
KONUT FİYAT TAHMİNİNDE YAPAY SİNİR AĞLARI YÖNTEMİNİN KULLANILMASI

Özgür YILMAZEL¹

Aslı AFŞAR²

Sibel YILMAZEL³

Öz

Teknolojinin gelişmesiyle konut fiyat tahmini için kullanılan yöntemlere yapay sinir ağları yöntemi de eklenmiştir. Bu çalışmada Eskişehir ilinde satılık konut fiyatlarının tahmininde yapay sinir ağlarının kullanılması araştırılmıştır. Konutların büyüklüğü, oda sayısı, birinci katta bulunup bulunmadığı, konutun bulunduğu binadaki toplam kat sayısı, merkezi ısıtmalı olup olmadığı, banyo sayısı, asansörün, otoparkın, ankastre mutfağın ve fiber internet bağlantısının bulunup bulunmadığı gibi farklı fiziksel özellikleri, bulunduğu mahalle ve tramvaya uzaklığı parametreleri ile yapay sinir ağları modelleri kurulmuştur. Geliştirilen yapay sinir ağları modellerinde gizli katman nöron sayıları farklılaştırılarak 19 adet model elde edilmiş ve bu modellerin performanslarının karşılaştırması yapılarak en uygun gizli katman nöron sayısı belirlenmiştir. Sonuç olarak yapay sinir ağlarının konut fiyatının tahmin edilmesinde etkili bir araç olduğu gösterilmiştir.

Anahtar Kelimeler: Konut Fiyat Tahmini, Yapay Sinir Ağları, YSA, Eskişehir’de Konut Piyasası
JEL Sınıflandırması: C45, R21

USING ARTIFICIAL NEURAL NETWORK METHOD TO PREDICT HOUSING PRICES

Abstract

With improvements in technology artificial neural network has been added among the methods for house price prediction. This study explores the usage of artificial neural network method to predict the housing prices in the city of Eskişehir. The physical characteristics of housing such as the size of the apartment, number of the rooms, if the apartment is located on the first floor or not, the number of the floors of the building, whether it has central heating, number of the bathrooms, whether there is an elevator, and parking lot of the building, if there is built-in kitchen cabinets, availability of fiber internet connection in the building, the neighborhood of the apartment and the distance to the nearest tram stop are used within the neural network model. Different numbers of neurons are tried out within the generated neural network. The results are compared and in conclusion it was shown that artificial neural network is an effective method to predict the housing prices.

Keywords: Housing Price Prediction, Artificial Neural Network, ANN, Housing Market in Eskişehir
JEL Classification: C45, R21

¹Doç. Dr., Anadolu Üniversitesi, Eskişehir Meslek Yüksekokulu, ozgur@anadolu.edu.tr, ORCID: 0000-0002-1892-2316

²Doç. Dr., Anadolu Üniversitesi, Eskişehir Meslek Yüksekokulu, aafsar@anadolu.edu.tr, ORCID: 0000-0001-7031-1419

³Öğr. Gör., Anadolu Üniversitesi, Eskişehir Meslek Yüksekokulu, syilmazel@anadolu.edu.tr, ORCID: 0000-0003-0708-0202

1. Giriş

Konut, barınmanın yanısıra dayanıklı bir tüketim malı ve bir yatırım aracı olması, ekonomik olarak gelecekte güven hissi vermesi gibi faktörlere bağlı olarak ekonomik bir nitelik taşımaktadır. Konutun, hem mal hem de yatırım aracı olması dolayısıyla konut piyasası diğer piyasalara göre bazı farklılıklar göstermektedir. Bu farklılıklar, konut arzının çok maliyetli olması, konutun devamlı ve sürekli olması, heterojen olması, sabit olması, ikincil piyasalarda büyümeye neden olması ve teminat olarak kullanılması şeklinde sıralanabilir (Lacoviello, 2000: 8).

Konut piyasası ekonomide önemli bir ağırlık oluştururken aynı zamanda tüketici harcamaları ve toplam refahın da önemli bir göstergesidir. Konut ve barınma için yapılan harcamalar hane halkının giderlerinin önemli bir kısmını oluşturmaktadır (Bekmez, Özpolat, 2013: 171). Konut fiyatlarındaki seyir ve fiyatlamının doğru olup olmaması yalnız konut sektörü için değil tüm ekonomi için önemli bir gösterge özelliği taşımaktadır. Konut sektörü, gerek alt sektörleri harekete geçirmesi gerekse istihdam, barınma gibi yanları ile bir değer taşımaktadır. Dolayısıyla konut fiyatları ile inşaat sektöründeki fiyat hareketleri ve ekonomik gerçekleştirmeler toplumun büyük bir kısmını ya doğrudan ya da dolaylı olarak etkilemektedir. Hem konut alanlar ve satanlar hem de konuta yatırım yapmak isteyenler için konut fiyatının gerçekçi tahmin edilmesi oldukça önemlidir (Bin, 2004: 70).

Gayrimenkul özellikle de konut fiyat tahmini oldukça karmaşık ve çok sayıda parametrenin dikkate alınmasını gerektiren bir çabadır. Teknolojinin gelişmesiyle kullanılan tahmin yöntemlerine yapay sinir ağları (YSA) yöntemi de eklenmiştir. Yapay sinir ağları metoduyla doğru bir tahmin yapabilmek için sözkonusu parametreleri gözden geçirmek ve kullanılan verileri özenle sayısallaştırmak gerekmektedir. Gerekli parametreleri içeren verilere ulaşmak ve kullanılan parametreleri doğru şekilde tasarlamak yapay sinir ağları ile yüksek oranda tutarlı sonuçta ulaşmak için önemlidir.

Yapay sinir ağları son yıllarda finansal konulardan mühendisliğe, tıp alanından sanayi uygulamalarına kadar geniş bir alanda, gerçek hayatta karşılaşılan problemlere sıklıkla uyarlanmaktadır. Geniş bir uygulama sahasına sahip olan yapay sinir ağlarının en güçlü özelliği, verilerden yararlanarak bu veriler arasındaki ilişkileri öğrenebilme yeteneğidir. Bu nedenle, yapay sinir ağları kendilerinin dizayn edilmesinde kullanılan girdi verilerine bağımlıdır (Hagan, Demuth & Beale, 1996: 6). Yapay Sinir Ağları'nın ekonomi ve finans alanında kullanıldığı yerlerin başında tahmin etme yani geleceği öngörme gelmektedir. Bu problemlere örnek olarak; hisse senetlerinin performansının ölçülmesi ve seçimi, döviz kurlarının yönünün belirlenmesi, bir şirketin iflas edip etmeyeceğinin tahmin edilmesi, finansal krizlerin öngörülmesi, hileli (manipülatif) işlemlerin tespit edilmesi, menkul kıymet alım-satımı ve tahminler yapılması ile gelecekteki fiyatların tahmin edilmesi, endeks tahmini, gayrimenkul fiyat tahmini, kredi danışmanlığı, kurumsal tahvil değerlendirilmesi, kredi kartı kullanım analizi, kurumsal finansal analiz, finansal sıkıntı teşhisi ve portföy optimizasyonu gibi konular sayılabilir (Akel, Bayramoğlu, 2008: 24).

