

Gayrimenkul Değerlemesinde Yapay Sinir Ağlarının Kullanılması

Cengiz SERTKAYA^{1*}, Zekeriya KÖSE²

¹Bilgisayar Mühendisliği Bölümü / Mühendislik Fakültesi, İstanbul Topkapı Üniversitesi, Türkiye

²BT Uygulama Çözümleri Bölümü, Eminevim, Türkiye

*(cengizsertkaya@topkapi.edu.tr)

(Geliş Tarihi: 27 Nisan 2023, Kabul Tarihi: 20 Mayıs 2023)

(DOI: 10.59287/ijanser.721)

(1st International Conference on Contemporary Academic Research ICCAR 2023, May 17-19, 2023)

ATIF/REFERENCE: Sertkaya, C. & Köse, Z. (2023). Gayrimenkul Değerlemesinde Yapay Sinir Ağlarının Kullanılması. *International Journal of Advanced Natural Sciences and Engineering Researches*, 7(4), 308-312.

Özet – Taşınmaz malları değerlendirme vergilendirme, kredi gibi birçok finansal alanı ilgilendiren, önemi gün geçtikçe artan bir çalışma alanı olarak ortaya çıkmıştır. Taşınmaz değerlendirme gibi, sosyal ve ekonomik koşullara göre zaman içerisinde değişkenlik gösteren zor bir problemde, değerlemenin doğru ve objektif olarak yapılabilmesi için gelişmiş sistemlerin kullanımı zorunlu hale gelmiştir. Değerlemeye etki eden birçok parametrenin varlığı ve işlenmesi gereken büyük boyutta veri de göz önüne alındığında, klasik yöntemlerin aksine insan zekasına yakın yorumlar yapabilen makine öğrenmesi methodlarının kullanımına ihtiyaç duyulmaktadır.

Bu çalışmanın amacı, tasarruf finansmanı sektöründe faaliyet gösteren firmalar için gayrimenkul ekspertiz ve değerlendirme süreçlerinde kullanılmak üzere, makine öğrenmesi yöntemlerinden yapay sinir ağı tabanlı bir sistem önerisi sunulmasıdır. Önerilen sistemin değerlendirme sürecinde, Türkiye’de yaygın kullanılan ilan sitelerindeki gayrimenkul bilgilerinden yola çıkılarak, en doğru değerlemenin yapılabilmesi için uzmana bir karar desteği sağlaması hedeflenmektedir. Elde edilen sonuçlara göre önerilen sistemin, 0.86 ve 0.85 R^2 başarı değerlerine ulaştığını ve başarılı bir gayrimenkul değerlendirme sistemi olduğu belirlenmiştir.

Anahtar Kelimeler – Tasarruf Finansmanı, Eminevim, Gayrimenkul Değerleme, Makine Öğrenmesi, Yapay Sinir Ağları

I. GİRİŞ

Pek çok insan için gayrimenkul sahibi olmak aynı zamanda bir maddi refah göstergesi olarak da kabul edilmektedir[1]. Bu özelliği ile sadece bireysel alıcıların değil bankaların, sigorta şirketlerinin, vergi dairelerinin ve müşterilerine taşınmaz edinimini amaçlayan tasarruf finansmanı şirketlerinin ilgi alanına girmektedir[2]. Gayrimenkul değerlemenin doğru tahmini bu sektörler için oldukça önemlidir[3].

Gelişen ve değişen dünyada ekonomik ve sosyal gelişmelere paralel olarak gayrimenkullere ait fiyat skalası da değişim göstermektedir. Değerlemede etki eden farklı veri formatlarının varlığı ve muazzam miktardaki veri de düşünüldüğünde, gayrimenkul değeri belirlenirken ihtiyaç duyulan verilerin işlenmesi ve analiz edilmesi klasik yöntemler ile yapılamayacak kadar zor hale gelmektedir.

Makine öğrenmesi gayrimenkul değerlendirme gibi karmaşık süreçlerin analizinde ve gizli ilişkilerin ortaya çıkarılmasında kullanılan etkili yöntemler içermektedir[4]. Oluşturulan modeller giriş ve çıkış arasındaki ilişkiyi kurmak suretiyle tahminler gerçekleştirmektedir[5]. Öğrenme sonrasında daha önce görmediği veriler üzerinde yorum yapabilmekte, dolayısıyla değişimlere ayak uydurabilmektedir[6]. Gayrimenkul gibi dinamik bir sektör için makine öğrenmesi methodları, bu yetenekleri sayesinde etkili sonuçlar verebilmektedir[7], [8].

