



Ekim/October 2025, Cilt/Volume: 15, Sayı/Issue: 2, ss. 229-245.

Başvuru/Submitted: 21.07.2025

Kabul/Accepted: 21.10.2025

Yayın/Published: 27.10.2025

DOI: 10.17828/yalovasosbil.1747075

Araştırma Makalesi/Research Article

<https://dergipark.org.tr/tr/pub/yalovasosbil>

Türkiye'nin İllere Göre Konut Satış Miktarının Sinir Ağları Yöntemiyle İncelenmesi

Şeyma Nur Ünal*

Öz

Konut sektörü bir ülkenin sosyal ve ekonomik kalkınmasında çok önemli bir rol oynamaktadır. Sektör, istihdam, tasarruf, yatırım ve işgücü verimliliği gibi başlıca makroekonomik göstergeler üzerindeki etkisiyle ekonomik büyüme ve kalkınmaya katkıda bulunmaktadır. Bilişim teknolojisinin ilerlemesiyle birlikte, makine öğreniminin konut sektöründe, özellikle de konut satış analizi için uygulanması giderek daha önemli hale gelmiştir. Bu araştırma illere göre konut satış miktarını Yapay Sinir Ağları (YSA) yöntemiyle analiz etmeyi amaçlamaktadır. Kullanılan veriler, sanayi üretim endeksi, tüketici güven endeksi, inşaat güven endeksi, ekonomik güven endeksi, döviz kurudur ve illere göre konut satış miktarıdır. Algoritmaların analizi, her iki algoritmanın performans test sonuçlarının Ortalama Karesel Hata (OKH), Kök Ortalama Karesel Hata (KOKH) ve R-Kare (R²) gibi regresyon modelleri için performans metrikleri kullanılarak karşılaştırılmasıyla gerçekleştirilir. Ek olarak, bu araştırma eğitim, doğrulama ve test verileri arasında hangi veri oranının en iyi sonuçları verdiğini analiz eder. Araştırma bulguları, OKH 0.0011 ve KOKH 0.0331 değerleri performans ölçütü ileri beslemeli sinir ağının 10-2 ağı sahip modelin YSA içinde en iyi performansı ürettiğini göstermektedir.

Anahtar Kelimeler: Makro İktisat, Konut Satışı, Yapay Zekâ, Makine Öğrenimi, Yapay Sinir Ağları.

Analysis of Housing Sales Quantity in Turkey by Provinces Using Neural Network Method

Abstract

The housing sector plays a very important role in the social and economic development of a country. The sector contributes to economic growth and development through its impact on major macroeconomic indicators such as employment, savings, investment and labor productivity. With the advancement of information technology, the application of machine learning in the housing industry, especially for housing sales analysis, has become increasingly important. This research aims to analyze the housing sales amount by province using Artificial Neural Networks (ANN) method. The data used

* Dr., sseymanurgnr@gmail.com, 0000-0002-3475-7226

are industrial production index, consumer confidence index, construction confidence index, economic confidence index, exchange rate and housing sales amount by province. Analysis of the algorithms is performed by comparing the performance test results of both algorithms using performance metrics for regression models such as Mean Square Error (MSE), Root Mean Square Error (RMSE) and R-Square (R²). Additionally, this research analyzes which data ratio among training, validation, and test data yields the best results. Research findings show that the performance criterion of feed forward neural network with 10-2 network produces the best performance within the ANN with MSE 0.0011 and RMSE 0.0331 values.

Keywords: Macroeconomics, Housing Sale, Machine Learning, Artificial Neural Network, Artificial Intelligence.

Giriş

Konut sektörü her zaman ekonominin ayrılmaz bir parçası olmuştur ve etkisi çok geniş kapsamlıdır. Herhangi bir ülkenin gayri safi yurtiçi hasılasına (GSYİH) en büyük katkıda bulunanlardan biridir. Sektör, konut ve ticari gayrimenkul mülklerinin inşası, finansmanı ve satışı ile ilgilenen çok çeşitli işletmeleri kapsar. Konut sektörünün performansı, istihdam oranlarını, tüketici harcamalarını ve hükümet gelirlerini etkileyerek genel ekonomi üzerinde önemli bir etkiye sahip olabilir. Konut sektörünü ve ekonomi üzerindeki etkisini anlamak, politika yapıcılar, yatırımcılar ve bireyler için aynı derecede önem arz etmektedir (Faster Capital, 2024).


Birçok alanda toplanan büyük miktardaki veriyi geliştiren gelişmiş kentsel dijitalleşme, karar destek sistemlerinde yapay zekâ (YZ) tabanlı araçların ortaya çıkmasına yol açmıştır. Bunlar, ev fiyat tahminleri gibi önemli karar alma süreçleri için değerli bilgiler çıkarmak üzere çeşitli makine öğrenimi algoritmaları kullanılmaktadır (Tekouabou, Gherghina, Kameni, Filali ve Gartoumi, 2023: 1079).

Makine Öğrenimi (MÖ) terimi, esas olarak o zamanki öncü yapay zekâ sistemlerinde "öğrenme" bileşenini sağlayan desen tanıma görevlerini tanımlamak için 1959 yılında IBM'de çalışırken Arthur Samuel tarafından tanıtılmıştır. Ekonomi problemlerine uygulanan Makine Öğrenmesinin başlangıcı 1974'e kadar uzanmakta olup o zamandan beri, ekonomideki görünümü giderek artmıştır (Gogas ve Papadimitriou, 2021: 2). Makine öğrenimi, bilgi toplamak ve gelecekteki olayları tahmin etmek için işletme, bilgisayar mühendisliği, endüstri mühendisliği, istatistik gibi disiplinlerde kullanılmıştır. Emlak piyasasındaki son büyümeyle birlikte, makine öğrenimi konut piyasasını analiz etmede önemli bir rol oynamaktadır (Park ve Bae, 2015: 2929). Yapay zekâ yöntemleri arasında Makine Öğrenmesi (MÖ), tablo verilerini tanımlamak, yorumlamak ve analiz etmek için kullanılabilen en son tekniklerden biri haline gelmiştir. MÖ algoritmaları, bilgisayar programlamada paradigmatik bir değişimi temsil etmektedir. Geleneksel olarak, bilgisayar bilimcileri kuralları ve verileri girdi olarak, sonuçları ise çıktı olarak kodlamışlardır. Ancak makine öğreniminde bilgisayarlar verileri ve sonuçları alırken, algoritma kuralları üretmektedir. Bu nedenle, bir MÖ sistemi açıkça programlanmak yerine eğitilmektedir. Son zamanlarda, MÖ'nin bir alt kümesi olan Yapay Sinir Ağları (YSA), verimlilikleri ve kolay uygulanabilirlikleri nedeniyle ivme kazanmaktadır (Rampini ve Cecconi, 2021: 589). Veri miktarları, bilgisayar teknolojisinin gelişimiyle sinir ağları finansal piyasaların analiz sürecinde daha fazla kullanılmaya başlanmıştır.

1. Türkiye’de Konut Sektörü

İnsanların temel ihtiyacı olan konut, toplumsal açıdan olduğu gibi ekonomik açıdan da önem taşımaktadır. Konut arzının artması, "makro ekonomik açıdan; artan çalışma ve yüksek güdüleme yoluyla yüksek ücretler ödenmesi, üretimin artması, yatırımdan çok getiri elde edilmesi gibi nedenlerle, ulusal ya da bölgesel gelirden artışlar görülmesi, kamu giderlerinde sağlanan düşüşler, mikro ekonomik açıdan ise konuta yatırım yapan kişinin kira, faiz vb. getiriler sonunda daha çok gelir elde etmesini sağlamaktadır" (Erdoğan, 1990: 11).