Yapay sinir ağlarının en büyük avantajı geleneksel teknolojiler için çok karmaşık olan, veri setinin doğrusal olmadığı, eksik veya çok boyutlu olduğu problemleri çözebilmeleridir. Bu tür veri setlerine sahip problemlerin matematiksel modelinin tahmin edilmesi ve geleceğe yönelik tahminlerinin yapılabilmesi, eğilimin keşfedilmesi gibi çözümler sunması nedeniyle yapay sinir ağları tercih edilmektedir. Örneğin, bir yapay sinir ağı öğrendiği girdi/çıktı verileri ile veri setindeki eksik bilgileri tamamlayabilir. Benzer şekilde yapay sinir ağı, veriler üzerinde sınıflandırma yapabilir veya girdi değerlerine karşılık gelebilecek çıktı değerini tahmin edebilir. Karmaşık ve kesin olmayan veriden anlam çıkarma gücü sayesinde yapay sinir ağları insan tarafından fark edilmesi güç eğilimleri bulmak ve verideki desenleri çıkarmak için tercih edilmektedir. Eğitilmiş sinir ağı, analizini yaptığı konuda uzman olarak nitelenebilir. Böylece bu sinir ağı ilgili alanda gelecek için projeksiyonlar yapma ve 'farzedelim ki' sorularına yanıt vermek için kullanılabilir.

Bu makalede nicel tahmin yöntemlerinden yapay sinir ağları ile 2017 yılının Ocak, Şubat ve Mart aylarında Eskişehir merkez ilçelerinde satışı bulunan konutların (apartman dairelerinin) fiyatlarının

tahmin çalışması gerçekleştirilmiştir. Konutların büyüklüğü, oda sayısı, birinci katta bulunup bulunmadığı, konutun bulunduğu binadaki toplam kat sayısı, merkezi ısıtılı olup olmadığı, banyo sayısı, asansörün, otoparkın, ankastre mutfağın ve fiber internet bağlantısının bulunup bulunmadığı gibi farklı fiziksel özellikleri, bulunduğu mahalle ve tramvaya uzaklığı parametreleri ile yapay sinir ağları modelleri kurulmuştur. Yapay sinir ağlarında örneklem sayısının yüksek olması tahminin doğruluğunu artırmaktadır. 5556 adet örneklem büyüklüğü ile bu çalışma literatürde Türkiye’de il bazında fiyat tahmini konusunda yapılmış araştırmalar arasında en büyük örnekleme sahiptir. Çalışma kapsamında kurulan modellerdeki gizli katman nöron sayıları farklılaştırılarak 19 adet model kurulmuş ve bu modellerin performanslarının karşılaştırması yapılarak en uygun gizli katman nöron sayısı belirlenmiştir.

2. Literatür Özeti

Finans literatüründe bağımlı ve bağımsız değişkenler arasındaki doğrusal olmayan örüntü ve ilişkiler, doğrusal modelleme araçları tarafından modellenememektedir. Ancak yapay sinir ağı teknolojisi kuvvetli bir doğrusal olmayan modelleme aracıdır (Yıldız, 2009: 108). Parametrik modellerle çalışırken eğer verilerin içinde uç değerler varsa korelasyon katsayısı grup ortalaması gibi parametreler bundan önemli ölçüde etkilenmektedir. Oysa yapay sinir ağı bu tür uç değerlere karşı dayanıklıdır ve bu tür durumlardan etkilenmeden modelleme yapabilir.

Coakley ve Brown’a (2000) göre, sınıflandırma problemlerinde veri setindeki grup sayısı ve değişken sayısı arttıkça yapay sinir ağı parametrik modellere göre daha iyi performans sergilemeye başlar. Ayrıca örneklem büyüklüğünün değişmesine ve grupların örneklem içinde temsil oranının değişmesine karşı daha dayanıklıdır. Çalışmalarında araştırmacıların verileri üç gruba bölmelerini önermektedirler. Bunlar eğitim, test ve geçerliliklerdir.

Yapay sinir ağları geleneksel istatistiksel yöntemlerden farklı olarak, verinin özellikleri ile ilgili istatistiksel varsayımlar yapmaz, algoritma veya matematiksel model geliştirmeye gerek duymaz. Verideki ilişki kalıplarını ve eğilimleri tanıyarak öğrenir. YSA'nın ağırlıkları ve öğrenme hızını uyarlayabilmesi ona esneklik kazandırır ve gerçek dünyadaki değişikliklere tepki verebilmesi kolaylaşır. Diğer taraftan, YSA'nın optimal ağı topolojisini belirleyen bir yöntem yoktur, deneme-yanılma ve deneyim gereklidir. YSA, genel sonuçları ve her girdi değişkeninin sonuca katkısını açıklamakta güçlü değildir.

Konut fiyatlarının tahmin edilmesinde YSA, 1990'lı yılların başından beri kullanılmaktadır. Borst (1991) tarafından yapılan ilk çalışmayı diğer çalışmalar takip etmiştir. Do ve Grudnitski (1992), 105 konuttan oluşan bir test örneğini kullandıklarında, bir yapay sinir ağı modelinin, konut fiyatını tahmin etmek için çoklu regresyon modelinden daha iyi performans gösterdiğini belirtmişlerdir. Yazarlar kanıt olarak ortalama yüzde 6.9 ve yüzde 11.3'lük mutlak hataları belirtmişlerdir.

Worzala, Lenk ve Siva (1995) çalışmalarında Colorado eyaletinde konut fiyatını yapay sinir ağları ile analiz etmişlerdir. Kullandıkları parametreler; bina yaşı, oda sayısı, banyo sayısı, toplam alan, garaj, şömine, arsa alanı ve bölgedir. 270 adet veri seti ile %82 doğruluk oranına ulaşmışlardır (Worzala, Lenk & Silva, 1995).

Rossini (1997) çalışmasında konut satış fiyatlarını çoklu regresyon analizi ve yapay sinir ağları ile analiz etmiştir. Satışı yapılan evlerde kullanılan parametreler; satış zamanı, satış fiyatı, mahalle, iyileştirme, arsa alanı, bölge, oda sayısı, eşdeğer inşaat alanı, durum, duvar tipi, çatı tipi, bina tipi ve bina inşaat tarihidir. 334 veri setinin 223 adeti eğitim için, 111 adeti test için kullanılmıştır. Sonuç olarak çoklu regresyon analizi %90 ortalama uyum ve %89 doğruluk oranına ulaşırken, yapay sinir ağları %78 ortalama uyum ve %81 doğruluk oranında kalmıştır.

Cechin, Antonio ve Gonzales (2000) Brezilya'nın Porto Alegre kentinde satılık ve kiralık bina verilerini doğrusal regresyon ve yapay sinir ağları yöntemleri ile analiz etmişlerdir. Kullandıkları parametreler; konutun büyüklüğü, semt, coğrafi konum, çevre düzeni, oda sayısı, bina inşaat tarihi ve toplam kullanım alanıdır. Çalışmanın sonunda yapay sinir ağları yönteminin doğrusal regresyona

göre daha kullanışlı olduğunu belirtmişlerdir. Yapay sinir ağı yöntemi ile ortalama 11 Amerikan doları, doğrusal regresyonda ise ortalama 33 Amerikan doları hata ile sonuca ulaşmışlardır. Kiralama sonuçlarının analizi, satış sonuçlarının analizine göre daha başarılı olmuştur.

Esperanza ve Gallego (2004) Madrid'de 12 parametre kullanarak konut fiyatlarını analiz etmişlerdir. Kullandıkları parametreler, şehir merkezine uzaklık, yol, ilçe büyüklüğü, inşaat sınıfı, bina yaşı, tadilat durumu, konut alanı, teras alanı, ilçe içinde konum, konut dizaynı, bulunduğu kat ve müstemilatın olup olmamasıdır. Veri seti bölgede satılık durumda olan 100 konutun satış değerlerinin gerçek değer olduğu varsayımıyla oluşturulmuştur. Sonuçlar regresyon analizine göre daha başarılı olmuştur, %95 ortalama uyum ve %86 doğruluk oranına ulaşmıştır.

