.0000	0.1
	10	0.1486 0.1310	0.1117 0.1988	0.1988 0.1713	0.0229 0.0182	0.0039 0.3402	0.0039 0.3402	0.0039 0.3402	0.0000 0.0000	0.25
	15	0.1175 0.1080	0.0925 0.1447	0.1447 0.1341	0.0154 0.0096	0.0039 0.3405	0.0039 0.3405	0.0039 0.3405	0.0000 0.0000	0.5
	30	0.0913 0.0927	0.0889 0.0960	0.0960 0.0974	0.0019 0.0016	0.0039 0.3406	0.0039 0.3406	0.0039 0.3406	0.0000 0.0000	0.75
	50	0.0894 0.0919	0.0886 0.0902	0.0902 0.0929	0.0004 0.0005	0.0039 0.3404	0.0039 0.3404	0.0039 0.3404	0.0000 0.0000	1

Tablolarda elde edilen sonuçlar 30'ar koşturma sonucunda elde edilen ortalama, en iyi, en kötü ve standart sapma olmak üzere dört metrik ile verilmiştir. Tablolarda farklı arka plan renkleriyle gösterilmiş parametre kategorisi için elde edilmiş en iyi metrikler koyu punto ile işaretlenmiştir. Tablo 2'de altı çizgili olarak işaretlenen en iyi metrikler test seti içindir. İşaretlenen en iyi başarımler metrikleri ve diğer gözlenen diğer hususlar çerçevesinde aşağıda listelenen sonuçlara ulaşılmıştır.

1. Eğitim süresi bakımından Tablo 1'de işaretlenen koyu puntolu saniye cinsinden metriklerden görüleceği üzere; $\lambda_i=1$ durumu hariç diğer tüm parametre kategorilerinde açık bir şekilde ÇK-AÖM daha üstün bir başarımler sahiptir.
2. Kararlılık bakımından, Tablo 2'de verilen standart sapma metriklerinden açıkça görüleceği üzere, çekirdek fonksiyonu kullanan ÇK-ÇAÖM son derece başarılıdır. Her çalışma sonunda hem eğitim hem de test veri seti için aynı başarımler göstermiştir. Ancak ÇK-AÖM'nin hücre sayısı arttıkça kararlılık bakımından ÇK-ÇAÖM ağına yaklaştığı gözlenmiştir.
3. Genelleme kabiliyeti açısından ÇK-AÖM'nin daha başarılı olduğu gözlenmiştir.
 - a. Büyük λ_i 'nin 5'den büyük değerleri için ÇK-ÇAÖM'nin eğitim seti için çok iyi başarımler göstermiş olması rağmen test seti için görece çok kötü başarımler göstermesi bu ağı ezberleme moduna geçtiğinin göstergesidir. Bunun sebebinin test verisiyle çekirdek hesabı yapılırken eğitim aşamasında eğitim veri setine bağlı olarak hesaplanan bir dönüşüm matrisinin kullanılması olduğu değerlendirilmiştir.
 - b. Tüm parametre kategorilerinde ÇK-AÖM mimarisinde hücre sayısı arttıkça hem eğitim hem de test seti için giderek iyileşen başarımler elde edilmiştir.

Teşekkür

Yazar bu çalışmada kullanılan veri setinin temini ve kullanım konusunda izin ve destekleri için Prof. Dr. Mehmet Kurban ve Dr. Emrah Dokur'a teşekkür eder.

Kaynaklar

[1] Huang G.-B., Zhu Q.-Y., Siew C.-K., 2004. Extreme Learning Machine: A New Learning Scheme of

Feedforward Neural Networks. IEEE International Conference on Neural Networks, Budapest, Hungary, 25-29 July, vol 2, pp.985-990.

- [2] Karakuzu C., Yüzgeç U., 2018. A Simple Heuristic Approach to Improve Performance of Extreme Learning Machine. International Conference on Advanced Technologies, Computer Engineering and Science (ICATCES'18), 11-13 May, Safranbolu, Turkey, pp. 212-17.
- [3] Jagtap P., Raut P., Pillai G. N., Kazi F., Singh N. M., 2015. Extreme-ANFIS: A Novel Learning Approach for Inverse Model Control of Nonlinear Dynamical Systems. 2015 International Conference on Industrial Instrumentation and Control (ICIC), College of Engineering Pune, India, 28-30 May, pp. 718-23.
- [4] Karakuzu C., Öztürk Ö., 2018. Fuzzy System Modeling with Extreme Learning Machines. International Conference on Data Science and Applications (ICONSADA 2018), Yalova, Turkey, 4-7 October, vol. 2, pp. 194-208.
- [5] Liao S., Feng C., 2014. Meta-ELM: ELM with ELM Hidden Nodes. Neurocomputing 128, 81-87.
- [6] Karakuzu C., 2019. Performance Comparison of a Neural Network and a Fuzzy Network Trained by ELM for Dynamic System Identification Problems. 2nd International Congress on Engineering and Architecture (ENAR), 22-24 April, Marmaris, Turkey, pp. 1465-1475.
- [7] Tang J., Deng C., Huang G.-B., 2016. Extreme Learning Machine for Multilayer Perceptron. IEEE Trans. on Neural Networks and Learning Systems, 27(4), 809-821.
- [8] Wong C. M., Vong C. M., Wong P. K., Cao J., 2018. Kernel-Based Multilayer Extreme Learning Machines for Representation Learning. IEEE Trans. on Neural Networks and Learning Systems, 29(3), 757-762.
- [9] Dokur E., Karakuzu C., Yüzgeç U., Kurban M., 2019. ELM Based Wind Speed Forecasting. International Symposium on Engineering Natural Sciences and Architecture (ISENSA), Kocaeli, Turkey, 2-4 May, pp. 104-108.