Türkiye’deki konut sektörü yıllara göre değişkenlik göstermektedir. Şekil 1’de 2023 Ocak ayında 97708 adet konut satışı yapıldığı görülmektedir. Bu sayı 2024 Ocak ayında 80308 iken 2025 Ocak ayında 112173’tür.

Şekil 1. Türkiye’deki Konut Satışı (Adet)

Kaynak: TÜİK

2. Makine Öğrenimi


Yapay zekânın (YZ) bir alt kümesi olan makine öğrenimi, sistemlere açıkça programlanmadan verilerden öğrenme yeteneği kazandırmaktadır. Makine öğrenimi algoritmaları genellikle denetlenen, denetlenmeyen, yarı denetlenen ve takviyeli öğrenme olmak üzere dört ana türe ayrılmaktadır. Denetimli öğrenme algoritmaları, eğitim verilerinin etiketli örnekler içerdiği problemler için kullanılmaktadır. Buna karşılık, denetimsiz öğrenme etiketsiz veriler kullanılarak modeller oluşturmayı içerir ve algoritmanın önceden tanımlanmış herhangi bir etiket olmadan verilerdeki örüntüleri ve ilişkileri algılaması beklenmektedir. Yarı denetimli öğrenme, birkaç etiketli verinin çok sayıda etiketsiz veriyle birlikte kullanıldığı denetlenen ve denetlenmeyen öğrenmeyi birleştirmektedir. Takviyeli öğrenme yöntemleri, akıllı bir etkenin çevre ile iletişim kurmasını ve eylemlerinden gelen geri bildirimle deneme yanılma yoluyla öğrenmesini sağlamaktadır. Denetimli öğrenme algoritmaları daha geniş uygulamalara sahiptir ve daha popülerdir. En yaygın kullanılanlar arasında lojistik regresyon, karar ağaçları, destek vektör makineleri, rastgele orman ve sinir ağları bulunmaktadır (Obaido, Mienye, Oluwaseun, Emmanuel, Ogunleye ve Ogbuokiri 2024).

Sinir ağları, beyindeki nöron ağlarının basitleştirilmiş modelleri olarak düşünülebilmektedir. Biyolojik açıdan bakıldığında, bir sinir ağının temel gereksinimi, ilgili "gerçek" ağın temel bilgi işleme özelliklerini yakalamaya çalışmasıdır. Yapay sinir ağı, işlevselliği genel olarak nörona dayanan, basit işlem elemanları, birimler veya düğümlerden oluşan birbirine bağlı bir yapıdır. Ağın işlem yeteneği, bir dizi eğitim modeline uyum sağlama veya bu modellerden öğrenme süreciyle elde edilen birimler arası bağlantı güçlerinde veya ağırlıklarında saklanmaktadır (Gurney, 1997: 10). YSA'lar içerisinde ileri beslemeli sinir ağı, Elman sinir ağı ve NARX sinir ağı en popüler olan sinir ağları arasında gösterilebilmektedir.

2.1. İleri Beslemeli Sinir Ağı

Yapay sinir ağı, deneyimlerden gelen bilgiyi depolar (örneğin, geçmiş verileri kullanarak) ve kullanıma hazır hale getirir. Şekil 2, iki gizli katmandan oluşan ileri beslemeli bir sinir ağı mimarisinin şematik diyagramını göstermektedir. Gizli katman sayısı, problemin doğasına ve karmaşıklığına bağlıdır. YSA'lar, kara kutu modelleri gibi çalışırları ve girdiler ile çıktılar arasındaki ilişkiyi öğrendikleri için sistem hakkında herhangi bir bilgiye ihtiyaç duymamaktadırlar (Ahmad, Mourshed, ve Rezgui, 2017: 4).

Şekil 2. YSA Görseli



Kaynak: Ahmad, Mourshed, & Rezgui, 2017: 6


YSA modeli giriş, gizli ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır. Giriş katmanında, özneliliklerini temsil eden giriş değişkenleri ağı beslenir. Gizli katman, matematiksel işlemin gerçekleştiği giriş ve çıkış katmanı arasındaki katman olarak tanımlanmaktadır. Gizli katmanda gerçekleşen dönüşümün sonucu, tahmin edilen özellik değerinin elde edildiği çıkış katmanında üretilmektedir (Abidoye & Chan, 2017: 561).

2.2. Elman Sinir Ağı

Elman sinir ağı tekrarlayan sinir ağlarından biridir. Tekrarlayan sinir ağlarında çıktı, bir önceki hesaplama ile bağlantılıdır. Bu ağlar o ana kadar hesaplananlar hakkında bilgi toplayan bir “hafıza” tutmaktadır (Ahmed, Mourshed ve Rezgui 2023: 13537). Tekrarlayan sinir ağındaki her birim, ağındaki bilgileri daha uzun bir süre boyunca saklayabileceği şekilde tekrarlayan bağlantılar içermektedir.

Elman sinir ağı; eğitilmiş, denetimli, çıktı ve istenen çıktı arasındaki farklılığı azaltmak için her katmanın ağırlıklarını güncelleyen hata geri yayılım algoritmasını kullanmaktadır. Bağlam birimlerine sahip bağlam katmanı ve gizli katmandan oluşan elman sinir ağı Şekil 3'te gösterilmektedir (Sathiavelu ve Mouleswaran, 2024: 6).

Şekil 3. Elman Sinir Ağı Görseli




Kaynak: Sathiavelu & Mouleswaran, 2024: 7.

2.3. NARX (Doğrusal Olmayan Otoregresif Dışsal Girdili) sinir ağları

NARX sinir ağları, harici zaman serisi girdilerini dikkate alabilen zaman serisi modelinin bir sinir ağı versiyonu olarak görülebilmektedir. Tahminleri aynı seriden gelen geçmiş verilere dayanmaktadır. Standart bir NARX sinir ağı mimarisi, paralel mimari çıktıyı ileri beslemeli sinir ağına geri besler, burası TDL zamansal gecikme hattıdır. Diğer mimari mod, geri bildirimle tahmin edilen çıktı yerine gerçek çıktıyı kullanan bir seri-paralel mimaridir (Song, Sun, Zhang, Du ve Li, 2021).

Şekil 4. NARX Sinir Ağı görseli



Kaynak: Ibtissem ve Nouredine, 2013: 2

Giriş ve çıkış gecikmelerine sahip tipik bir doğrusal olmayan tahmin modeli olarak NARX modelindeki akış $\hat{y} = (k + 1)$ öncesindeki giriş ve çıkış akış tahminlerinden elde edilmektedir.

3. Öğrenme Algoritmaları

Kenneth Levenberg ve Donald Marquardt tarafından bağımsız olarak geliştirilen Levenberg-Marquardt (LM) algoritması, doğrusal olmayan bir işlevi en aza indirme sorununa sayısal bir çözüm sunmaktadır. Bu algortima hızlıdır ve istikrarlı bir yakınsamaya sahiptir. Yapay sinir ağları alanında LM algoritması küçük ve orta ölçekli problemleri eğitmek için kullanılmaktadır (Yu ve Wilamowski, 2011: 11).