Limsombunchai, Gan ve Lee (2004) Yeni Zelanda'nın Christchurch şehrinde konut fiyatlarının tahmininde yapay sinir ağı yöntemini kullanmışlardır. Kullandıkları parametreler; konut alanı, bina yaşı, bina tipi, oda sayısı, banyo sayısı, garaj sayısı, sosyal tesisler ve coğrafi konumdur. Sonuçta %84 doğruluk oranına ulaşmışlardır.

Nghiep, Nguyen ve Crips Al (2001) konut değerlerinin tahmini için çoklu regresyon analizi ile yapay sinir ağı yöntemlerini kullanmışlardır. Kullandıkları parametreler; satış fiyatı, daire alanı, oda sayısı, banyo sayısı ve binanın yaşıdır. Yaptıkları analizler sonucunda, doğru verilerin seçilmesi halinde yapay sinir ağı yönteminin daha başarılı olduğu, aksi takdirde sonuçların çeşitlilik kazanmakta olduğunu belirtmişlerdir .

Özkan, Yalpır ve Uygunol (2007) Konya'nın Selçuklu ilçesinde konut fiyat tahmini için yapay sinir ağı ve regresyon yöntemlerini kullanmışlardır. Kullandıkları parametreler; konut büyüklüğü, bina yaşı, dairenin bulunduğu kat, cephe, TAKS (Taban alanı katsayısı), KAKS (Kat alanı katsayısı) ve bölgedir. 170 adet veri seti kullanılarak regresyon metodu ile %83, yapay sinir ağı ile %84,5 doğruluk oranı elde edilmiştir.

Khalafallah (2008) çalışmasında yapay sinir ağı yöntemi ile gayrimenkul satışlarını analiz etmiştir. Kullandığı parametreler; zaman, faiz oranı, satışların yıllara göre değişimi, bir önceki yıla göre satış birim değerinin değişimi, ortalama satış süresi ve işlem hacmidir. Sonuçta yapay sinir ağı yöntemiyle satışların değerine %2 tolerans oranla ulaşmıştır.

Selim (2009) çalışmasında konut fiyatlarının tahmininde hedonik regresyon ve yapay sinir ağı yöntemlerini kullanmıştır. Veri setini Türkiye için 2004 Hane Halkı Bütçe Anketi verileri oluşturmaktadır. Tahmin örneklemesinin (5741) büyüklüğü, konut özelliklerinin kapsamlı bir modellenmesine olanak sağlamıştır. Kullandığı değişkenler; konumsal özellikler, konut tipi, binanın yaşı, binanın tipi, salon ve oturma odaları zeminleri, banyo zeminleri, ısıtma sistemi, oda sayısı, konut büyüklüğü (metrekare) ve diğer yapısal özelliklerdir. Verilerin özelliklerinden dolayı, çevresel faktörler göz önüne alınmamıştır. Sonuç olarak Türkiye'de konut fiyatlarının tahmini için hedonik regresyon ile karşılaştırıldığında yapay sinir ağlarının daha iyi bir alternatif olabileceği belirtilmiştir.

Demirbilek ve Selim (2009) Türkiye'de konut kira değerini analiz etmek için hedonik ve yapay sinir ağı yaklaşımlarını kullanmışlardır. Bu çalışmada ele alınan veri seti Türkiye İstatistik Kurumunun (TÜİK) gerçekleştirmiş olduğu 2004 yılı Hanehalkı bütçe anketidir. Genel kira modeli için hem fiili hem de izafi kira verileri birleştirilmiş ve toplam 7514 hane ile çalışmışlardır. Modellerde kullandıkları değişkenler, konutun kentsel veya kırsal kesimde bulunup bulunmadığı, konut tipi, binanın yaşı, odaların ve banyonun zemin döşeme tipi, ısıtma sistemi, oda sayısı, konutun büyüklüğü, konutun diğer yapısal özellikleri ve hanehalkına ait olan özelliklerdir. Kullanılan veri setinde konuta ait çevresel özellikler yer almadığından modellerde çevresel değişkenler kullanılmamıştır. Konutların kira değerlerinin tahminlenmesinde yapay sinir ağlarının hedonik yöntemine göre etkin ve daha iyi alternatif bir yöntem olduğu belirlenmiştir.

Zurada, Levitan ve Guan (2011) konut değerlendirme analizinde bulanık mantık ve yapay sinir ağı yöntemlerini kullanmışlardır. Kullandıkları parametreler; banyo sayısı, konut alanı, garaj büyüklüğü, ısıtma sistemi, şömine, inşaat tipi ve garaj tipidir. Sonuç olarak bulanık mantık ve yapay sinir ağı

yeterli veri ve doğru analiz yapılması şartı ile kullanılabilir metotlar olup, üzerinde çalışılması gerektiği ifade edilmiştir.

Mimis, Rovolis ve Stamou (2013) çalışmalarında Atina örneğinde konut fiyat tahmini için YSA kullanmışlardır. Modelin çıkardığı bağımsız değişkenler aracılığıyla modelin coğrafi bilgi sistemleri ortamıyla bağlantısı yapılmış ve sonuçlar görselleştirilmiştir. Konut veri tabanı Atina'nın büyük bölgesindeki 3150 daireyi içermektedir. Bu veriler 2000-2006 dönemini kapsamaktadır. Bağımsız değişkenler olarak konum, yaş, yer boşluğu, toplu taşımaya olan mesafe, alanın sosyal durumu iken konutun fiyatı bağımlı değişken olarak kullanılmıştır. Modeller uygun hale geldikten sonra, verideki değişkenliğin %87'si YSA modeli ve % 76'sı CBS modeli ile açıklanmıştır. Bütün ölçümlerde YSA daha iyi performans göstermiş ve 16,625 Euro'luk bir mutlak ortalama hata göstermiştir.

Ecer (2014) çalışmasında Türkiye'de konut fiyatlarını tahmin etmek için hedonik regresyon yöntemi ile yapay sinir ağlarını karşılaştırmıştır. Bu çalışmada, İzmir'in Karşıyaka ilçesinde 2013 yılı Ocak-Temmuz ayları arasında satılmış olan 610 konutun verileri kullanılarak konut fiyatı tahminlemesi yapılmıştır. Veri setinde kullanılan değişkenler, konutların sahip olduğu 83 özelliiktir. Yapay sinir ağları modelinde konut fiyatını etkileyen değişkenler, yüzme havuzu, konutun deniz kenarında olması, şehir merkezine yakın olması, hırsız alarmının olması, gömme dolaba sahip olması, yaşı, tren istasyonuna yakınlığı, bulunduğu sitede güvenliğinin olması, deniz otobüsüne yakınlığı, cami, üniversite ve sağlık ocağına yakınlığı, cadde üzerinde olması, ankastre mutfaka, ses yalıtımına ve ısıcama sahip olması, kablo TV, hidrofor ve çelik kapının olması ve terastır. İki modelin tahmin doğrulukları karşılaştırıldığında yapay sinir ağları modelinin hedonik modelden daha iyi tahmin yaptığı sonucuna ulaşılmıştır.