Yapılan bir çalışmada, emlak fiyatlarının değerlendirilmesinde, destek vektör makinesi(SVM), rastgele orman(RF) ve gradyan arttırma makinesi(GBM) modelleri uygulanarak, Hong Kong şehrindeki 40.000 konut üzerinde inceleme yapılmıştır. Modeller karşılaştırıldığında RF ve GBM modellerinin daha başarılı olduğu belirlenmiştir[9].

Diğer bir çalışmada, 2014-2015 yıllarına ait Washington eyaletindeki konut fiyatlarının tahmini için, kısmi en küçük kareler(PLS), yığın regrasyon, K-en yakın komşu, SVM ve GBM modelleri kullanılmıştır. Yığın regrasyon modeli 0.88 R^2 değeri ile en başarılı model olmuştur[10].

Diğer bir çalışmada, gayrimenkul fiyat tahmini için, lineer, çok değişkenli ve polinom regrasyon modelleri kullanılmıştır[11].

Diğer bir çalışmada, Endonezya'daki konutlar için, fiyat tahmininde kullanılmak üzere regrasyon ve parçacık sürü optimizasyonu(PSO) modelleri oluşturulmuştur. PSO'nun en başarılı model olduğu belirtilmiştir[12].

Yapılan diğer bir çalışmada, konutların görsel nitelikleri kullanılarak fiyat tahmini yapılmak istenmiştir. Bu amaçla oluşturulan çok katmanlı yapay sinir ağı(MLNN) methodu, 0.94 R değeri ile başarılı olmuştur[13].

Amerika'nın konut fiyatlandırma trendleri ile elde edilen veriler üzerinden, Virginia eyaletindeki konut fiyatlarının tahmini üzerine yapılan çalışmada, 5359 adet konuta ait veri elde edilmiştir. Kullanılan C4.5, Ripper, Naive Bayes ve Adaboost algoritmaları ortalama hata yöntemi ile incelenmiştir. Ripper modeli 0.25 ortalama hata değeri ile en başarılı model olmuştur[14].

Bu çalışmada, gayrimenkul fiyatlarının tahminini yapabilmek amacıyla makine öğrenmesi yöntemlerinden yapay sinir ağı ile bir sistem önerilmiştir. Sistemde kullanılan veriler, Türkiye'de konut ilanlarının yayınlandığı sitelerinden elde edilmiştir. Geliştirilen sistemin özellikle, tasarruf finansmanı sektöründeki firmaların ekspertiz ve gayrimenkul değerlendirme süreçlerine destek sağlaması amaçlanmıştır.

II. MATERYAL VE YÖNTEM

Modellerin oluşturulmasında öncelikle verilerin toplama ve elde edilen veriseti üzerinde analiz çalışmaları yapılmış olup sonrasında, uygun modellerin seçilmesiyle çalışmaya devam edilmiştir.

A. Verisetlerinin Oluşturulması

Gayrimenkul değerlendirme için İstanbul ili sınırlarındaki daire ve arsa bilgileri, Türkiye'nin önde gelen ilan sitelerinden toplanmıştır. Bu amaçla, ilgili sitelerinin ön yüzünden halka açık olan veriler toplanarak anonimleştirilmiştir. Verilerin toplanması için bir veri toplama uygulaması C# dilinde geliştirilmiştir. Uygulama ile satılık kategorisindeki arsa ilanlarından 7000 adet ve daire ilanlarından 140.000 adet ilan toplanarak iki ayrı veriseti elde edilmiştir. Verisetleri içerisinde bulunan özellikler Tablo 1'de gösterilmektedir.

Tablo 1. Verisetlerinin özellikleri

Veriseti	No	Özellik
Arsa	1	İlçe
	2	Mahalle
	3	İmar durumu
	4	Metrekare
	5	Ada no
	6	Parsel no
	7	Pafta no
	8	Gabari
	9	Tapu durumu
	10	Fiyatı
Daire	1	İlçe
	2	Mahalle
	3	Metrekare brüt
	4	Metrekare net
	5	Oda sayısı
	6	Bina yaşı
	7	Bulunduğu kat
	8	Kat sayısı
	9	Isıtma türü
	10	Banyo sayısı
	11	Tapu durumu
	12	Fiyatı

Burada, verisetleri içerisindeki fiyat özelliğinin makine öğrenmesi modellerinin üreteceği çıkış olarak kullanılması, geriye kalan diğer özelliklerin de modellere giriş olarak kullanılması hedeflenmiştir.