Bayesian Regularization, yapay sinir ağlarını genelleştirmek ve model belirsizliklerini değerlendirmek için birçok mühendislik çalışmasında yaygın olarak uygulanmaktadır. Algoritma, hiperparametreleri ve karşılık gelen ağırlıkları eğitmek için ‘kanıtları’ en üst düzeye çıkarma amacını kullanmaktadır. Bayes terimleriyle kanıt, arka olasılığın normalleştirici sabitidir ve model karmaşıklığı ile ters orantılıdır. Kanıtları en üst düzeye çıkarmak, model karmaşıklığını azalmaktadır. Bu durum ‘aşırı uyumu’ hafifletirken diğer yandan model genellemesini iyileştirmektedir (Chan, Ngan ve Rad, 2003: 29). Çalışmada öğrenme algoritmalarından biri olan Levenberg Marquardt (LM) öğrenme algoritmaları kullanılarak sinir ağları modelleri oluşturulmuştur.

4. Literatür

Ghorbani ve Afgheh (2017) 2015 yılındaki İran’ın Ahvaz kentindeki konut fiyatını tahmin etmek için 27 ilgili değişkene dayalı olarak 286 istatistiksel birimi kullanmışlardır. Bu çalışmada yarı log hedonik fonksiyon ve Yapay Sinir Ağı Çok Katmanlı Algılayıcı (MLP) yaklaşımları uygulanmıştır. Test sonuçları Hedonik regresyon modeline (%88) kıyasla YSA (%98) modelinin daha yüksek performansını doğrulayan iki modelin tahmin gücü arasında anlamlı bir fark olduğunu göstermiştir (Ghorbani ve Afgheh: 2017).

Oshodi vd. (2019) çalışmalarında, Güney Afrika Cape Town'daki konut mülklerinin kira fiyatlarını tahmin etmek için bir sinir ağı modeli geliştirmiştir. 286 konut mülküne ilişkin veriler 2018 yılında toplanmıştır. Sonuçlar, geliştirilen sinir ağı modelinin tahmin doğruluğunun %78,95 olduğunu göstermektedir (Oshodi, Thwala, Odubiyi, Abidoye ve Aigbavboa , 2019).

Winky vd. (2020), çalışmalarında emlak fiyatlarının değerlendirilmesinde destek vektör makinesi (DVM), rastgele orman (RO) ve gradyan artırma makinesi (GAM) olmak üzere üç makine öğrenimi algoritması kullanılmıştır. Hong Kong’ta Haziran 1996’dan Ağustos 2014’e kadar yaklaşık 40.000 konut işleminin veri örneğini incelenmiştir. Tahmin gücü açısından, RO ve GAM, DVM ile karşılaştırıldığında daha iyi performans elde etmiştir. Bu iki algoritma ile ilişkili ortalama karesel hata, kök ortalama karesel hata ve ortalama mutlak yüzde hatası olmak üzere üç performans metriği de destek vektör makinesindekilerden daha iyi performans göstermektedir.

Sa’at vd. (2021) 2009-2018 dönemine ait Malezya konut işlem verilerini kullanarak Hedonik Fiyat Modeli’nin ve YSA arasındaki tahmin performansını değerlendirmeyi amaçlamaktadır. Sonuçlar, YSA’nın hem istatistiksel hem de tahmin performansında HFM’den daha iyi performans sergilediğini göstermiştir.

Nazemi ve Rafiean (2022), çalışmalarında İran'ın İsfahan kenti için 1995- 2017 yılları arasındaki konut fiyatını etkileyen verileri kullanarak yapay sinir ağı modeli oluşturmuşlardır. Yapılan analiz sonucunda MAPE değeri% 4,3, RMSE değeri 4,75 olarak elde edilirken korelasyon değeri (R) 0,9998 olarak bulunmuştur. Bu durum modelin doğruluğunun kabul edilebilir düzeyde olduğunu ispat etmiştir.

Bai ve Chan (2023) Amerika Birleşik Devletleri'nin 2021 yılındaki Ames şehrinin konut fiyat verilerini tahmin etmekte ve konut fiyatları ile göstergeler arasındaki doğrusal olmayan eşleme ilişkisini çözmek için bir Bayesian düzenli BP sinir ağı modeli kurmaktadır. Model sonucunda R değeri 0,9667 olarak elde edilmiştir.

Lee vd. (2024), Avustralya Greater Sydney bölgesi için 2018'deki konut mülkü işlem verilerini kullanmıştır. Model olarak sayısal ve kategorik değişkenlere sahip tam bağlı sinir ağı katmanları olan bir evrişimli sinir ağı (CNN) ile bir makine öğrenimi modeli kullanarak otomatik mülk değerlemesine yönelik yeni bir yaklaşım önermiştir. Çalışma; birleştirilmiş modelin, temel modelin MAPE'sinden (%11,59) önemli ölçüde daha düşük ortalama mutlak yüzde hatası (MAPE) (%8,71) olan değerlemeler ürettiğini bulmuştur.

Xu ve Zhang (2024) çalışmalarında, Temmuz 2005-Nisan 2021 tarihleri arasında 10 büyük Çin şehrinde ofis mülkü fiyat endeksi tahmini için sinir ağlarını incelemeyi amaçlamaktadır. Bu bağlamda yazarlar, eğitim, doğrulama ve test aşamaları için 10 şehirde yaklaşık %1,45 ortalama bağıl karekök hatasının istikrarlı performansına yol açan üç gecikme ve üç gizli nöron içeren basit bir sinir ağı (NN) elde etmişlerdir.

Soltani ve Lee (2024) çalışmalarında, Güney Avustralya konut fiyatlarını makine öğrenimi algoritmaları uygulayarak analiz etmişlerdir. 2010'dan 2021'e kadar 10.000'den fazla bölgesel ev satışından oluşan kapsamlı bir veri seti kullanılmıştır. Konut fiyatları ile mikroekonomik faktörler (örneğin, ev büyüklüğü, arazi alanı, bina kalitesi) ve sosyoekonomik özellikler (örneğin, olanaklara yakınlık ve gelir düzeyleri) arasındaki doğrusal olmayan ilişkiler araştırılmıştır. Analiz sonucunda, makine öğrenimi modellerinin bölgesel konut fiyatlarını tahmin etmede, geleneksel ekonometrik modellerden daha yüksek doğruluk ve daha iyi uyum ile daha iyi performans gösterdiği sonucuna ulaşılmıştır.

