

IV. BASKENT INTERNATIONAL CONFERENCE ON MULTIDISCIPLINARY STUDIES

GELİŞTİRİLMİŞ ÇOK KATMANLI AŞIRI ÖĞRENME MAKİNELERİ: REGRESYON
PROBLEMLERİNDE BAŞARIM KARŞILAŞTIRMASI

IMPROVED MULTILAYER EXTREME LEARNING MACHINES: COMPARISON OF
SUCCESS IN REGRESSION PROBLEMS

Muhammed YILDIRIM

*Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Bilecik,
Türkiye*

ORCID ID: 0000-0001-5968-3406

Cihan KARAKUZU

*Prof. Dr., Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü,
Bilecik, Türkiye*

ORCID ID: 0000-0003-0569-098X

ÖZET

Bu çalışmada, yakın zamanda geliştirilmiş çok katmanlı aşırı öğrenme makinelerinin regresyon problemlerindeki başarımı incelenmiştir. Bu inceleme için UCI Machine Learning Repository içerisinde 10 adet veri kümesi seçilerek Matlab ortamında ağların başarımı deneysel olarak irdelenmiştir. Her bir ağ her bir veri kümesi için 100'er kez eğitilmiş olup elde edilen sonuçlar istatistiksel metriklerle değerlendirilmiştir. Değerlendirme sonucunda yeni çok katmanlı aşırı öğrenme makinelerinin regresyon problemlerinde daha başarılı sonuçlar verdiği gözlemlenmiştir.

Anahtar kelimeler: Aşırı öğrenme makinesi, yapay öğrenme, sinir ağları, regresyon

ABSTRACT

In this study, the performance of recently developed multilayer extreme learning machines in regression problems is investigated. For this study, 10 datasets were selected from the UCI Machine Learning Repository and the performance of the networks was examined experimentally in the Matlab environment. Each network was trained 100 times for each dataset and the results were evaluated with statistical metrics. As a result of the evaluation, it was observed that the new multilayer extreme learning machines gave more successful results in regression problems.

Keywords: Extreme learning machine, artificial learning, neural networks, regression

GİRİŞ

Aşırı öğrenme makinesi (AÖM) [1], yinelemesiz bir yapay öğrenme algoritmasıdır. AÖM, öğrenme aşamasında gizli katmandaki ağırlıkları rastgele atar ve bu ağırlıkları sabit olarak tutar. Ardından, ağırlıkların sabit olması nedeniyle geriye doğru yayılım (backpropagation) adımı yapılmaz.

AÖM'nin temel ilkesi, giriş verilerini gizli katmanın sinir hücrelerine doğrudan bağlamak ve çıktı katmanındaki ağırlıkları analitik olarak belirlemektir. Bu nedenle, AÖM'de giriş verilerinden gizli katmandaki sinir hücrelerine bağlantılar rastgele atanır ve ardından en uygun çıkış bağlantı ağırlıkları hesaplanır. Bu işlem, hızlı ve tekrarsız bir öğrenme süreci sağlar.

Çok katmanlı aşırı öğrenme makinesi (ÇK-AÖM) AÖM öğrenme yöntemini çok katmanlı sinir ağı yapısına genişleten bir öğrenme modelidir.

IV. BASKENT INTERNATIONAL CONFERENCE ON MULTIDISCIPLINARY STUDIES

AÖM'nin temelindeki fikir, giriş verilerini gizli katmandaki sinir hücrelerine rastgele bağlamak ve ardından ağırlıkları analitik olarak hesaplamaktır. ÇK-AÖM, bu fikri genişleterek daha karmaşık öğrenme problemleri için derin sinir ağı yapısını kullanır.

ÇK-AÖM'de, giriş verileri bir giriş katmanına beslenir ve ardından bir veya daha fazla gizli katman eklenir. Her gizli katmanda, giriş verileri ile sinir hücreleri arasında rastgele bağlantılar oluşturulur. Bu bağlantılar, giriş verilerinin katmanlara yayılmasını sağlar. Son katmanda, çıktılar hesaplanır ve ağırlıklar analitik olarak belirlenir.

Referans [2]'de iki yeni çok katmanlı aşırı öğrenme makinesi geliştirmiştir. Bildiri içerisinde bunlara GÇK-AÖM kısaltması ile atıfta bulunulacaktır. GÇK-AÖM1 ağında, her katman ortonormal olarak rastgele atanmış bağlantı ağırlıklarına sahiptir. GÇK-AÖM2 ise sadece birinci katmanda ortonormal olarak rasgele atanmış bağlantı ağırlıklarına sahiptir. Sonraki katmanların bağlantı ağırlıkları, bir önceki katmanın çıktı ağırlık matrisinden alınır.