Veriseti özelliklerinin bazıları sayısal olmadığından yapay zeka modellerinde kullanılabilmesi için sayısallaştırılması gerekmektedir[15]. Sayısallaştırılan özellikler, arsa için; ilçe, mahalle, imar durumu, tapu durumu özellikleri, daire için ise; ilçe, mahalle, oda sayısı, ısıtma türü, tapu durumu özellikleridir. Sayısallaştırma işlemi her bir metinsel değer için 1'den başlayarak numaralandırılması şeklinde yapılmıştır.

Sonraki aşamada, özelliklerin değişim aralıkları incelenmiştir. Burada her iki veriseti için de, ilçe ve mahalle bilgilerinin, diğer özelliklere göre veri değişim aralığı oldukça farklı olduğu görülmüştür. Bu nedenle verisetlerinin özellikleri kurulacak yapay zeka modellerinin olumsuz etkilenmemesi için normalizasyon işlemine tabi tutulmuştur[16]. Bu amaçla Denklem 1'de gösterilen formül uygulanarak özellikler 0-1 arasında normalize edilmiştir.


$$X_{nor} = \left(\frac{X_i - X_{min}}{X_{max} - X_{min}} \right) \quad (1)$$

Burada X_{nor} ifadesi, özelliğin X_i değerinin normalize edilmiş halini, X_{min} özelliğin minimum, X_{max} ise maximum değerini ifade etmektedir.

Normalize işlemi sonrasında verisetleri iki ayrı model için ayrı ayrı 10 adet folda, rastgele şekilde bölünmüştür. Burada veriseti %80 eğitim ve %20'si testte kullanılmak üzere 8 fold eğitim ve 2 fold test için ayrılmıştır.

B. Yapay Sinir Ağı Modeli


Yapay sinir ağları temelde insan beyninin çalışma prensiplerini ve öğrenme yeteneklerini örneklemektedir[17]. Temel bir yapay sinir ağının şeması Şekil 1'de gösterilmektedir.



Şekil 1. Yapay sinir ağı şeması[18]

Burada, bilgiler giriş katmanından alınarak, ağ içerisinde ara katmanlar ve en sonunda çıkış katmanına doğru ilerlemektedir. Bu iletim esnasında her bir düğümdeki bilginin ağırlık değerleri tutulmaktadır. Ağırlıkların değiştirilerek doğru değerlere yaklaşması ile eğitim süreci gerçekleşir ve istenen başarı kriterleri sağlandığında ağın öğrendiği kabul edilmektedir. Burada, ağırlık değerleri problemin çözümünü sağlayacak matematiksel formülasyonda ilgili özelliğin katsayısını ifade etmektedir[19].

MATLAB nntool üzerinde, farklı yapay sinir ağları modelleri oluşturulmuştur. Yapılan incelemeler neticesinde, 2 adet gizli katman ve gizli katmanlarda sırasıyla 10'ar adet düğümün bulunduğu modeller seçilmiştir. Modellerin içerisinde öğrenme fonksiyonu olarak, TRAINLM fonksiyonu tercih edilmiştir. Oluşturulan modelin yapısı Şekil 2'te gösterilmektedir.



Şekil 2. Yapay sinir ağı model yapısı

III. SONUÇLAR

Gayrimenkul değerlendirme sistemi için önerilen yapay sinir ağı tabanlı modeller için, modellerin ürettiği sonuçların başarıları değerlendirilmesinin yapılması gerekmektedir. Bu amaçla, literatürde sıklıkla kullanılan determinasyon katsayısı (R^2) ve ortalama hata karesi (MSE) methodları bu çalışmada

kullanılmıştır. Denklem 2’de, kullanılan R^2 hesaplama formülü verilmiştir[20].

$$R^2 = \frac{1}{r} \times \sum_{i=1}^r [(x_i - \bar{x}) \times (y_i - \bar{y})] / (\sigma_x \times \sigma_y)^2 \quad (2)$$

Burada, r tahmin sayısını, x_i gerçek değeri, \bar{x} ortalama gerçek değeri, y_i tahmin değerini, \bar{y} ortalama tahmin değerini, σ_x gerçek değerlerin standart sapmasını, σ_y tahmin değerlerinin standart sapmasını ifade etmektedir[20].