5. Analiz

Bu çalışmada illere göre konut satışlarında etkili olan parametrelerin yapay sinir ağları ile incelenmesi gerçekleştirilmiştir. Her bir göstergenin farklı boyutları nedeniyle, eğitim sürecinde daha yüksek değerlere sahip özellikler ağ ağırlığı üzerinde daha büyük bir etkiye sahip olabilir ve daha küçük değerlere sahip özelliklerin sonuçlar üzerindeki etkisini zayıflatabilmektedir. Bu nedenle, çalışmanın başında, büyük hatalara neden olmamak için göstergelerin verilerini normalleştirmek gerekmektedir. Spesifik olarak normalizasyon, verileri işleme için 0 ila 1 aralığına eşlemektir. Bu durum boyutsal ifadeyi boyutsuz ifadeye dönüştürme rolünü oynamaktadır. Böylece farklı birimlerin göstergeleri çalıştırılabilir, ağırlıklandırılabilir ve genel işlem basitleştirilebilir (Bai ve Chen, 2023: 21). Tablo 1'de analizde kullanılan illere göre konut satış miktarı, sanayi üretim endeksi, tüketici güven endeksi, inşaat güven endeksi, ekonomik güven endeksi ve döviz kuru verilerinin normalizasyon değerleri verilmektedir.

$$X_{ölçeklenmiş} = \frac{X_n - X_{minimum}}{X_{maksimum} - X_{minimum}}$$

$$X_n = X_{ölçeklenmiş} * (X_{maksimum} - X_{minimum}) + X_{minimum}$$

Tablo 1. Analizde Kullanılan Verilerin Normalizasyon Yapılmış Değerleri

Yıl	İllere Göre Konut Satışı	Sanayi Üretim Endeksi	Tüketici Güven Endeksi	İnşaat Güven Endeksi	Ekonomik Güven Endeksi	Döviz Kuru
2013.01	0,2395498392	0,01354401806	0,8264705882	0,7063655031	0,9314079422	0,001021422194
2013.02	0,2454448017	0	0,8352941176	0,8090349076	0,9620938628	0
2013.03	0,2958199357	0,1004514673	0,8441176471	1	0,9837545126	0,001443522194
2013.04	0,281886388	0,1139954853	0,8617647059	0,9527720739	0,9620938628	0,001082641646
2013.05	0,3242229368	0,1681715576	0,9441176471	0,9301848049	0,9873646209	0,001804402743
2013.06	0,2877813505	0,1602708804	0,9205882353	0,8562628337	0,9981949458	0,004691447131
2013.07	0,3424437299	0,1884875847	0,9735294118	0,8028747433	0,9711191336	0,005774088777
2013.08	0,2234726688	0,006772009029	0,9382352941	0,7638603696	0,9855595668	0,006856730422
2013.09	0,31886388	0,2178329571	0,8235294118	0,6776180698	0,9548736462	0,009022013713
2013.10	0,1800643087	0,1207674944	0,8794117647	0,659137577	0,9837545126	0,007939372068
2013.11	0,3210075027	0,2641083521	0,9823529412	0,6344969199	0,9837545126	0,009022013713
2013.12	0,3912111468	0,269751693	0,9058823529	0,5564681725	0,9458483755	0,01046553591
2014.01	0,2406216506	0,118510158	0,8264705882	0,8357289528	0,8971119134	0,01623962468
2014.02	0,2132904609	0,07223476298	0,7588235294	0,772073922	0,8844765343	0,01587874414
2014.03	0,2406216506	0,190744921	0,8529411765	0,7864476386	0,9061371841	0,01623962468
2014.04	0,2191854234	0,1794582393	1	0,8316221766	0,9512635379	0,01299169975
2014.06	0,2690246517	0,2110609481	0,8852941176	0,7823408624	0,940433213	0,0126308192
2014.07	0,2272240086	0,1534988713	0,8911764706	0,7145790554	0,9079422383	0,0126308192
2014.08	0,3370846731	0,1388261851	0,8882352941	0,7392197125	0,9205776173	0,01407434139
2014.09	0,3912111468	0,2855530474	0,9	0,7125256674	0,9494584838	0,01587874414
2014.10	0,283494105	0,1738148984	0,8235294118	0,5893223819	0,963898917	0,01768314688
2014.11	0,3269024652	0,2607223476	0,8088235294	0,6119096509	0,9079422383	0,01696138578
2014.12	0,4924973205	0,355530474	0,7882352941	0,5605749487	0,9151624549	0,01876578852
2015.01	0,2325830654	0,1094808126	0,7617647059	0,7166324435	0,9277978339	0,02020931072
2015.02	0,2808145766	0,08126410835	0,7470588235	0,8480492813	0,9223826715	0,02490075785
2015.03	0,3933547696	0,2562076749	0,6794117647	0,8973305955	0,857400722	0,02959220498
2015.04	0,4105037513	0,2516930023	0,7058823529	0,8747433265	0,8989169675	0,03175748827
2015.05	0,3488745981	0,2460496614	0,6882352941	0,8993839836	0,9007220217	0,03175748827
2015.06	0,3638799571	0,3103837472	0,7705882353	0,8726899384	0,8790613718	0,03356189101
2015.07	0,2883172562	0,2042889391	0,7294117647	0,7782340862	0,8682310469	0,03356189101
2015.08	0,3735262594	0,2776523702	0,6411764706	0,7371663244	0,8682310469	0,03897509924
2015.09	0,2663451233	0,2268623025	0,5529411765	0,636550308	0,797833935	0,04474918802
2015.10	0,3290460879	0,3577878104	0,6647058824	0,5544147844	0,8501805054	0,04186214363
2015.11	0,3397642015	0,3442437923	0,9352941176	0,6570841889	0,9494584838	0,03969686034
2015.12	0,5353697749	0,4503386005	0,8794117647	0,613963039	0,940433213	0,04150126308
2016.01	0,2240085745	0,1613995485	0,8382352941	0,7515400411	0,9187725632	0,04474918802
2016.02	0,3161843516	0,2121896163	0,7735294118	0,8151950719	0,8718411552	0,04222302418
2016.03	0,399249732	0,3318284424	0,7794117647	0,8583162218	0,8790613718	0,04041862144
2016.04	0,3408360129	0,2900677201	0,8176470588	0,8767967146	0,8664259928	0,03861421869
2016.05	0,3863879957	0,3397291196	0,8323529412	0,8028747433	0,8790613718	0,04186214363

