



MANİSA KENTSEL SU TÜKETİMİNİN ÖNTAHMİNİ*

FORECASTING URBAN WATER CONSUMPTION OF MANISA PROVINCE

 Kadir KARAGÖZ¹  Gökhan ÖZKUBAT²

¹ Sorumlu Yazar: Doç. Dr., Manisa Celal Bayar Üniversitesi, İİBF, Ekonometri Bölümü, kadir.karagoz@cbu.edu.tr

² Arş. Gör. Manisa Celal Bayar Üniversitesi, İİBF, Ekonometri Bölümü, gokhan.ozkubat@cbu.edu.tr

Received / Alınma: 27.02.2024

Accepted / Kabul: 24.03.2024

ÖZET

Dünyadaki tatlı su kaynakları içme suyu, tarımsal sulama ve enerji için yoğun bir şekilde kullanılmakta, ancak artan kentleşme, değişen iklim koşulları ve yanlış yönetim nedeniyle su kaynakları giderek azalmaktadır. Özellikle küresel iklim değişimleri karşısında geçmiş yıllarda ülkemizde de görüldüğü gibi, kentlerdeki su talebinin karşılanmasında güç durumlarla karşı karşıya kalmaktadır. Dolayısıyla su talebinin belirlenmesi, dönemsel tahminlerinin yapılması ve bu tahminler sonucunda ayrıntılı planlamaların yapılması, kentlerdeki su hizmeti sunan kuruluşlar ve bu hizmetten yararlanan tüm çevreler için hayati derecede önemli bir konudur.

Kentsel su ihtiyacını neredeyse tümüyle sondaj kuyularından sağlayan ve zaman içinde nüfusu hızla artan Manisa'da mevcut su kaynaklarının etkin bir şekilde yönetilmesi ve talebin sorunsuz bir şekilde karşılanması için güvenilir öntahminlere ihtiyaç vardır. Bu çalışmada, çeşitli ekonometrik tekniklerden yararlanarak Manisa'da kentsel su tüketiminin öntahmini yapılmış, alternatif yöntemlerin performansları karşılaştırılmıştır.

Anahtar Kelimeler: Kentsel Su Talebi, Öntahmin, Yapay Sinir Ağı Analizi, ARIMA Modeli, Manisa.

ABSTRACT

World freshwater resources are used intensively for drinking water, agricultural irrigation and energy, but water resources are gradually decreasing due to increasing urbanization, changing climatic conditions and mismanagement. Especially in the face of global climate change it is faced with difficult situations in meeting the water demand in the cities, as seen in our country in the past years. Therefore, determining water demand, making periodic forecasts and preparing detailed plans as a result of these forecasts is vital for the organizations that provide water services in cities and all the beneficiaries who benefit from this service.

To manage the available water resources effectively and meet the demands without problems reliable forecasts are needed in Manisa which provides urban water needs almost entirely from drilling wells and which is rapidly increasing in population over time. In this study, urban water consumption in Manisa was estimated by using various econometric techniques and the performances of alternative methods were compared.

Keywords: Urban Water Consumption, Forecasting, Artificial Neural Network Analysis, ARIMA Models, Exponential Smoothing, Manisa.

* Bu araştırma, Manisa Celal Bayar Üniversitesi Rektörlüğü Bilimsel Araştırma Projeleri Birimi tarafından BAP 2017-056 no'lu proje ile desteklenmiştir.

1. GİRİŞ

Dünyadaki tatlı su kaynakları içme suyu, tarımsal sulama ve enerji için yoğun bir şekilde kullanılmakta, ancak artan kentleşme, değişen iklim koşulları ve yanlış yönetim nedeniyle su kaynakları giderek azalmaktadır. Özellikle küresel iklim değişikliği karşısında geçmiş yıllarda ülkemizde de görüldüğü gibi, kentlerdeki su talebinin karşılanmasında güç durumlarla karşı karşıya kalınmaktadır. Dolayısıyla su talebinin belirlenmesi, dönemsel tahminlerinin yapılması ve bu tahminler sonucunda ayrıntılı planların hazırlanması, kentlerdeki su hizmeti sunan kuruluşlar ve bu hizmetten yararlanan tüm çevreler için hayati derecede önemli bir konudur.