Abraham (2016) Yeni Zelanda'da konut fiyat tahmini için yapay sinir ağları yöntemi kullanmıştır. Yazar 2000-2015 arası konut fiyat değişimini ölçmek için Yeni Zelanda konut fiyat endeksini kullanmıştır. Çalışmada hem konut talebini hem de konut arzını etkileyen değişkenler; kısa vadeli faiz oranları, enflasyon oranı, işsizlik oranı, konut kredisi onayları, konut satışları, ev stokunun toplam değeri, konut yatırımları (GSYİH), yapı ruhsatlarının sayısı (konut) ve toplam nüfusun demografik değerleri ve kalıcı uzun vadeli göçmenlerdir. Sonuçta, YSA ile Yeni Zelanda piyasasında konut fiyatlarının belirleyicilerinin daha iyi tahmin edilebildiği ifade edilmiştir.

Abidoye ve Chan (2017) yapay sinir ağı yöntemiyle Nijerya'da konut fiyat tahmini yapmışlardır. Yazarlar ülkede konut istatistikleri düzgün tutulmadığı için altı yılda Lagos şehrinde emlakçılardan elde ettikleri 370 veri ve 11 bağımsız değişken kullanmışlardır. Kullanılan bağımsız değişkenler; yatak odası sayısı, tuvalet sayısı, banyo sayısı, bina türü, çocuk odası sayısı, park yeri sayısı, binanın yaşı, kat sayısı, güvenlik olup olmaması, deniz manzarasının olup olmaması, konutun konumudur. Sonuçta YSA tekniklerinin benimsenmesinin, konut fiyat tahmini değerlemesinin yanlışlığını azaltabileceğini belirtmişlerdir.

Konut fiyatını tahmin etmeye yönelik yapılan ve YSA modellerinin kullanıldığı çalışmaların büyük çoğunluğu YSA modellerinin konut fiyatlarını tahmin etmede iyi performans sergilediğini göstermektedir.

3. Yapay Sinir Ağları Yaklaşımı


Yapay sinir ağları insan beyninin çalışma tekniğinden esinlenerek oluşturulmuş bir yapay zeka bilimi araştırma alanı olarak karşımıza çıkmaktadır. Yapay sinir ağlarında öğrenme işlemi gerçekleşmiş girdi ve çıktı verilerinin kullanılmasıyla bağlantı ağırlıklarının (weight of synopsis) yakınsamasının sağlanmasına kadar ayarlanmasıyla gerçekleşir. Bir sinir ağı deneysel bilgileri depolamaya yönelik doğal eğilimi olan ve bunların kullanılmasını sağlayan büyük ölçekli paralel dağıtık işlemcilerdir. Yapay sinir ağlarında:

1. Bilgi, ağ tarafından bir öğrenme süreciyle elde edilir.

2. Elde edilen bilgileri depolamak için sinaptik ağırlıklar olarak da bilinen nöronlar arası bağlantı kuvvetleri kullanılır. (Haykin, 2004: 246)

Yapay sinir ağlarının temel birimi işlem elemanı ya da nöron olarak adlandırılan yapay sinirdir. Şekil 1 de görüldüğü gibi girişler X sembolü ile gösterilmektedir. Bu girişlerin her biri ağırlık W ile çarpıldıktan sonra eşik değeri Q ile toplanır ve sonucu oluşturmak için etkinlik işlevi ile işlem yapılarak $f(x)$ çıktısı bulunur. Bir yapay sinir ağının öğrenme başarısı model içerisindeki ağırlıkların uygun şekilde ayarlanmasına bağlıdır (Elmas, 2003: 28).


Şekil 1: Yapay Sinir Ağlarında Bir Nöron Yapısı



Kaynak: Elmas, 2003:28

En basit hali ile bir yapay sinir ağı sadece girdi ve çıktı katmanlarından oluşuyorsa tek katmanlı yapıdadır. Karmaşık işlemleri hesaplama yeteneğinden yoksun olan tek katmanlı ağların bu işlemi yapabilmeleri için en az bir ara katmanları olmalıdır (Elmas, 2003: 43-46). Buna göre en temel yapay sinir ağının yapısında girdi katmanı, bir gizli katman ve çıktı katmanı olmak üzere toplam 3 katman ve her bir katmanda nöron olarak adlandırılan bir veya daha fazla sayıda yapay sinir hücresi bulunmaktadır. Şekil 2'de gösterilen çok katmanlı YSA mimarisinde 2 girişli 3 katmanlı bir sinir ağı gösterilmiştir.

Şekil 2: Çok Katmanlı Yapay Sinir Ağı Mimarisi



Kaynak: Elmas, 2003:28

Yapay sinir ağlarında öğrenme, verilen örneklere karşılık beklenen çıktının doğru hesaplanabilmesi için her bir bağlantıdaki ağırlıkların hesaplanması ile gerçekleşir. Öğrenme algoritması aslında verdiğimiz ağı sinaptik bağlarının ağırlıklarını hesaplamadan sorumludur. Yapay sinir ağları literatüründe birçok sinir ağından bahsedilse de fiyat gibi sürekli değişkenlerin tahmininde ileri beslemeli ağlar yaygın olarak kullanılmaktadır. İleri beslemeli ağlarda bilgi giriş katmanından ara katmanlara ve çıkış katmanına doğru akar. Öğrenme algoritması her bir iterasyonda bulunması gereken değerler ile oluşan çıktıyı karşılaştırıp ağırlıkları düzenler. Bunun için kullanılan en yaygın

yöntem de geri yayılım (backpropagation) algoritmasıdır. Geri yayılım algoritması öğrenme setinde bulunan örnek çıktılar ile örnek girdilere karşılık gelen değerleri kullanarak bir kayıp fonksiyonunu (Loss function) minimize etmek için her bir nörondaki ağırlık değerini değiştirerek çalışır. Bu sayede eğitim seti için kaybın minimum olduğu ağırlık değerleri YSA modelini oluşturur. Geri yayılım algoritmasının detayları ve teorisi hakkında detaylı bilgi Hecht-Nielsen tarafından yazılmış olan "Theory of the backpropagation neural network" makalesinde bulunabilir (Hecht-Nielsen, 1988:593-594). Bu çalışmada 3 katmanlı ileri beslemeli yapay sinir ağı yapısı kullanılmış ve geri yayılım algoritması kullanılarak eğitilmiştir.

4. Araştırmanın Yöntemi

4.1. Veri Seti

Çalışmanın veri kümesini 2017 yılının Ocak, Şubat ve Mart aylarında Eskişehir ilinin merkez ilçeleri için internette satış ilanı bulunan konutlara ait özellikler ve fiyat bilgileri oluşturmaktadır. 5556 adet veri mahallelere göre gruplanarak %70 oranında öğrenme ve %20 oranında test ve %10 doğrulama seti için üç kısma ayrılmıştır.