2016.06	0,3403001072	0,3431151242	0,8411764706	0,7864476386	0,8754512635	0,04150126308
2016.07	0,2068595927	0,111738149	0,7735294118	0,7761806982	0,8898916968	0,04294478528
2016.08	0,38585209	0,3216704289	0,9352941176	0,6796714579	0,8483754513	0,04330566582
2016.09	0,3547695606	0,1862302483	0,9235294118	0,659137577	0,916967509	0,04294478528
2016.10	0,4694533762	0,4063205418	0,9294117647	0,5708418891	0,8971119134	0,04691447131
2016.11	0,4817792069	0,414221219	0,8235294118	0,4784394251	0,9061371841	0,05413208228
2016.12	0,5359056806	0,4582392777	0,6941176471	0,431211499	0,844765343	0,06207145435
2017.01	0,281886388	0,2268623025	0,7352941176	0,5544147844	0,7996389892	0,07109346806
2017.02	0,3145766345	0,2167042889	0,7117647059	0,6755646817	0,8700361011	0,06892818477
2017.03	0,4619506967	0,4085778781	0,7794117647	0,9425051335	0,9097472924	0,06856730422
2017.04	0,384244373	0,374717833	0,8411764706	0,9691991786	0,9205776173	0,06820642367
2017.05	0,3954983923	0,414221219	0,9058823529	0,9466119097	0,940433213	0,06495849874
2017.06	0,293676313	0,3171557562	0,8617647059	0,909650924	0,9512635379	0,06315409599
2017.07	0,3917470525	0,4006772009	0,8764705882	0,841889117	0,9675090253	0,06459761819
2017.08	0,4153269025	0,414221219	0,8852941176	0,8542094456	1	0,06315409599
2017.09	0,5230439443	0,3792325056	0,8411764706	0,704312115	0,9945848375	0,06134969325
2017.10	0,4292604502	0,5519187359	0,7705882353	0,6447638604	0,9891696751	0,06856730422
2017.11	0,4287245445	0,5417607223	0,7058823529	0,6016427105	0,9422382671	0,07614579574
2017.12	0,4833869239	0,6004514673	0,7176470588	0,5379876797	0,9241877256	0,0750631541
2018.01	0,2915326902	0,3634311512	0,8529411765	0,7885010267	0,9909747292	0,07253699026
2018.02	0,2851018221	0,3194130926	0,8705882353	0,8213552361	0,976534296	0,07253699026
2018.03	0,3654876742	0,493227991	0,85	0,7967145791	0,9386281588	0,07614579574
2018.04	0,3236870311	0,427765237	0,8323529412	0,8254620123	0,90433213	0,08264164562
2018.05	0,4121114684	0,4977426637	0,8088235294	0,7597535934	0,880866426	0,09563334536
2018.06	0,411039657	0,3408577878	0,8147058824	0,6776180698	0,8303249097	0,1032118369
2018.07	0,434619507	0,4954853273	0,8676470588	0,6735112936	0,8321299639	0,1075424035
2018.08	0,3344051447	0,2686230248	0,7441176471	0,4579055441	0,7274368231	0,1432695778
2018.09	0,4533762058	0,4266365688	0,5205882353	0,1437371663	0,5866425993	0,1660050523
2018.10	0,5562700965	0,4830699774	0,4411764706	0,112936345	0,5559566787	0,1476001444
2018.11	0,2513397642	0,4424379233	0,5147058824	0,05749486653	0,6407942238	0,130277878
2018.12	0,5042872454	0,453724605	0,4794117647	0	0,6588447653	0,1277517142
2019.01	0,1618435155	0,2708803612	0,4911764706	0,160164271	0,6245487365	0,1299169975
2019.02	0,191318328	0,2607223476	0,4529411765	0,1724845996	0,6263537906	0,126308192
2019.03	0,3344051447	0,4300225734	0,5205882353	0,2710472279	0,6768953069	0,1328040419
2019.04	0,2861736334	0,4130925508	0,5941176471	0,3080082136	0,702166065	0,1432695778
2019.05	0,2636655949	0,4966139955	0,4	0,1786447639	0,6101083032	0,1544568748
2019.06	0,09967845659	0,2257336343	0,4911764706	0,1683778234	0,702166065	0,1461566222
2019.07	0,31886388	0,4898419865	0,4558823529	0,18275154	0,6588447653	0,1411042945
2019.08	0,3633440514	0,2494356659	0,4764705882	0,205338809	0,7328519856	0,1392998917
2019.09	0,5584137192	0,4796839729	0,4176470588	0,2525667351	0,7166064982	0,1425478167
2019.10	0,5364415863	0,5203160271	0,4352941176	0,2915811088	0,7815884477	0,1450739805
2019.11	0,5123258307	0,4966139955	0,5235294118	0,2361396304	0,7942238267	0,1432695778
2019.12	0,8542336549	0,585778781	0,5029411765	0,3141683778	0,8411552347	0,1468783833

2020.01	0,3799571275	0,3577878104	0,5205882353	0,636550308	0,844765343	0,1497654276
2020.02	0,4072883173	0,388261851	0,4676470588	0,6324435318	0,8303249097	0,1544568748
2020.03	0,3531618435	0,4176072235	0,5176470588	0,7679671458	0,7509025271	0,1642006496
2020.04	0	0,01354401806	0,4352941176	0,03080082136	0	0,1826055576
2020.05	0,04394426581	0,08013544018	0,5735294118	0,3326488706	0,2093862816	0,1872970047
2020.06	0,7899249732	0,4187358916	0,5764705882	0,7556468172	0,463898917	0,1818837965
2020.07	1	0,4808126411	0,5705882353	0,9014373717	0,6516245487	0,1836881992
2020.08	0,6843515541	0,4311512415	0,4823529412	0,794661191	0,7039711191	0,1981234211
2020.09	0,5037513398	0,6331828442	0,5441176471	0,7125256674	0,7418772563	0,2071454349
2020.10	0,4115755627	0,6546275395	0,5323529412	0,6160164271	0,8014440433	0,2204980152
2020.11	0,3735262594	0,6151241535	0,4882352941	0,5379876797	0,7761732852	0,2251894623
2020.12	0,3386923901	0,7641083521	0,4823529412	0,4845995893	0,7545126354	0,2150848069
2021.01	0,1489817792	0,4469525959	0,5735294118	0,5195071869	0,7833935018	0,2031757488
2021.02	0,206323687	0,4593679458	0,6088235294	0,5852156057	0,7707581227	0,1916275713
2021.03	0,3670953912	0,6772009029	0,6823529412	0,5975359343	0,8321299639	0,211836882
2021.04	0,2845659164	0,5891647856	0,4970588235	0,5544147844	0,738267148	0,2306026705
2021.05	0,08788853162	0,453724605	0,4147058824	0,5564681725	0,7166064982	0,2374594009
2021.06	0,4930332262	0,7246049661	0,5470588235	0,5852156057	0,8176895307	0,2464814147
2021.07	0,3483386924	0,460496614	0,4911764706	0,6427104723	0,8700361011	0,2472031757
2021.08	0,5289389068	0,690744921	0,4441176471	0,7310061602	0,8844765343	0,2421508481
2021.09	0,5594855305	0,7663656885	0,4764705882	0,6611909651	0,9151624549	0,2435943703
2021.10	0,5075026795	0,7358916479	0,3852941176	0,6303901437	0,8971119134	0,2663298448
2021.11	0,7293676313	0,8306997743	0,2176470588	0,6324435318	0,8646209386	0,3161313605
2021.12	0,9849946409	1	0,15	0,5277207392	0,8321299639	0,4247564056
2022.01	0,2443729904	0,5665914221	0,2735294118	0,523613963	0,8772563177	0,4168170336
2022.02	0,293676313	0,6455981941	0,2176470588	0,5441478439	0,8285198556	0,4355828221
2022.03	0,4898177921	0,8340857788	0,2705882353	0,5811088296	0,7779783394	0,4655359076
2022.04	0,4844587353	0,7550790068	0,1147058824	0,6570841889	0,7635379061	0,4720317575
2022.05	0,4287245445	0,6399548533	0,1294117647	0,6016427105	0,8032490975	0,5312161674
2022.06	0,5782422294	0,8758465011	0	0,6242299795	0,7454873646	0,5391555395
2022.07	0,2743837085	0,5124153499	0,15	0,6406570842	0,738267148	0,5824612053
2022.08	0,4324758842	0,7674943567	0,2735294118	0,6303901437	0,7490974729	0,5925658607
2022.09	0,3788853162	0,7855530474	0,2794117647	0,5934291581	0,7509025271	0,6041140383
2022.10	0,3210075027	0,7957110609	0,3794117647	0,5954825462	0,8014440433	0,6077228437
2022.11	0,4024651661	0,8148984199	0,3882352941	0,5995893224	0,7960288809	0,6077228437
2022.12	0,8853161844	0,9751693002	0,3529411765	0,59137577	0,8104693141	0,6106098881
2023.01	0,2947481243	0,6602708804	0,4617647059	0,6960985626	0,8339350181	0,6149404547
2023.02	0,2004287245	0,5124153499	0,5617647059	0,6858316222	0,8267148014	0,6174666185
2023.03	0,3360128617	0,8284424379	0,4911764706	0,7166324435	0,8231046931	0,6279321545
2023.04	0,229903537	0,5880361174	0,7088235294	0,7330595483	0,8862815884	0,6380368098
2023.05	0,3778135048	0,8103837472	0,8147058824	0,8028747433	0,9115523466	0,6835077589
2023.06	0,2191854234	0,6873589165	0,6382352941	0,704312115	0,8664259928	0,8762179719
2023.07	0,3579849946	0,7742663657	0,4911764706	0,6755646817	0,8321299639	0,9076145796