Su talep tahmini, su tüketimiyle ilgili gelişmelerin planlanması veya sistemin genişletilmesi, depoların büyüklüğü ve işletilmesi, pompa istasyonları ve boru kapasitelerinin hesaplanması ve kentsel su yönetimi (fiyatlandırma politikası, su kullanımının sınırlandırılması) gibi birçok alanda kullanılmaktadır. Su talep tahmini literatürde genellikle kısa ve uzun dönemli olarak sınıflandırılmaktadır. Kısa dönemli tahminler mevcut su temin sistemlerinin yönetimi ve işletilmesi için, uzun dönemli tahminler ise sistem planlaması, tasarım ve kaynak yönetiminde kullanılmaktadır. Kentsel su talep tahmini yapılırken, öncelikle tahmin modelleri oluşturulmakta ve daha sonra bu model içerisinde tahmini belirleyen iklim değişikliği, ekonomik gelişim, nüfus artışı, kişi başına düşen gelir, hane halkı geliri, eğitim düzeyi, nüfus yoğunluğu, ticari ve endüstriyel faaliyetler, su fiyatlaması gibi bağımsız değişkenler belirlenmektedir.

Yapılan bu araştırmayla, Manisa ili kent merkezi içme suyu talep miktarı yapay sinir ağı, ARIMA modeli ve üstel düzleştirme yöntemiyle tahmin edilmeye çalışılmıştır. Çalışmanın planı şöyledir: Girişi izleyen bölümde Manisa ili tanıtılmakta, ilin su varlığı ve yönetimi konusunda bilgiler verilmektedir. Üçüncü bölümde su talep tahminine yönelik mevcut ampirik çalışmalardan bahsedilmektedir. Çalışmada kullanılan öntahmin yöntemlerinin teorik olarak tanıtıldığı, öntahmin sonuçlarının elde edildiği ve tartışıldığı dördüncü bölümü genel değerlendirmenin yer aldığı sonuç bölümü izlemektedir.

2. MANİSA'DA SU VARLIĞI VE KENTSEL SU YÖNETİMİ

2.1. Manisa'nın Genel Tanıtımı¹

Manisa ili, Türkiye'nin batısında, Ege Bölgesinin Ege Bölümünde yer almaktadır. İl topraklarının büyük bir bölümü Gediz Havzası içinde, küçük bir bölümü de kuzey batıda Ege (Bakır çay) Havzası içinde bulunmaktadır. Coğrafi olarak 27° 08' ve 29° 05' doğu boylamları ile 38° 04' ve 39° 58' kuzey enlemleri arasında yer alır. İlin doğusunda en uç noktası Selendi-Kürkçü köyü, batıda en uç noktası Merkez ilçede Düzlen köyü, kuzeyde en uç noktası Soma-Türkali köyü, güneyde en uç noktası Sarıgöl-Aşağıkızılcukur köyüdür. İl merkezinin yüksekliği 71 m olup, Merkezde en yüksek nokta Spil Dağı (1.513 m), ilin en yüksek noktası Salihli Bozdağlar Kumtepe (2.070 m), en yüksek ilçe merkezi de Demirci ilçesidir (850 m). İdari yönden, doğudan Uşak ve Kütahya, batıdan İzmir, kuzeyden Balıkesir, güneyden Aydın, güneydoğudan Denizli illeri ile çevrilidir. İlin yüzölçümü 13.810 km², 2016 yılı itibarıyla nüfusu 1.396.945 kişidir.

Manisa ilinin başlıca akarsuları Gediz, Bakırçay ve Kumçayı'dır. Bu kaynaklar tarımsal sulama amacıyla kullanılmaktadır. Manisa'da doğal göl bulunmamakta, çeşitli amaçlar için inşa edilmiş orta küçük çaplı göletler ve baraj gölleri bulunmaktadır. Gediz havzasında akifer alüvyon kullanılmaktadır. Bazı yerlerde kireçtaşı ve neojen birimlerinden yeraltı suyu temin edilmektedir. Gediz ve Bakırçay'ın bir kısmının yılda 474 hm³ yeraltı suyu potansiyeli

¹ Bu ve izleyen altbölümde ağırlıklı olarak Manisa Valiliği Çevre ve Şehircilik İl Müdürlüğü tarafından 2015 yılında hazırlanan rapordan (MÇŞM, 2015) yararlanılmıştır.

bulunmaktadır. Manisa'da yeraltı su seviyesi yağışa ve çekime göre farklılık göstermektedir. Örneğin; Kırkağaç Bakraz Dere 9,3 m, Muradiye Göksu 7,6 m, Saruhanlı Sarıkız 6,9 m, Saruhanlı Hacır Rahmanlı 7,2 m, Salihli Kabazlı 10 m, Alaşehir Merkez 12,5 m'dir. Manisa merkezinin içme suyu ihtiyacı kentin çeşitli yerlerinde açılmış bulunan sondaj kuyularından çekilen su ile karşılanmaktadır.