Eskişehir'deki konut fiyatlarını etkileyen faktörlerin hedonik model ile belirlenmesi konusunda yapılan çalışmada konutun büyüklüğü, oda sayısı, banyo sayısı, otopark, ebeveyn banyosu, ankastre mutfak, asansör, gibi özelliklerin konut fiyat üzerinde pozitif yönde etkisinin olduğu belirlenmiştir (Afşar, Yılmazel, Yılmazel, 2017:203). Bu çalışmadaki parametrelere tramvay duraklarına olan uzaklık da dahil edilmiş ve konut fiyatını tahmin etmek üzere geliştirilen yapay sinir ağı modelinde aşağıdaki parametreler kullanılmıştır:

- Oda sayısı
- Banyo sayısı
- Apartman dairesinin büyüklüğü (metrekare)
- Apartman dairesinin bulunduğu binadaki toplam kat sayısı
- Apartman dairesinin birinci katta bulunup bulunmadığı (birinci katta ise=1, değilse=0)
- Asansör bulunup bulunmadığı (var ise 1, yok ise=0)
- Otoparkın bulunup bulunmadığı (var ise 1, yok ise 0)
- Ankastre mutfak bulunup bulunmadığı (var ise 1, yok ise=0)
- Merkezi ısıtma bulunup bulunmadığı (var ise 1, yok ise=0)
- Ebeveyn banyosunun bulunup bulunmadığı (var ise 1, yok ise=0)
- Fiber Internetin bulunup bulunmadığı (var ise 1, yok ise=0)
- En yakın tramvay durağına uzaklık (metre)
- Bulunduğu mahalle: 71 Evler, Akarbaşı, Alanönü, Arifiye, Aşağı Söğütönü, Bahçelievler, Batıkent, Büyükdere, Çamlıca, Çankaya, Deliklitaş, Emek, Ertuğrulgazi, Esentepe, Eskibağlar, Fatih, Gökmeydan, Göztepe, Güllük, Gültepe, HacıSeyit, İhlamurkent, İstiklal, Kırmızıtoprak, Kumlubel, Kurtuluş, Orhangazi, Osmangazi, Ömerağa, Sümer, Sütlüce, Şarhöyük, Şeker, Şirintepe, Tunalı, Uluönder, Vadişehir, Vişnelik, Yenibağlar, Yıldıztepe

Modelde kullanılan eğitim veri seti değişkenlerine ait tanımlayıcı istatistik bilgileri Tablo 1 ve Tablo 2'de verilmiştir.

Tablo 1: Nümerik Değişkenler için İstatistik Özet

Değişken	Minimum	Maksimum	Ortalama
oda_sayısı	1	6	2.51
kat_sayısı	1	13	3.73

banyo_sayısı	1	4	1.26
tramway_uzaklık	0.0047	4.3658	0.6145
metrekare (ln)	3.4	5.88	4.7
fiyat (ln)	10.915	13.458	12.138

Tablo 2: Kategorik Değişkenler için İstatistikî Özet

Değişken	Var	Yok
merkezi_ısıtma	237	3667
birinci_kat	1181	2723
asansör	1740	2164
otopark	935	2969
ankastre_mutfak	1034	2870
ebeveyn_banyo	628	3276
fiberİnternet	464	3440

Veri setindeki apartman dairesi büyüklüğünü gösteren “metrekare” değişkeni ve apartman fiyatını gösteren “fiyat” değişkeni için doğal logaritmik dönüşüm fonksiyonu uygulanmıştır. Veri setinde bulunan değerlerin içinde fiyat ve metrekare bilgilerinin ölçeği yüzler ve yüzbinler mertebesinde olduğu için ve bu rakamların konut grupları arasında büyük farklılık göstermesinden dolayı, öğrenme algoritmasına tek başlarına hakim olmalarını önlemek için makine öğrenmesinde sık kullanılan yumuşatma metodlarından biri olan logaritmik dönüşüm kullanılmıştır.

4.2. Yöntem ve Araç

Bu çalışmada Waikoto Üniversitesi tarafından geliştirilmiş ve günümüzde makine öğrenme algoritmaları için yaygın olarak tercih edilen WEKA 3.8.0 programı kullanılmıştır. WEKA Java dilinde geliştirilmiş ve açık kaynak kodlu olarak sürülmüş olup sınıflandırma (classification), kümeleme (clustering) ve ilişkilendirme (association) veri madenciliği işlemlerinin yapılabildiği bir araçtır. WEKA, İngilizce “Attribute Relationship File Format” kelimelerinin baş harflerinden oluşan ve WEKA için özel olarak geliştirilmiş ARFF dosya yapısını kullanmaktadır (Frank, Hall, Witten, 2016:57). Bu yapıda dosyanın ilk satırında ilişki tipi (relation), ikinci satırdan itibaren ise veri kümesindeki özellikleri (attributes) bulunmaktadır. Özelliklerden sonra ise veri kümesi ve her kümesindeki her satır bir örneği gösterecek şekilde liste yer almaktadır. Veri kümesindeki özellikler virgül karakteri ile ayrılmaktadır. Söz konusu ARFF formatına uygun olacak şekilde modele girdi oluşturan dosya şu şekilde hazırlanmıştır:

```
@RELATION evfiyatları
@attribute oda_sayısı {1,2,3,4,5,6}
@attribute birinci_kat {1,0}
@attribute kat_sayısı NUMERIC
```


@attribute merkezi_ısıtma {1,0}

@attribute banyo_sayısı {1,2,3,4}

@attribute asansör {1,0}

@attribute otopark {1,0}

@attribute ankastremutfak {1,0}

@attribute ebeveynbanyo {1,0}

@attribute fiberInternet {1,0}

@attribute tramvay_uzaklık NUMERIC

@attribute mahalle

{71Evler, Akarbasi, Alanonu, Arifiye, AsagiSogutonu, Bahcelievler, Batikent, Buyukdere, Camlica, Cankaya, Deliklitas, Emek, Ertugrulgazi, Esentepe, Eskibaglar, Fatih, Gokmeydan, Goztepe, Gulluk, Gultepe, HaciSeyit, Ihlamurkent, Istiklal, Kirmizitoprak, Kumlubel, Kurtulus, Orhangazi, Osmangazi, Omeraga, Sumer, Sutluce, Sarhoyuk, Seker, Sirintep,Tunali, Uluonder, Vadisehir, VisnelikYenibaglar, Yildiztepe}

@attribute metre_kare NUMERIC

@attribute fiyat NUMERIC

Tasarlanan 3 katmanlı ileri beslemeli yapay sinir ağı geri yayılım algoritması kullanılarak eğitilmiştir. Transfer fonksiyonu olarak, tahmin edilmeye çalışılan değerın pozitif nümerik bir değer olmasından dolayı, 0 ile 1 arasında değişen Sigmoid fonksiyonu kullanılmıştır. Öğrenme ve momentum katsayısı için 0.1 değeri alınmıştır. Eğitim süreci 500 iterasyon kullanılarak gerçekleştirilmiştir. Tek gizli katmanlı yapay sinir ağı modelinde en uygun gizli katman nöron sayısının belirlenebilmesi için nöron sayılarının 2'den 20'ye kadar değiştirilmesiyle 19 adet model geliştirilmiştir.

4.3. Model Performans Kriterleri

Çalışmada oluşturulan modellerin performanslarının kıyaslanmasında literatürde de sıklıkla tercih edilen Ortalama Karesel Hata Karekökü (RMSE) Ortalama Mutlak Hata (Mean Absolute Error-MAE) ve korelasyon katsayısı (R) göstergeleri kullanılmıştır (Limsombunchai, 2004:7). Ortalama Karesel Hata Karekökü (RMSE) ölçüm değerleri ile bir model tarafından tahmin edilen değerler arasındaki hata oranını belirlemek amacıyla kullanılan bir göstergedir. Bu nedenle RMSE değerinin sıfıra yaklaşması modelin tahmin gücünün arttığını göstermektedir. RMSE şu formülle hesaplanmaktadır:

$$RMSE = \frac{\sqrt{\sum_{i=1}^n (y_{model,i} - y_{gözlenen,i})^2}}{\sqrt{n}} \quad (1)$$