VERİ KÜMELERİ

UCI Machine Learning Repository[3], Kaliforniya Üniversitesi, Irvine tarafından yönetilen bir veri havuzu ve araştırma kaynağıdır. Çeşitli disiplinlerden gelen gerçek dünya problemlerine odaklanan çeşitli veri kümelerini barındırır. Bu veri kümeleri, yapılandırılmış verilerden oluşur ve özellikleri, hedef değişkenleri ve bazen açıklamaları içerir. Sınıflandırma, regresyon, kümeleme gibi farklı makine öğrenimi problemleri için kullanılabilen geniş bir veri yelpazesine sahiptir.

Bu çalışmada kullanılmak üzere 10 adet regresyon ilişkili görevler için paylaşılmış veri kümesi belirlenmiştir. Belirlenen veri kümeleri Tablo 1'de verilmiştir.

Tablo 1. Veri kümeleri

Veri Kümesi Adı	Örnek Sayısı	Özellik Sayısı	Normalizasyon
Abalone	4177	9	Z-Score
Auto-Mpg	392	9	Z-Score
Auto Imports Price	205	26	Z-Score
Boston Housing	506	14	Z-Score
Relative CPU Performance	209	9	Z-Score
Delta Ailerons	7129	6	Z-Score
Delta Elevators	9517	7	Z-Score
Servo	167	5	Z-Score
İstanbul Srock Exchange	536	8	Z-Score
QSAR fish toxicity	908	7	Uygulanmadı

Abalone

Abalone canlılarının yaşını fiziksel ölçümlerden tahmin etme amaçlı bir veri kümesidir[4].

Auto-Mpg

Araçların galon başına mil cinsinden şehir içi yakıt tüketimiyle ilgilidir[5].

Auto Imports Price

Bir otomobilin çeşitli karakteristikler açısından özellikleri, atanan sigorta risk derecesi, diğer otomobillere kıyasla kullanımdaki normalleştirilmiş kayıpları olmak üzere üç tip parametrelerden oluşan bir veri kümesidir[6].

Boston Housing

Boston mahallelerindeki konut değerleri ile ilgilidir[7].

Relative CPU Performance

IV. BASKENT INTERNATIONAL CONFERENCE ON MULTIDISCIPLINARY STUDIES

İşlemcilerin bağıl performans değerleri ile ilgilidir[8].

Delta Ailerons

F16 savaş uçağının kanatçıklarını kontrol etme görevinden elde edilmiş verilerdir[9].

Delta Elevators

F16 savaş uçağının asansörlerini kontrol etme görevinden elde edilmiş verilerdir[10].

Servo

Bir servomekanizmanın bir adım değişikliğine yanıt vermesi için gereken süreyi tahmin etme ile ilgilidir[11].

İstanbul Stock Exchange

5 Haziran 2009'dan 22 Şubat 2011'e kadar İstanbul Menkul Kıymetler Borsası'nın diğer yedi uluslararası endeks ile getirilerini içermektedir; SP, DAX, FTSE, NIKKEI, BOVESPA, MSCE_EU, MSCI_EM[12].

QSAR fish toxicity

908 kimyasaldan oluşan bir sette Pimephales promelas balığına yönelik akut su toksisitesini tahmin etmek için kantitatif regresyon QSAR modellerini geliştirmek için kullanılmış bir veri kümesidir. [13]

YÖNTEM

Çalışma Matlab ortamında Intel(R) Core(TM) i7-4710HQ CPU @ 2.50GHz işlemci ve 16 GB RAM içeren donanım kullanılarak yapılmıştır.


Öncelikle veri kümelerini Matlab ortamında okuyacak kodlar yazılarak çalışma ortamına yüklenmiştir. Verilerin %70'i öğrenmeye ayrılarak %30'u test için kullanılmıştır. Kategorik değişkenler sayısal olarak çevrilerek ağların öğrenmesine sunulmuştur. Normalizasyona ihtiyaç duyulan durumlarda Z-Score normalizasyon yöntemi kullanılmıştır.

Orijinal ÇK-AÖM, GÇK-AÖM1 ve GÇK-AÖM2 olmak üzere 3 adet çok katmanlı aşırı öğrenme makinesi her veri kümesi için 100'er kez çalıştırılmıştır. Çalışma sonuçlarında her bir aşırı öğrenme makinesi ve veri kümesi için çıkan metrikler, başarımlar, grafikleri, çalışma alanı değişkenleri kaydedilmiştir. Başarımların metriği olarak Root Mean Square Error (RMSE) kullanılmıştır.

SONUÇLAR


Tüm sonuçlar incelendiğinde yeni geliştirilmiş ÇK- AÖM'lerin regresyon problemlerinin çözümünde başarılı olduğu ve orijinal olana göre daha başarılı sonuçlar verdiği görülmüştür. Şekil 1-3'de Auto-Mpg veri kümesi için ÇK-AÖM'lerin test fazındaki başarımlarını gösteren grafikler paylaşılmıştır.