2023.08	0,4255091104	0,8148984199	0,1352941176	0,636550308	0,738267148	0,899314327
2023.09	0,3210075027	0,8374717833	0,2382352941	0,6098562628	0,761732852	0,9252977265
2023.10	0,2733118971	0,8600451467	0,3294117647	0,5893223819	0,7815884477	0,9577769758
2023.11	0,2722400857	0,8126410835	0,3558823529	0,6160164271	0,7581227437	0,9787080476
2023.12	0,513397642	0,9514672686	0,4117647059	0,5318275154	0,7779783394	1

Modellerinin performans ölçütleri için Kök ortalama kare hatası (Root Mean Square Error-RMSE) kullanılmış ve performans değeri (R) verilmiştir. RMSE değerinin sıfıra yakın olması R değerinin ise 1'e yakın olması başarılı bir analiz yapıldığını göstermektedir. Kök-ortalama-kare hatası model değerlendirmede kullanılan standart ölçütlerden biridir (Hodson, 2022). Analizde kullanılan performans ölçütlerinin hesaplanması aşağıda verilmiştir.


$$MSE = \frac{\sum(Av - Ev)^2}{N}$$

$$RMSE = \sqrt{\frac{\sum(Av - Ev)^2}{N}}$$

AV= Gerçek değer, EV= Modele göre tahmini değer, N= Gözlem sayısı (Nazemi ve Rafieian, 2021).

Bu çalışmanın temel amacı; yapay sinir ağı modellerinden ileri besleme sinir ağı, elman sinir ağı ve NARX sinir ağıyla Ocak 2013 ile Aralık 2023 arasındaki illere göre konut satışının analizinin yapılmasıdır. Uygulamanın bağımlı değişkeni, yani hedeflenen değer illere göre konut satış miktarı iken bağımsız değişkenler; sanayi üretim endeksi, tüketici güven endeksi, inşaat güven endeksi, ekonomik güven endeksi ve döviz kurudur.


Şekil 5. Analizde Kullanılan Verilerin Görseli




Kaynak: Yazar tarafından oluşturulmuştur

YSA modellerinin tasarlanması bir dizi sistemik prosedürü takip etmektedir. Genel olarak beş temel adım vardır: (1) veri toplama, (2) verileri ön işleme, (3) ağı kurma, (4) eğitme ve (5) modelin test performansı. Bu temel adımlar şekil 6'da verilmektedir.

Şekil 6. Yapay Sinir Ağı Modelini Tasarlamak İçin Temel Akış




Şekil 7. MATLAB Sinir Ağı Oluşumu

Kaynak: Görsel MATLAB programı ile çıkarılmıştır

Analizde kullanılan veri setlerinin eğitilmesi için traininglm (Levenberg-Marquardt) algoritması seçilmiş olup, learngdm (Adaptation Learning Function) öğrenme fonksiyonu olarak ve aktivasyon fonksiyonu için de tanjant sigmoid (tansig) fonksiyonu uygulanarak yapay sinir ağı modeli oluşturulmuştur. Şekil 7’de uygulanan komut ekranı verilmektedir. ‘tansig’ ifadesi, tan-sigmoid fonksiyonun transfer fonksiyonu olarak seçilmesi durumunda Matlab’da kullanılan komutu göstermektedir. Yapay sinir ağları uygulamalarında en çok kullanılan transfer fonksiyonlarından biri de tan-sigmoid fonksiyondur (Ersöz, Yaman ve Birgören, 2008). Levenberg-Marquardt (LM) algoritması yapay sinir ağlarının eğitiminde sağlamış olduğu hız ve kararlılık nedeni ile tercih edilmektedir (Çavuşlu, Becerikli ve Karakuzu, 2012).

5.1. NARX Sinir Ağı

Şekil 8’de çok aşamalı tahmin için kapalı döngü doğrusal olmayan otoregresif (NARX) zaman serisi problemi için sinir ağı kurulumu gösterilmektedir

Şekil 8. NARX Sinir Ağı Oluşumu


Kaynak: Görsel MATLAB programı ile çıkarılmıştır

NARX Ağ Mimarisinde, 5 adet girdi ve bir adet çıktı değişkeni bulunmaktadır. Girdi katmanında, ağa sunulan beş bağımsız değişkene ait beş adet girdi işlemci elemanı, çıktı katmanında ise bağımsız değişkene ait bir adet çıktı işlemci elemanı bulunmaktadır. Çalışma sonucunda 12 nöron sayısına sahip olan ağ en iyi sonucu verdiği için bu ağın görseli kullanılmıştır. NARX Ağ Yapısı, gizli katmanda sigmoid transfer fonksiyonu ve çıkış katmanında doğrusal transfer fonksiyonu bulunan iki katmanlı bir ağıdır. Ağ yapısı, 5 girdi, 12 gizli nöron ve 1 çıktıdan oluşmaktadır. Ağın eğitimi için Levenberg-Marquardt algoritması kullanılmıştır. Veriler training- eğitim %70 (92) validation- doğrulama %15 (20) testing-test %15 (20) olarak ayrılmıştır. Kullanılan nntool arayüzü ve eğitim sonucunda elde edilen veriler Şekil ’de gösterilmiştir.

5.2. İleri Geri Besleme Sinir Ağı Modeli

İleri geri besleme ağı en az üç katmandan (giriş, gizli katman ve çıkış) oluşmaktadır. Bu oluşum bilgi dolaşımının yönü ve değişkenler için ağırlık hesaplamalarının, girdilerden çıkışlara kadar gizli katman üzerinden uygulanmasıyla olmaktadır. Ardından, ağ eğitimi sürecinde hata değerlerini azaltmak için değişkenlerin ağırlıkları ayarlanmaktadır. Şekil 9'da gösterilen ileri geri besleme sinir ağında, 5 adet girdi ve bir adet çıktı değişkeni bulunmaktadır.

Şekil 9. İleri Geri Besleme Sinir Ağı Modeli




Kaynak: Görsel MATLAB programı ile çıkarılmıştır

5.3. Elman Sinir Ağı


Elman sinir ağı, giriş katmanı, gizli katman ve çıkış katmanının varlığı açısından ileri besleyici ağlara benzer, ancak bağlam katmanı olan ek bir dördüncü katman içermektedir. Bağlam katmanı girdileri gizli katman çıktılarından gelmektedir. Şekil 10'da gösterildiği gibi önceki zamanın gizli katmanının çıktı değerlerini depolamak için kullanılır. Bu nedenle bağlam katmanı olarak adlandırılmaktadır. Elman Sinir Ağı, zaman içinde değişen kalıpları tespit etmeye ve oluşturmaya yardımcı olan her gizli katmanın çıkışından ilgili katmanın girdisine gelen geri bildirimi kullanmaktadır. Ayrıca bu ağ, öğrenme süreci boyunca minimum hata dizilerini elde etmek için geri yayılma yöntemlerinden faydalanmaktadır.(Elshamy, Tiraturyan, Uglova ve Elgendy, 2021: 48).