Formülde $y_{model,i}$ model tahminini $y_{göz,i}$ ölçüm değerlerini temsil etmektedir. n ise gözlem sayısıdır. Ortalama Mutlak Hata (MAE) ölçüm değerleri ile model tarafından tahmin edilen değerlerin arasındaki mutlak hatayı göstermek için kullanılmaktadır. RMSE değerine benzer şekilde MAE değerinin de sıfıra yaklaşması modelin tahmin gücünün arttığını göstermektedir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{gözlenen,i} - y_{model,i}| \quad (2)$$

Korelasyon katsayısı (R) ölçüm değerleri ile modelin tahmin ettiği değerler arasında doğrusal bir ilişkinin bulunup bulunmadığını göstermektedir. R değerinin 1'e yaklaşması model tahminleri ile ölçüm değerleri arasındaki doğrusal ilişkinin güçlü olduğunu göstermektedir. Korelasyon katsayısı R hesaplaması için aşağıdaki formül kullanılmaktadır:

$$R = \left[\frac{n \sum_{i=1}^n y_{gözlenneni} y_{model,i} - (\sum_{i=1}^n y_{gözlenneni}) (\sum_{i=1}^n y_{model,i})}{\sqrt{[n \sum_{i=1}^n y_{gözlenneni}^2 - (\sum_{i=1}^n y_{gözlenneni})^2] \times [n \sum_{i=1}^n y_{model,i}^2 - (\sum_{i=1}^n y_{model,i})^2]}} \right] \quad (3)$$

6. Bulgular

Bu çalışmada Eskişehir ilinde satılık ilanı bulunan konutların fiyatlarını tahmin etmek amacıyla geliştirilen yapay sinir ağları modellerinde öğrenme algoritması olarak geri yayılım algoritması, gizli katman ve çıktı katmanında aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. Tek gizli katmanlı YSA modelinde probleme en uygun gizli katmandaki nöron sayısını belirlemek için gizli katmandaki nöron sayıları 2'den 20'ye kadar ardışık olarak değiştirilmiş ve kurulan her bir modelin tahmin değerlerinin ölçülen değerlerle RMSE, MAE ve korelasyon katsayısı performans ölçütü kullanılarak karşılaştırılması yoluyla gizli katmandaki en uygun nöron sayısı 5 (Model 4) olarak belirlenmiştir. Gizli katmandaki en uygun nöron sayılarına ait performans değerleri Tablo 3'te özet olarak gösterilmektedir.

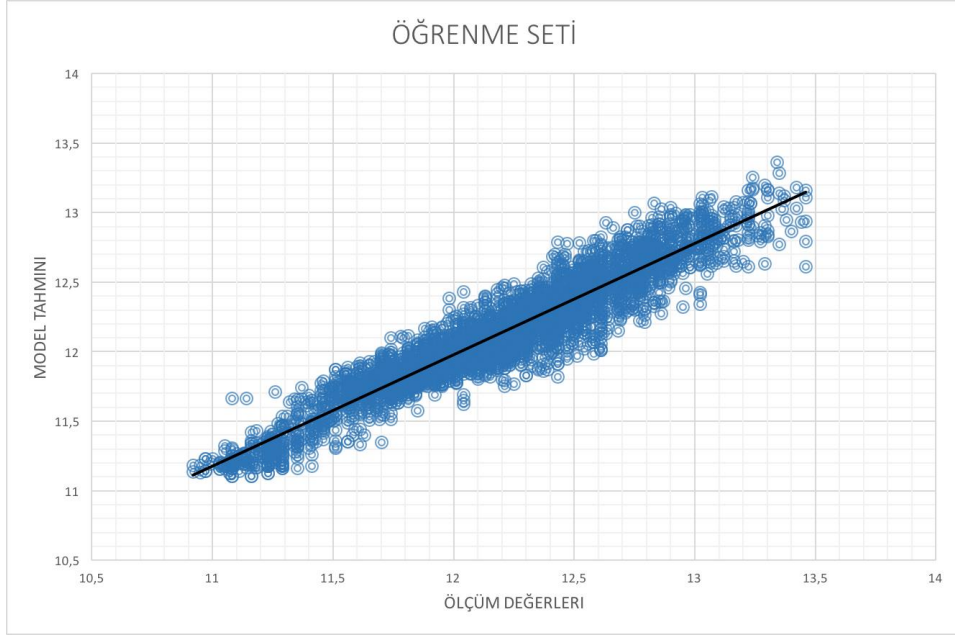
Tablo 3: Farklı Nöron Sayılı Modellerin Tahmin Değerlerinin Performans Göstergeleri

Model	Nöron Sayısı	Korelasyon Katsayısı (R)	RMSE	MAE
Model 1	2	0,9106	0,1944	0,1899
Model 2	3	0,9109	0,1935	0,1789
Model 3	4	0,911	0,1927	0,1698
Model 4	5	0,9219	0,192	0,1441
Model 5	6	0,9152	0,2011	0,146
Model 6	7	0,9146	0,2048	0,1472
Model 7	8	0,9089	0,2087	0,1555
Model 8	9	0,9101	0,2071	0,1546
Model 9	10	0,9108	0,2051	0,1505
Model 10	11	0,9109	0,205	0,1512
Model 11	12	0,9112	0,2048	0,1518
Model 12	13	0,9115	0,2032	0,151
Model 13	14	0,9116	0,2034	0,153
Model 14	15	0,9117	0,2036	0,1534
Model 15	16	0,9098	0,2045	0,1536
Model 16	17	0,9089	0,2049	0,1594
Model 17	18	0,9073	0,2055	0,1602
Model 18	19	0,9075	0,212	0,162
Model 19	20	0,9085	0,215	0,1623

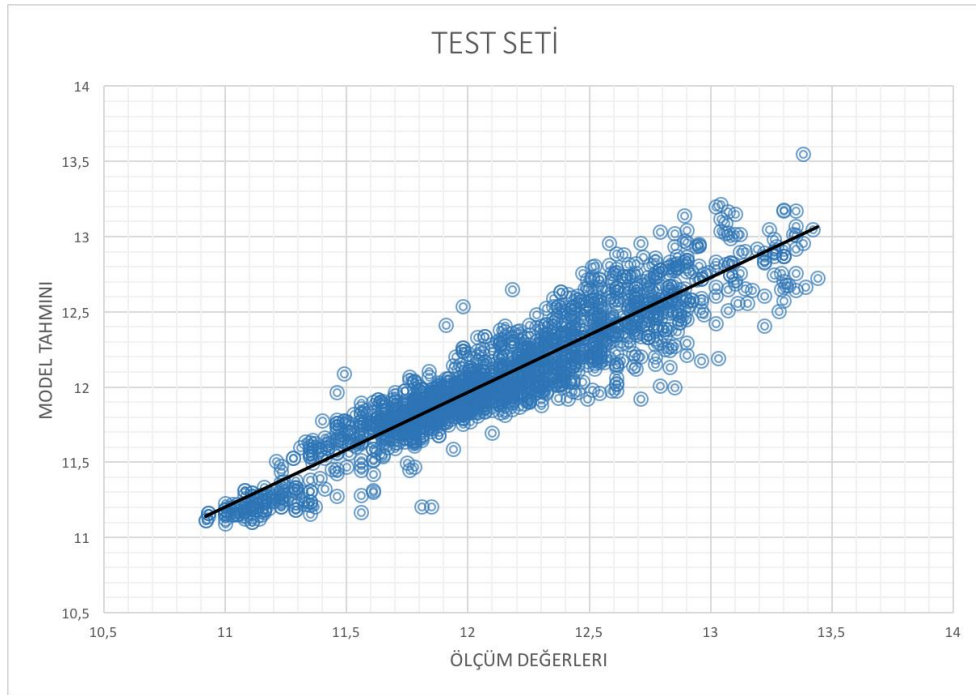
Buna göre test veri seti üzerinde en düşük RMSE ve MAE ile en yüksek korelasyon katsayısı değerini sağlayan 5 adet nörondan oluşan yapay sinir ağları modeli girdi ve çıktı değişkenleri arasındaki ilişkiyi en iyi şekilde tanımlamakta ve çıktı değişkenini en yüksek doğrulukla tahmin etmektedir. Gerçekleştirdiğimiz 5 adet nörondan oluşan yapay sinir ağı doğrulama seti ile değerlendirildiğinde R=0,9207, RMSE=0,1938, MAE=0,1490 değerlerine ulaşılmıştır.