IV. BASKENT
INTERNATIONAL CONFERENCE ON
MULTIDISCIPLINARY STUDIES




Şekil 1. Orijinal ÇK-AÖM'nin en iyi test başarımı

IV. BASKENT
INTERNATIONAL CONFERENCE ON
MULTIDISCIPLINARY STUDIES



Şekil 2. GÇK-AÖM1 modelinin en iyi test başarımı

**IV. BASKENT
INTERNATIONAL CONFERENCE ON
MULTIDISCIPLINARY STUDIES**



Şekil 3. GÇK-AÖM2 modelinin en iyi test başarımı

Tablo 2, Tablo 3, Tablo 4 ve Tablo 5 içerisinde eğitim ve test fazları için başarımların değişim metrikleri verilmiştir. Tablolardaki negatif yüzdeler ilgili değerin azaldığını, pozitif yüzdeler ise sayılar arttığını göstermektedir. Tablolar incelendiğinde test fazlarında RMSE değerlerinin düştüğü görülmektedir. Ayrıca tüm fazlarda standart sapmaların düşmesi de daha etkin bir öğrenme işlemi olduğunu göstermektedir.

IV. BASKENT INTERNATIONAL CONFERENCE ON MULTIDISCIPLINARY STUDIES

Tablo 2. GÇK-AÖM1'in orijinale göre eğitim fazındaki metriklerinin yüzdelik değişimi

Veri Kümesi	Train RMSE			
	Ortalama	En iyi	En Kötü	Standart Sapma
Abalone	-%1,63	-%1,95	-%2,04	-%31,83
Auto-Mpg	%34,64	%28,5	%22,16	-%89,09
Auto Imports Price	%51,88	%24,66	-%12,69	-%193,27
Boston Housing	%4,52	%0,91	-%5,91	-%62,9
Relative CPU Performance	%37,04	%22,24	%8,53	-%47,43
Delta Ailerons	-%10,71	-%13,97	-%17,59	-%240,35
Delta Elevators	-%2,81	-%3,57	-%5,37	-%228,72
Servo	%65,93	%53,68	%42,79	-%437,7
İstanbul Srock Exchange	-%2,82	-%6,67	-%11,16	-%395,1
QSAR fish toxicity	%3,16	-%10,18	-%17,2	-%300,19

Tablo 3. GÇK-AÖM1'in orijinale göre test fazındaki metriklerinin yüzdelik değişimi

Veri Kümesi	Test RMSE			
	Ortalama	En iyi	En Kötü	Standart Sapma
Abalone	-%3	-%4,14	-%5,31	-%93,17
Auto-Mpg	-%45,08	-%62,76	-%95,28	-%400,4
Auto Imports Price	-%410,6	-%170,69	-%439,07	-%1051,01
Boston Housing	-%8,79	-%26,27	-%34,47	-%180,79
Relative CPU Performance	-%31,98	-%85	-%133,44	-%735,72
Delta Ailerons	-%8,32	-%10,35	-%14,38	-%145,34
Delta Elevators	-%3,82	-%5,23	-%6,74	-%246,21
Servo	-%11,31	-%25,04	-%75,52	-%1972,69
İstanbul Srock Exchange	-%22,97	-%41,15	-%69,35	-%1849,34
QSAR fish toxicity	%4,44	-%7,53	-%31,62	-%513,42

IV. BASKENT INTERNATIONAL CONFERENCE ON MULTIDISCIPLINARY STUDIES

Tablo 4. GÇK-AÖM2'nin orijinale göre eğitim fazındaki metriklerinin yüzdelik değişimi

Veri Kümesi	Train RMSE			
	Ortalama	En iyi	En Kötü	Standart Sapma
Abalone	-%3,27	-%2,92	-%2,66	%20,21
Auto-Mpg	%6,86	%2,88	%0,05	-%29,75
Auto Imports Price	%50,38	%30,22	-%3,27	-%122,09
Boston Housing	-%5,17	-%3,04	-%70,42	%11,73
Relative CPU Performance	%16,92	-%6,7	-%22,44	-%126,16
Delta Ailerons	-%13,19	-%16,18	-%20,26	-%279,73
Delta Elevators	-%4,32	-%4,94	-%6,72	-%156,37
Servo	%54,29	%42,18	%32,82	-%50,58
İstanbul Srock Exchange	-%7,63	-%9,8	-%11,7	-%61,63
QSAR fish toxicity	%4,64	-%8,4	-%15,03	-%275,68