2.2. Manisa'da Kentsel Su Yönetimi

2560 sayılı kanun çerçevesinde, 6 Aralık 2012 ve 28489 sayılı Resmî Gazete'de yayınlanan 6360 sayılı Kanun hükümleri gereğince Manisa Belediyesi 30 Mart 2014 tarihinde yapılan Mahalli İdareler Seçimi'nden itibaren Büyükşehir statüsü kazanmıştır. 31 Mart 2014 tarihi itibarıyla Manisa Büyükşehir Belediyesi'ne bağlı Manisa Su ve Kanalizasyon İdaresi Genel Müdürlüğü kurulmuştur (MASKİ, 2015: 12). MASKİ yönetimi dört ana organdan oluşmaktadır: Genel Kurul, Yönetim Kurulu, Denetçiler ve Genel Müdürlük. Manisa Büyükşehir Belediyesi Meclisi aynı zamanda MASKİ Genel Kurulu olarak görevli ve yetkilidir. Genel Kurul 2560 sayılı kanunun 6. maddesinde belirtilen görevleri ifa eder. Büyükşehir Belediyesi Başkanı Yönetim Kurulu'nun başkanıdır. Yönetim Kurulu 2560 sayılı kanunun 9. maddesinde belirtilen görevleri yerine getirir (MASKİ, 2015: 16).

6360 sayılı Kanun ile büyükşehir belediye sınırları tüm il sınırlarını kapsayacak şekilde genişletilmiştir. Buna göre MASKİ, 2016 yılı sonu itibarıyla 13.810 m²'lik faaliyet alanında 17 ilçede yaşayan 1.396.945 kişiye hizmet vermektedir ve abone sayısı 567.277 dir (MASKİ, 2017: 15). 2015 yılı başında MASKİ tarafından Manisa içme suyu, atıksu arıtma tesisleri, kanalizasyon ve yağmur suyu şebekesi master planının iki yıl içerisinde yapılması kararlaştırılmış ancak kırsaldaki altyapı problemlerinin ciddi boyutlara ulaşması ve bu sorunun çevre sağlığını etkileme tehlikesi nedeniyle ilgili yerleşim yerlerinin projelendirilmesine öncelik verildiğinden 2016 sonu itibarıyla master plan çalışmalarında herhangi bir ilerleme kaydedilememiştir. Yine aynı gerekçeyle, 2015 - 2019 arasında tamamlanması planlanan acil ihtiyaca yönelik (kısa vadeli) içme suyu iletim hattı ve şebekelerine ait etüt ve proje çalışmalarında da herhangi bir gerçekleştirme sağlanamamıştır (MASKİ, 2017: 199-200).

2.3. Manisa'da Su Arz ve Talebi

Manisa'da su arz ve talebinin gelişiminde bir dengesizlik olduğu söylenebilir. Arz cephesinde, artan talebe cevap verme konusunda halihazırda bir sıkıntı yaşanmasa da gelecekte önemli zorluklarla karşılaşılması olasıdır. Bu durumu doğuran en önemli etken mevcut yeraltı kaynaklarının artan kentsel su talebini karşılamaya elverecek oranda zengin olmamasıdır. Yukarıda da belirtildiği gibi Manisa'nın içme ve kullanım suyu şehrin çeşitli yerlerinde açılmış bulunan sondaj kuyularından sağlanmaktadır. Yeraltı su kaynaklarının potansiyeli ise yağış miktarıyla doğrudan ilişkilidir. Bu durum bir yandan dönem dönem görülen kuraklığa bağlı olarak su arzında istikrarsızlık riski doğururken diğer yandan temin ve dağıtım giderlerindeki artış nedeniyle arz maliyetini yükseltmektedir.