Ayrıca model sonuçları ve ölçüm değerleri arasında bir kıyaslama yapabilmek amacıyla öğrenme veri seti ve test veri seti üzerinde serpilme diyagramları çizdirilmiştir. Şekil 3 ve Şekil 4'te öğrenme seti ve test setinde ölçüm değerleri ile yapay sinir ağları modelinin tahmin ettiği değerlerinin serpilme diyagramları gösterilmektedir. Test veri setinde ölçüm değerleri ile modelin tahmin ettiği değerlerin birbiri ile doğrusal ilişkide olduğu görülmektedir.

Şekil 3: Test Seti Üzerinde Ölçüm Değişimleri (log) ve Model Tahmini Değerleri (log) Serpilme Diyagramı



Şekil 4: Öğrenme Seti Üzerinde Ölçüm Değerleri (log) ve Model Tahmini Değerleri (log) Serpilme Diyagramı



5. Sonuç

Bilimsel temellere dayanan yöntemlerle konut sektöründe güvenilir ve doğru tahmin çalışmalarının yapılması sektördeki paydaşların karar almalarını destekleyecek bir nitelik olarak ortaya çıkmaktadır. Yapılan bu çalışma yapay sinir ağları tekniklerinin konut fiyatlarının tahmininde bir araç olarak kullanılabilirliğini göstermiştir. Yapay sinir ağlarından geri yayılım algoritmasını temel alan yapay sinir ağı modeli kullanılmıştır. Eskişehir'deki konut fiyatlarında etkili olan faktörler yapay sinir ağları modeline girdi teşkil etmek üzere belirlenmiştir. Konut fiyatlarında etkili

olabilecek değişkenlerden konutların büyüklüğü, oda sayısı, birinci katta bulunup bulunmadığı, konutun bulunduğu binadaki toplam kat sayısı, merkezi ısıtılı olup olmadığı, banyo sayısı, asansörün, otoparkın, ankastre mutfak ve fiber internet bağlantısının bulunup bulunmadığı gibi farklı fiziksel özellikleri, bulunduğu mahalle ve tramvaya uzaklığı parametreleri girdi olarak kullanılmıştır. Çalışmada amaç farklı gizli katman nöron sayıları ile denenen modeller arasında en yüksek korelasyon katsayısı ve en düşük Ortalama Karesel Hata Karekökü (RMSE) ve Ortalama Mutlak Hata (MAE) değerlerini veren konfigürasyonu belirlemektir. Tek gizli katmanlı YSA modelinde probleme en uygun gizli katmandaki nöron sayısını belirlemek için gizli katmandaki nöron sayıları 2'den 20'ye kadar ardışık olarak değiştirilmiş ve kurulan her bir modelin tahmin değerlerinin ölçülen değerlerle RMSE, MAE ve korelasyon katsayısı performans ölçütü kullanılarak karşılaştırılması yoluyla gizli katmandaki en uygun işlem elemanı sayısı 5 olarak belirlenmiştir. Buna göre gizli katman nöron sayısının 5 olduğu modelin 0.9219 korelasyon değeri ve RMSE 0.1920 ve MAE 0.1441 değerleri ile 19 adet model içerisinde en az hataya sahip ve doğruluk oranı en yüksek model olduğu görülmektedir.

Bu çalışma ile literatürde ilk defa Eskişehir ilindeki konut fiyatlarında etkili olan parametrelerin yapay sinir ağları ile incelenmesi gerçekleştirilmiştir. Konutların özellikleri ve fiyatları arasındaki ilişkinin yapay sinir ağları ile incelendiği bu çalışmanın Eskişehir ilindeki konut fiyat tahmini ve Eskişehir özelinden Türkiye genelinde konut fiyatları tahmini çalışmalarına katkısı olacağına inanılmaktadır. Yapay sinir ağlarında örneklem sayısının yüksek olması tahminin doğruluğunu arttırmaktadır. 5556 adet örneklem büyüklüğü ile bu çalışma literatürde Türkiye'de il bazında fiyat tahmini konusunda yapılmış araştırmalar arasında en büyük örnekleme sahiptir.

İleriye yönelik yapılacak çalışmalarda farklı modellerde yapay sinir ağları kullanılarak ve modellere girdi teşkil edecek değişkenler çeşitlendirilerek Türkiye genelinde konut fiyatları tahminlerinin yapılması önerilebilir. Ülkemizde konut sektöründe yapay sinir ağları ile yapılacak tahminleme çalışmalarının gerek sektöre gerekse disiplinler arası çalışmalara önemli katkılar sağlayacağı öngörülmektedir.

Kaynakça

- Abidoeye, R. B. and Chan, A. P. C. 2017. Modeling Property Values in Nigeria Using Artificial Neural Network. *Journal of Property Research*. 1-18.
- Abraham, M. 2016. *Determinants of Residential Property Value in New Zealand: A Neural Network Approach*, Department of Applied Business, New Zealand Government Institute of Technology (Whitireia). Auckland. 1-24.
- Afşar, A., Yilmazel, Ö., & Yilmazel, S. (2017). Konut Fiyatlarını Etkileyen Faktörlerin Hedonik Model İle Belirlenmesi: Eskişehir Örneği. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (37), 195.
- Akel, V. ve Bayramoğlu, M. F. 2008. *Kriz Dönemlerinde Yapay Sinir Ağları İle Finansal Öngörüle Bulunma: İMKB 100 Endeksi Örneği*. In International Symposium on International Capital Flows and Emerging Markets. 24-28.
- Akgül, I. 2003. *Zaman Serilerinin Analizi ve ARIMA Modelleri*. Der Yayınları. İstanbul.
- Bekmez, S. ve Özpolat, A. 2013. Türkiye'de Konut Talebinin Belirleyenleri: Dinamik Bir Analiz. *TİSK Akademi*, 2013/II, 170-187.
- Bin, O., 2004. A Prediction Comparison of Housing Sales Prices by Parametric versus Semi-Parametric Regressions, *Journal of Housing Economics*, 13, s..68-84.
- Borst, R.A. 1991. Artificial Neural Networks: The Next Modelling/Calibration Technology For The Assessment Community. *Artificial Neural Networks*, 69-94.