Şekil10. Elman Sinir Ağı Modeli



Kaynak: Görsel MATLAB programı ile çıkarılmıştır

Analizde uygulanan eğitim sonunda, her girdi örneği için, YSA modeli tarafından bir çıktı (tahmini konut fiyatı) tahmin edilmiştir. Daha sonra elde edilen sonuçlar hedef değerlerle (gerçek konut fiyatı) karşılaştırılmıştır. Çıktılar ve hedef değerler arasındaki korelasyon katsayısı (R-değeri), eğitilmiş YSA'yı değerlendirmek için uygun bir indeks olarak seçilmiştir. Eğitim seti (Train), doğrulama seti (validation), test seti (Test) ve tüm veri seti (ALL) için R değerleri hesaplanmıştır. Uygulama sonucunda önerilen İleri geri besleme sinir ağı modeli (10- 2) modeli için, eğitim setiyle ilgili R değeri 1'e çok yakın bulunmuştur. Bu durum sinir ağında çok iyi bir uyum olduğunu göstermektedir. Diğer yandan test seti ile ilgili R değerinin 0,81 olması bu durumun iyi bir uyuma sahip olduğunu göstermektedir. Şekil 11'de, elde edilen çıktı, hedef ve R değerleri gösterilmektedir. Bu şekilde, YSA çıktıları hedeflere (daireler) göre çizilmektedir. En iyi doğrusal uyum, düz çizgi ile gösterilirken mükemmel uyum (hedeflere eşit çıktı) kesikli bir çizgi ile gösterilmektedir.


Şekil 11. İleri Geri Besleme Sinir Ağı Modeli (10- 2)

Kaynak: Görsel MATLAB programı ile çıkarılmıştır


Tablo 2’de eğitim, doğrulama ve test değerleri için hesaplanan performans ölçütleri gösterilmektedir. Gizli katmandaki nöron sayısı ise, eğitim ve doğrulama kümeleri için en iyi sonucu verecek şekilde deneme yanılma yöntemiyle belirlenmiştir. Analiz sonucunda MSE ve RMSE performans ölçütü ileri beslemeli sinir ağıının 10-2 ağı yapısıdır.

Tablo 2. YSA Performans Sonuçları

	İleri Beslemeli Sinir Ağı		Elman Sinir Ağı		NARX Sinir Ağı	
Nöron	10	12	10	12	10	12
Katman	2	2	2	2	2	2
MSE	0.0011	0.0025	0.0023	0.0036	0.0245	0.0187
RMSE	0.0331	0.0500	0.0479	0.0600	0.1565	0.1367

Şekil 12. YSA Performans Sonuçlarının Görseli

Şekil 13. Hata Histogramı



Kaynak: Görsel MATLAB programı ile çıkarılmıştır

Hata histogramı, ileriye dönük bir sinir ağını eğittikten sonra hedef değerler ile öngörülen değerler arasındaki hataların görselleştirilmesidir. Kutular, şekildeki hata histogramında bulunan dikey çubukların sayısını temsil eder. Görselde YSA'nın toplam hatası -0.3264 (en soldaki kutu) ile 0.6188 (en sağdaki kutu) arasında değişmektedir. Her dikey çubuk, seçilen veri kümesinden belirli bir kutuda bulunan örnek sayısını işaret etmektedir. Hata histogramının ortası, doğrulama veri kümesinin -0.02796 ile 0.02179 arasında hatası olduğunu göstermektedir.

Sonuç

Yapay zekâ tekniklerinin gelişimi ve teknolojik ilerlemeler yeni araştırma alanlarının ortaya çıkmasına yol açarken makinelerin giderek daha fazla güç ve beceri kazanmasını sağlamıştır. YSA, güçlü öğrenme ve problem çözme kapasitesi sayesinde farklı sektörlerde çeşitli sorunların çözümünde ve analizinde kullanılan yeni bir teknik olmuştur.

Yapay zekâ teknolojisiyle insanlar tarafından gerçekleştirilen birçok düşünme görevi, günümüzde insan benzeri düşünme yetenekleriyle güçlendirilen modern makineler tarafından da gerçekleştirilebilmektedir. Dolayısıyla, yapay zekâ geliştirmeye yönelik modern yaklaşımın temel hedefleri, modern bilimlerin ve keşiflerin gücünün, geleneksel yaşamda insan tarafından gerçekleştirilen tüm süreçleri ve faaliyetleri kontrol edebilen bir makine beyni inşa etmek için etkili bir şekilde kullanılmasına dayanmaktadır.

Bilişim teknolojisinin ilerlemesiyle birlikte, makine öğreniminin konut sektöründe, özellikle de konut satış analizi için uygulanması giderek daha önemli hale gelmiştir. Makine öğrenimi, yapay zekâ sistemlerinin verilerden öğrenmesini sağlayan bir özellik olarak görülebilmektedir.

Ekonomide, konut satış verilerini etkileyen bir dizi faktör vardır. Çalışmada Ocak 2013 ile Aralık 2023 yılları arasındaki illere göre konut satış miktarı, sanayi üretim endeksi, tüketici güven endeksi, inşaat güven endeksi, ekonomik güven endeksi ve döviz kuru verileri kullanılmıştır. MATLAB ortamında normalizasyon uygulanıp en hızlı öğrenme fonksiyonu olan Levenberg-Marquardt algoritmasıyla sinir ağı modelleri oluşturulmuştur. Türkiye İstatistik Kurumu (TÜİK), Türkiye Cumhuriyet Merkez Bankası (TCMB) verilerinden faydalanılmıştır. İleri besleme sinir ağı, elman sinir ağı ve NARX sinir ağı yöntemi ile illere göre konut satışı analiz edilerek en iyi mimariyi belirlemek bu makalenin ana amacı olarak benimsenmiştir. Ayrıca analizde kullanılan ileri beslemeli sinir ağı, elman sinir ağı ve NARX sinir ağlarından hangisinin en iyi sonucu verdiği, bu modellerin öngörü performanslarının hangisinin en az hata oranına sahip olduğunu tespit edilmesi çalışmanın bir başka amacıdır. Sinir ağı modellerinin performans ölçütleri için Ortalama Hata Kareleri- Mean-Square Error (MSE) ve Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error-RMSE) kullanılmıştır. Araştırma bulguları, MSE 0.0011 ve RMSE 0.0331 değerleri performans ölçütü, ileri beslemeli sinir ağının 10-2 ağı sahip modelin YSA içinde en iyi performansı ürettiğini göstermektedir. Ayrıca bu

modelin eğitim setiyle ilgili R değeri 1'e çok yakındır, bu da çok iyi bir uyum olduğunu göstermektedir. Test setinin R değeri ise 0,81 olarak elde edilmiştir. Bu değer sinir ağındaki uyumun iyi olduğu sonucuna ulaştırmaktadır.

Yapılan modellemede konut satışlarının analiz edilmesi sürecinde YSA yaklaşımı, diğer analiz yöntemleri ile kullanılabilir. Modeldeki performans kriterleri artırabilir böylece daha fazla kriter karşılaştırılıp değerlendirilebilir. Diğer yandan gelecekteki araştırmalarda daha farklı sayı ve türde değişkenler kullanılarak illere ve yıllara göre konut satış sayılarının analiz çalışmaları yapılabilir.