Modellerin değerlendirilmesinde kullanılan MSE formülü Denklem 3’te verilmiştir[21].

$$MSE = \frac{1}{N} \sum_{i=0}^N (Y_i - \hat{Y}_i)^2 \quad (3)$$

Burada, N tahmin sayısını, Y_i gerçek değeri, \hat{Y}_i tahmin edilen değeri ifade etmektedir[21].

Her iki model için ayrı ayrı MATLAB ortamında modellerin eğitim ve devamında test simülasyonları gerçekleştirilmiştir. Test simülasyonları sonucunda elde edilen model sonuçları, Tablo 4’te gösterildiği şekildedir.

Tablo 4. Yapay sinir ağı modellerinin test sonuçları

	YSA Model1 (Arsa)		YSA Model2 (Daire)	
	R^2	MSE	R^2	MSE
Fold 1	0.90	0.10	0.87	0.12
Fold 2	0.92	0.08	0.72	0.21
Fold 3	0.95	0.02	0.77	0.18
Fold 4	0.94	0.03	0.83	0.13
Fold 5	0.87	0.12	0.82	0.15
Fold 6	0.83	0.14	0.96	0.01
Fold 7	0.84	0.12	0.95	0.01
Fold 8	0.82	0.15	0.87	0.10
Fold 9	0.78	0.18	0.88	0.10
Fold 10	0.75	0.19	0.82	0.16
Ortalama	0.86	0.11	0.85	0.12

IV. TARTIŞMA

Bu çalışmada, tasarruf finansmanı sektöründe faaliyet gösteren firmaların ekspertiz süreçlerinde, daire ve arsa gayrimenkullerinin değerlendirilmesinde

kullanılmak üzere, yapay zeka temelli bir sistem önerisinde bulunulmuştur. Bu amaçla Türkiye’de yaygın olarak kullanılan gayrimenkul ilan sitelerinden halka açık veriler kullanılarak, veri toplama ve makine öğrenmesi sistemlerine uygun hale getirilebilmesi için uygulanması gereken süreçlerden bahsedilmiştir. Ayrıca gayrimenkul değerlendirilmede etki etmesi muhtemel özellikler ortaya çıkarılmıştır.

Çalışmada yapay zeka modellerinin kurulmasında, literatürde yaygın olarak kullanılan MATLAB ortamında, birçok yapay sinir ağı modeli denenerek, verisetlerine yönelik uygun modeller belirlenmiştir.

Önerilen modeller üzerinde gerçekleştirilen test simülasyonları sonucunda fiyat çıkış özelliğine ait R^2 değeri sırasıyla 0.86 ve 0.85, MSE değeri ise sırasıyla 0.11 ve 0.12 olarak hesaplanmıştır.

Elde edilen sonuçlar önerilen modellerin tasarruf finansmanı sektöründe faaliyet gösteren firmalar için arsa ve daire gayrimenkul türlerine ait değerlendirme işlemlerinde kullanılabilir, başarılı modeller olduğunu göstermiştir. Aynı zamanda modeller, ekspertiz süreçlerinde uzmana verdiği kararda destek sağlaması amacıyla bir karar destek sistemi olarak da kullanılabilir.

Sonraki çalışmalarda, farklı veri setleri veya farklı yapay zeka yöntemleri kullanılarak, modellerin sonuçları değerlendirilebilir. Elde edilen sonuçlar bu çalışmadaki sonuçlar ile karşılaştırılarak yorumlanabilir.

KAYNAKLAR

- [1] P. A. Arvanitidis, “The economics of urban property markets: An institutional economics analysis,” *The Economics of Urban Property Markets: An Institutional Economics Analysis*, pp. 1–252, Jan. 2014, doi: 10.4324/9781315758770.
- [2] J. Frew and G. D. Jud, “Estimating the value of apartment buildings,” *Journal of Real Estate Research*, vol. 25, no. 1, pp. 77–86, Jan. 2003, doi: 10.1080/10835547.2003.12091101.
- [3] C. Fan, Z. Cui, and X. Zhong, “House prices prediction with machine learning algorithms,” *ACM International Conference Proceeding Series*, pp. 6–10, Feb. 2018, doi: 10.1145/3195106.3195133.
- [4] K. Y. Ngiam and I. W. Khor, “Big data and machine learning algorithms for health-care delivery,” *Lancet*