Tablo 5. GÇK-AÖM2'nin orijinale göre test fazındaki metriklerinin yüzdelik değişimi

Veri Kümesi	Test RMSE			
	Ortalama	En iyi	En Kötü	Standart Sapma
Abalone	-%4,45	-%4,75	-%5,02	-%33,48
Auto-Mpg	-%16,03	-%30,17	-%54,73	-%275,3
Auto Imports Price	-%269,72	-%64,36	-%186,61	-%322,67
Boston Housing	-%35,48	-%41,3	-%189,98	-%48,72
Relative CPU Performance	-%66,19	-%107,21	-%133,37	-%337,06
Delta Ailerons	-%12,03	-%13,88	-%19,08	-%206,96
Delta Elevators	-%2,17	-%3,21	-%4,74	-%170,56
Servo	-%0,33	-%28,85	-%68,42	-%410,23
İstanbul Srock Exchange	-%18,81	-%28,86	-%46,61	-%249,41
QSAR fish toxicity	-%15,01	-%26,75	-%48	-%284,09

IV. BASKENT INTERNATIONAL CONFERENCE ON MULTIDISCIPLINARY STUDIES

Şekil 4’de verilen grafikte yeni geliştirilen ÇK-AÖM’lerin test fazında orijinale göre RMSE metriği cinsinden başarımları bar grafikte gösterilmiştir. Grafikteki değerler 100 koşmanın ortalaması alınarak elde edilmiştir.

GÇK-AÖM1’in ele alınan problemlerde yüzdelik olarak [3, 410,6] aralığında değişen daha üstün başarımları gözlenmiştir. GÇK-AÖM2 için ise bu aralık [0,33, 269,72]’dir. Şekil 4’den de görüleceği üzere, GÇK-AÖM1 10 problemin 4’ünde en iyi başarımları gösterirken, GÇK-AÖM2 10 problemin 6’sında en iyi başarımları göstermiştir. Sonuç olarak GÇK-AÖM1 ve GÇK-AÖM2’nin regresyon problemleri üzerinde %100’ün dahi üzerine çıkan oranlarda başarılı olduğu gözlemlenmiştir.



Şekil 4. GÇK-AÖM’lerin öğrenme başarımları

KAYNAKLAR

- [1] G.-B. Huang, Q.-Y. Zhu, C.K. Siew, Extreme learning machine: A new learning scheme of feedforward neural networks, in: 2004 IEEE International Joint Conference on Neural Networks, 2004, <http://dx.doi.org/10.1109/IJCNN.2004.1380068>.
- [2] Kale, Gizem Atac, and Cihan Karakuzu. "Multilayer extreme learning machines and their modeling performance on dynamical systems." Applied Soft Computing 122, 2022, <https://doi.org/10.1016/j.asoc.2022.108861>.
- [3] Dua, D. and Graff, C. (2019). UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>]. Irvine, CA: University of California, School of Information and Computer Science
- [4] Nash, Warwick, Sellers, Tracy, Talbot, Simon, Cawthorn, Andrew, and Ford, Wes. (1995). Abalone. UCI Machine Learning Repository. <https://doi.org/10.24432/C55C7W>.
- [5] Quinlan, R. (1993). Auto MPG. UCI Machine Learning Repository. <https://doi.org/10.24432/C5859H>.
- [6] Schlimmer, Jeffrey. (1987). Automobile. UCI Machine Learning Repository. <https://doi.org/10.24432/C5B01C>.
- [7] The Boston house-price data of Harrison, D. and Rubinfeld, D.L. 'Hedonic prices and the demand for clean air', J. Environ. Economics & Management, vol.5, 81-102, 1978.
- [8] Feldmesser, Jacob. (1987). Computer Hardware. UCI Machine Learning Repository. <https://doi.org/10.24432/C5830D>.

IV. BASKENT INTERNATIONAL CONFERENCE ON MULTIDISCIPLINARY STUDIES

[9] Camacho, R. Delta Ailerons, https://www.dcc.fc.up.pt/~ltorgo/Regression/delta_ailerons.html
(18.06.2023)

[10] Camacho, R. Delta Elevators, https://www.dcc.fc.up.pt/~ltorgo/Regression/delta_elevators.html
(18.06.2023)

[11] Ulrich, Karl. (1993). Servo. UCI Machine Learning Repository. <https://doi.org/10.24432/C5Q30F>.

[12] Akbilgic, Oguz. (2013). ISTANBUL STOCK EXCHANGE. UCI Machine Learning Repository.
<https://doi.org/10.24432/C54P4J>.

[13] Ballabio, Davide, Cassotti, Matteo, Consonni, Viviana, and Todeschini, Roberto. (2019). QSAR fish toxicity. UCI Machine Learning Repository. <https://doi.org/10.24432/C5JG7B>.