Kaynakça

- Abidoye, R. B., ve Chan, A. P. (2017). Artificial neural network in property valuation: Application Framework and Research. *Property Management*, 5(35), 554-571.
- Ahmad, M. W., Mourshed, M. ve Rezugui, Y. (2017). Trees vs neurons: comparison between random forest and ann for high-resolution prediction of building energy consumption. *Energy and Buildings* (147), 77-69.
- Ahmed, S. F., Alam, M. S., Hassan, M., Rozbu, R. M., Ishtiaq, T., Rafa, N., vd. (2023). Deep Learning Modelling Techniques: Current Progress, Applications, Advantages, and Challenges. *Artificial Intelligence Review* (56), 13521–13617.
- Bai, H., ve Chen, X. (2023). House price forecasting in ames based on bayesian regularized BP neural network. *Automation and Machine Learning*, 4(1), 17-23.
- Capital, F. (2024, 06 19). <https://fastercapital.com/topics/understanding-the-housing-industry-and-its-impact-on-the-economy.html>
- Chan, Z. S., Ngan, H. W., ve Rad, A. B. (2003). Improving bayesian regularization of ANN via pre-training with early-stopping. *Neural Processing Letters*, 1(18), 29-34.
- Çavuşlu, M. A., Becerikli, Y., ve Karakuzu, C. (2012). Levenberg – Marquardt algoritması ile YSA eğitiminin donanımsal gerçekleştirilmesi. *TBV Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5, 31-38.
- Elshamy, M. M., Tiraturyan, A. N., Uglova, E. V., ve Elgendy, M. Z. (2021). Comparison of Feed-Forward, Cascade-Forward, and Elman algorithms models for determination of the elastic modulus of pavement layers. (s. 46-53). ICGDA.
- Erdoğan, M. H. (1990). Türkiye'de konut sektörünün ekonomik analizi (1979-1988) (Yüksek lisans tezi). Anadolu Üniversitesi Sosyal Bilimler Enstitüsü.
- Ersöz, S., Yaman, N., ve Birgören, B. (2008). Müşteri ilişkileri yönteminde verilerin yapay sinir ağları ile modellenmesi ve analizi. *Gazi Üniv. Müh. Mim. Fak. Dergisi*, 23(4), 759-767.
- Ghorbani, S. ve Afzheh, S. M. (2017). Forecasting the house price for ahvaz city: the comparison of. *Urban Economics and Management*, 3(5), 29-45.
- Gogas, P. ve Papadimitriou, T. (2021). Machine learning in economics and finance. *Computational Economics* (57), 1-4.
- Gurney, K. (1997). *An Introduction To Neural Networks*. UCL Press.
- Hodson, T. O. (2022). Root mean square error (RMSE) or Mean absolute error (MAE): When to use them or not. *Geoscientific Model Development*, 14(15), 5481-5487. <https://doi.org/10.5194/gmd-15-5481-2022>
- Ibtissem, C. ve Nouredine, L. (2013). A Hybrid method based on conjugate gradient trained neural network and differential evolution for non linear systems identification. *ICEESA*. Hammamet, Tunisia.
- Lee, H., Han, H., Pettit, C., Gao, Q., ve Shi, V. (2024). Machine learning approach to residential valuation: a convolutional neural network model for geographic variation. *The Annals of Regional Science* (72), 579-599.
- Nazemi, B. ve Rafiean, M. (2022). Modelling the affecting factors of housing price using gmdh-type artificial neural networks in Isfahan city of Iran. *International Journal of Housing Markets and Analysis*, 15(1), 4-18.
- Nazemi, B. ve Rafiean, M. (2022). Modelling the affecting factors of housing price using GMDH-type artificial neural networks in Isfahan city of Iran. *International Journal of Housing Markets and Analysis*, 15(1), 4-18.

- Obaido, G., Mienye, I. D., Oluwaseun, E. F., Emmanuel, D. I., Ogunleye, A., Ogbuokiri, B. vd. (2024). Supervised machine learning in drug discovery and development: algorithms, applications, challenges, and prospects. *Machine Learning with Applications* (17).
- Oshodi, O. S., Thwala, W. D., Odubiyi, T. B., Abidoye, R. B., ve Aigbavboa, C. O. (2019). Using neural network model to estimate the rental price of residential properties. *Journal of Financial Management of Property and Construction*, 2(12).
- Park, B., ve Bae, J. K. (2015). Using machine learning algorithms for housing price prediction: the case of fairfax county, virginia housing data. *Expert Systems with Applications*, 6(42), 2928-2934.
- Rampini, L. ve Cecconi, F. (2021). Artificial intelligence algorithms to predict Italian real estate market prices. *Journal of Property Investment & Finance*, 6(40), 588-611.
- Sa'at, N. F., Maimun, N. H. ve Idris, N. H. (2021). Enhancing the accuracy of Malaysian house price forecasting: a comparative analysis on the forecasting performance between the hedonic price model and artificial neural network model. *Planning Malaysia Journal*, 3(19), 249-259.
- Sathiavelu, S. K. ve Mouleswaran, S. (2024). Investigation of machine faults using elman neural network and decision tree. *ICAMDMS*. EAI.
- Soltani, A. ve Lee, L. C. (2024). The non-linear dynamics of south australian regional housing markets: A Machine Learning Approach. *Applied Geography* (166).
- Song, Z., Sun, F., Zhang, R., Du, Y., ve Li, C. (2021). Prediction of road network traffic state using the NARX neural network. *Advanced Transportation*, 774-786.
- Tekouabou, S. C., Gherghina, Ş. C., Kameni, E. D., Filali, Y. ve Gartoumi, K. I. (2023). AI-based on machine learning methods for urban real estate prediction: A systematic survey. *Archives of Computational Methods in Engineering* (31), 1079-1095.
- Winky, K. O., Tang, B.-S. ve Wong, S. W. (2020). Predicting property prices with machine learning algorithms. *Journal of Property Research*, 1, 48-70.
- Xu, X., ve Zhang, Y. (2024). Office property price index forecasting using neural networks. *Journal of Financial Management of Property and Construction*, 29(1), 52-82.
- Yu, H., ve Wilamowski, B. M. (2011). Levenberg–Marquardt training. Auburn University: https://www.eng.auburn.edu/~wilambm/pap/2011/K10149_C012.pdf

Beyan ve Açıklamalar

Etik Beyan: Bu çalışmanın hazırlanma sürecinde bilimsel ve etik ilkelere uyulduğu ve yararlanılan tüm çalışmaların kaynakçada belirtildiği beyan olunur (Şeyma Nur Ünal). Araştırma ikincil verilere sahip bir çalışma olduğu için etik beyana gerek yoktur.

Yazar Katkısı: Kavram/fikir, veri toplama/işleme, analiz, yazım ve eleştirel inceleme ve düzenleme Şeyma Nur Ünal (katkı oranı %100) tarafından yapılmıştır. Yazar makalenin yayınlanan versiyonunu okumuş ve kabul etmiştir.

Finansman: Bu çalışma herhangi bir fon desteği almamıştır.

Çıkar Çatışması: Çıkar çatışması bulunmamaktadır.

İntihal: Bu makale, en az iki hakem tarafından incelendi ve intihal içermediği teyit edildi.

Lisans: CC BY-NC 4.0