- Cechin, A., Antonio, S. and Gonzales, M. A. 2000. *Real Estate Value at Porto Alegre City Using Artificial Neural Networks*. Neural Networks, Proceedings, Sixth Brazilian Symposium on IEEE, November 2000. 237-242.
- Coakley, J. R. and Brown, C. 2000. Artificial Neural Networks in Accounting and Finance: Modelling Issues, International Journal of Intelligent Systems in Accounting. *Finance and Management*. 9 (2), 119-144.
- Do, A. Q. and Grudnitski, G. 1992. A neural network approach to residential property appraisal. *The Real Estate Appraiser*. 58 (3). 38-45.
- Ecer, F. 2014. Türkiye'deki Konut Fiyatlarının Tahmininde Hedonik Regresyon Yöntemi ile Yapay Sinir Ağlarının Karşılaştırılması. International Conference On Eurasian Economies. 1-10.
- Eibe, F., Mark, A., Hall, and Ian H. Witten (2016). The WEKA Workbench. *Online Appendix for Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann, Fourth Edition.
- Elmas, Ç. 2003. *Yapay Sinir Ağları*, Birinci Baskı, Ankara: Seçkin Yayıncılık.
- Esperanzo, M. and Gallego, J. 2004. Artificial Intelligence Applied to Real Estate Valuation an Example for the Appraisal of Madrid. *Catastro*. April 2004. 255-265.
- Hagan, M. T., Demuth, H. B. and Beale, M. H. 1996. *Neural Network Design*. PWS Pub. Co.. Boston. 6.
- Haykin, S. and Network, N. 2004. A Comprehensive Foundation. *Neural Networks*. New York: MacMillan College Publishing Company. 246-262.
- Hecht-Nielsen, R. (1988). Theory of the Backpropagation Neural Network. *Neural Networks*, 1(Supplement-1), 445-448.
- Iacoviello, M. (2000). House Prices and The Macroeconomy in Europe: Results from a Structural VAR Analysis. *European Central Bank. Working Paper No:18*
- Limsombunchai, V. (2004, June). House price prediction: hedonic price model vs. artificial neural network. In *New Zealand Agricultural and Resource Economics Society Conference* (pp. 25-26).
- Limsombunchai, V., Gan, C. and Lee, M. 2004. House Price Predicting Using Artificial Neural Networks: A Comparative Study with Hedonic Price Model. *American Journal of Applied Sciences*. 1 (3). 193-201.
- Khalafallah, A. 2008. Neural Networks Based Model for Predicting Housing Market Performance. *Tsinghua Science & Technology*. 13, 325-328.
- Mimis, A., Rovolis, A. and Stamou, M. 2013. Property Valuation with Artificial Neural Network: The Case of Athens. *Journal of Property Research*. 30 (2). 128-143.
- Nghiep, N. and Cripps, A. 2001. Predicting Housing Value: A Comparison of Multiple Regression Analysis and Artificial Neural Networks. *Journal of Real Estate Research*. 22(3). 313-336.
- Özkan, G., Yalçın, Ş. ve Uygunol, O. 2007. An Investigation on the Price Estimation of Residable Real Estates by Using ANN and Regression Methods. *The 12th Applied Stochastic Models and Data Analysis International Conference (ASMDA)*. Chania, Crete, Greece.
- Rossini, P. A. 1997. Artificial Neural Networks Versus Multiple Regression in the Valuation of Residential Property. *Australian Land Economics Review*. 3 (1). 1-12.
- Selim, H. 2009. Determinants of House Prices in Turkey: Hedonic Regression Versus Artificial Neural Network. *Expert Systems with Applications*. 36 (2). 2843-2852.

- Selim, S. ve Demirbilek, A. 2009. Türkiye’de Konutların Kira Değerinin Analizi: Hedonik Model ve Yapay Sinir Ağları Yaklaşımı. *Aksaray Üniversitesi İİBF Dergisi*. Ocak 2009, 1 (1). 73-90.
- Worzala, E., Lenk, M. and Silva, A. 1995. An Exploration of Neural Networks and Its Application to Real Estate Valuation. *Journal of Real Estate Research*. 10 (2). 185-201.
- Yıldız, B. 2009. *Finansal Analizde Yapay Zeka*, Detay Yayıncılık, Ankara, 10.
- Zurada, J. M., Levitan, A. S., and Guan, J. 2011. Non-Conventional Approaches to Property Value Assessment. *Journal of Applied Business Research*, 22 (3). 1-14.

USING ARTIFICIAL NEURAL NETWORK METHOD TO PREDICT HOUSING PRICES

Extended Abstract

Aim: An accurate assessment of the value of a real estate is important for all roles in this market. Neural network models have been developed and widely used across different disciplines such as engineering, economics and health. Inspired by how the brain works neural network models are well suited to problems with classification, feature detection and pattern recognition in nature. This study aims to predict the residential housing prices in Eskişehir, Turkey by using artificial neural network method. This paper first constructs a neural network model with backpropagation and sigmoid function. The learning rate and the momentum rate values were used as 0.1. The number of epochs to training through was used as 500. One hidden layer was used within the model. Since this research investigated the benefits of applying neural network method to the problem of real estate appraisal 19 different neural network models with different number of nodes along with the configuration parameters given above were developed. Three criteria were used to compare the performance of these different models: R Correlation Coefficient, RMSE (Root Mean Squared Error) and Mean Absolute Error (MAE). For this study, online real estate listings data was gathered for the period of January, February and March of 2017.

Method(s): The primary focus of this research is to compare the predictive performance of neural network models in the context of residential real estate market appraisal. 19 different neural network models were developed by varying the number of nodes in the hidden layer. The WEKA tool was used to construct the neural network models.

Three criteria were used to compare the performance of these different models: R Correlation Coefficient, RMSE (Root Mean Squared Error) and Mean Absolute Error (MAE). The best model for predicting the actual house sale prices was determined by having the highest R and the lowest root mean squared error and the lowest mean absolute error.

The sales data for 5556 apartments which were listed on the web for sale in Eskişehir, Turkey between January and March of 2017 were used in this study. The data was divided into 70% for training, 20% for testing and 10% for validation.

The independent variables for the model included the following characteristics for the apartments: The size of the apartment, number of the rooms, if the apartment is located on the first floor or not, the number of the floors of the building, whether it has central heating, number of the bathrooms, whether there is an elevator, and parking lot of the building, if there is built-in kitchen cabinets, availability of fiber internet connection in the building, the neighborhood of the apartment (71Evler, Akarbasi, Alanonu, Arifiye, AsagiSogutonu, Bahcelievler, Batikent, Buyukdere, Camlica, Cankaya, Deliklitas, Emek, Ertugrulgazi, Esentepe, Eskibaglar, Fatih, Gokmeydan, Goztepe, Gulluk, Gultepe, HaciSeyit, Ihlamurkent, Istiklal, Kirmizitoprak, Kumlubele, Kurtulus, Orhangazi,

Osmangazi, Omeraga, Sumer, Sutluce, Sarhoyuk, Seker, Sirintepe, Tunalı, Uluönder, Vadişehir, Vişnelik, Yenibağlar, Yıldıztepe) and the distance to the nearest tram stop.

Findings: The model's accuracy in predicting house price was measured by a number of criteria. Specifically three criteria were used to compare the performance of these different models: R Correlation Coefficient, RMSE (Root Mean Squared Error) and Mean Absolute Error (MAE). The best model for predicting the actual house sale prices was determined by having the highest R and the lowest root mean squared error and the lowest mean absolute error. As a result the neural network model with backpropagation classifier and sigmoid function along with the learning rate and the momentum rate of 0.1 and the number of epochs to training of 500, and with one hidden layer and five nodes on the hidden layer performed the highest R (0,9219) and the lowest root mean squared error (0,1920) and the lowest mean absolute error (0,1441).

Conclusion: This research investigated the benefits of applying neural network method to the problem of real estate appraisal. The research compared the performance of 19 different neural network models with different number of nodes. The results indicated that the neural network model with 5 nodes in the hidden layer performed the highest correlation coefficient along with the lowest root mean squared error and the lowest mean absolute error. Continued research in this area is needed with larger dataset covering Turkey and possibly with more features that might have effect on the housing prices such as the current market conditions.