- Oncol, vol. 20, no. 5, pp. e262–e273, May 2019, doi: 10.1016/S1470-2045(19)30149-4.
- [5] P. Harrington, “Machine Learning in Action,” *Mach Learn*, vol. 37, no. 3, pp. 1–20, 2012.
- [6] Ethem Alpaydın, *Introduction to Machine Learning*. The MIT Press, 2004.
- [7] N. J., “Review on the Application of Artificial Neural Networks in Real Estate Valuation,” *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 9, no. 3, pp. 2918–2925, 2020.
- [8] W. T. Lim, L. Wang, Y. Wang, and Q. Chang, “Housing price prediction using neural networks,” 2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery, ICNC-FSKD 2016, pp. 518–522, Oct. 2016, doi: 10.1109/FSKD.2016.7603227.
- [9] W. K. O. Ho, B. S. Tang, and S. W. Wong, “Predicting property prices with machine learning algorithms,” <https://doi.org/10.1080/09599916.2020.1832558>, vol. 38, no. 1, pp. 48–70, 2020, doi: 10.1080/09599916.2020.1832558.
- [10] S. O. Farrell, “House Price Prediction,” *Comparison of Data Mining Models to Predict House Prices*, Jan. 2018.
- [11] R. Manjula, S. Jain, S. Srivastava, and P. Rajiv Kher, “Real estate value prediction using multivariate regression models,” *IOP Conf Ser Mater Sci Eng*, vol. 263, no. 4, p. 042098, Nov. 2017, doi: 10.1088/1757-899X/263/4/042098.
- [12] A. Nur, R. Ema, H. Taufiq, and W. Firdaus, “Modeling House Price Prediction using Regression Analysis and Particle Swarm Optimization Case Study: Malang, East Java, Indonesia,” *International Journal of Advanced Computer Science and Applications*, vol. 8, no. 10, 2017, doi: 10.14569/IJACSA.2017.081042.
- [13] E. Ahmed and M. Moustafa, “House price estimation from visual and textual features,” *NCTA, 8th International Conference on Neural Computation Theory and Applications*, Sep. 2016.
- [14] B. Park and J. Kwon Bae, “Using machine learning algorithms for housing price prediction: The case of Fairfax County, Virginia housing data,” *Expert Syst Appl*, vol. 42, no. 6, pp. 2928–2934, Apr. 2015, doi: 10.1016/J.ESWA.2014.11.040.
- [15] A. Makalesi, C. Sertkaya, and S. Akçay, “Giysi Endüstrisinde Üretim Performansının Tahmininde Yapay Sinir Ağlarının Kullanılması,” *European Journal of Science and Technology*, vol. 28, no. 28, pp. 34–39, Nov. 2021, doi: 10.31590/EJOSAT.979656.
- [16] G. Aksu, C. O. Güzeller, and M. T. Eser, “The Effect of the Normalization Method Used in Different Sample Sizes on the Success of Artificial Neural Network Model,” *International Journal of Assessment Tools in Education*, pp. 170–192, Apr. 2019, doi: 10.21449/IJATE.479404.
- [17] I. S. H. Bahia, “A Data Mining Model by Using ANN for Predicting Real Estate Market: Comparative Study,” *Int J Intell Sci*, vol. 03, no. 04, pp. 162–169, 2013, doi: 10.4236/IJIS.2013.34017.
- [18] “Bölüm 3: Yapay Sinir Ağları (MatLab) Artificial Neural Network.” <https://slideplayer.biz.tr/slide/11225843/> (accessed May 12, 2023).
- [19] S. McGreal, A. Adair, D. McBurney, and D. Patterson, “Neural networks: the prediction of residential values,” *Journal of Property Valuation and Investment*, vol. 16, no. 1, pp. 57–70, Mar. 1998, doi: 10.1108/14635789810205128.
- [20] C. Sertkaya and N. Yurtay, “Artificial immune system based wastewater parameter estimation,” *Turkish Journal of Electrical Engineering and Computer Sciences*, vol. 26, no. 6, pp. 3356–3366, Jan. 2018, doi: 10.3906/elk-1503-206.
- [21] A. Makalesi, C. Sertkaya, and S. Akçay, “Giysi Endüstrisinde Üretim Performansının Tahmininde Yapay Sinir Ağlarının Kullanılması,” *Avrupa Bilim ve Teknoloji Dergisi*, vol. 28, no. 28, pp. 34–39, Nov. 2021, doi: 10.31590/EJOSAT.979656.