Diğer taraftan yaşam standartlarındaki yükselmeye bağlı olarak (çim sulama, araç yıkama, süs ve yüzme havuzları vs. kaynaklı) ev-dışı kentsel su tüketiminin zaman içinde artması dönemsel olarak da olsa su arzı üzerindeki baskıyı güçlendirmektedir. Bilhassa siteler ve sanayi kuruluşları tarafından açılan özel sondaj kuyularının sayısının çoğalması mevcut yeraltı su kaynaklarını zayıflatarak kentsel su arzında sıkıntı yaşanması olasılığını artırmaktadır. Talep tarafında ise özellikle artan şehirleşme ve özellikle içgöçten kaynaklanan nüfus artışına bağlı olarak Manisa'da su tüketimi de son yıllarda hızlı bir gelişim göstermiştir.

3. KENTSEL SU TALEBİ TAHMİNİNE İLİŞKİN AMPİRİK LİTERATÜR

Konuyla ilgili literatür incelendiğinde, su talep tahmininde ilk olarak 1960'lı yıllardan itibaren regresyon analizi, 1980'li yıllardan sonra zaman serileri analizi, 1990'lı yıllardan sonra hibrid modeller ve 2000'li yıllarla birlikte yapay zekâ teknikleri ve Monte Carlo simülasyon yöntemlerinin kullanıldığı görülmektedir. House-Peters ve Chang (2011) son otuz yılda su talebi ile ilgili yapılan çalışmaları incelemişler ve 1979 yılından 2010 yılına kadar su talebi alanında yapılan çalışmaların oldukça arttığını belirlemişlerdir. Çalışmalar zamansal ve mekânsal analiz olarak ikiye ayrılmıştır. Zamansal analizde açıklayıcı değişken olarak genellikle sıcaklık, yağış, rüzgâr hızı, buharlaşma, su fiyatı, oran yapısı, nüfus artışı ve gelir değişkenlerinin kullanıldığı, mekânsal analizde ise açıklayıcı değişken olarak yaş, hanehalkı ya da aile büyüklüğü, eğitim, evin büyüklüğü, yatak odası sayısı, dış mekân büyüklüğü, havuz, bahçe, tek kişilik hanelerin oranı, ev yapısı ve koruma politikaları değişkenlerinin kullanıldığı görülmüştür. Tahmin yöntemi olarak çok değişkenli regresyon, kesitsel doğrusal regresyon, mekânsal açıklayıcı en küçük kareler regresyon, coğrafi ağırlıklandırılmış regresyon, eşanlı denklem talep modeli, ARIMA, durum uzayı tahmin modeli, Bayesyen maksimum entropi, yapay sinir ağları ve sistem dinamikleri modelleri yöntemleri kullanılmıştır. Arbués vd. (2003) de konutlarda su talebinin tahmini alanında yapılan çalışmaları incelemişlerdir. Su talebini etkileyen değişkenler su fiyatı, gelir, hava değişkenleri, konut özellikleri, faturalama sıklığı ve ücret tasarımı, iç ve dış kullanım, mevsimsel talepler ve pik yük fiyatlaması olarak sıralanmıştır. Çoğu çalışmada fiyatın talebe göre esnek olmadığı bulunmuştur. Bunun nedeni olarak suyun temel kullanımda ikamesinin olmaması ve su faturasının gelirin küçük bir kısmını oluşturması sebebiyle tüketicilerin su fiyatındaki değişimlere düşük oranda tepki vermeleri gösterilmektedir. Ayrıca su talebi tahmini için kullanılan yöntemler incelenmiştir. Genellikle en küçük kareler, araç değişkenler, panel veri ve zaman serisi ekonometrik yöntemlerinin kullanıldığı görülmüştür.

Wong vd. (2010) Hong Kong'un günlük kentsel su tüketimini tahmin etmişlerdir. Su tüketimini ifade eden istatistiksel model temel, mevsimsel ve takvimsel su kullanımından oluşmaktadır. Temel su kullanımı trend, mevsimsel su kullanımı mevsimsellik ve iklim regresyonu, takvimsel su kullanımı ise haftanın günleri, tatil günleri ve otoregresyondan oluşmaktadır. Günlük su tüketiminde hafta içi su kullanımının hafta sonuna göre daha fazla olduğu görülmüştür. Tatil günlerinde su tüketiminin azaldığı görülmüştür.

Babel vd. (2007) çok değişkenli regresyon yöntemiyle Nepal'in başkenti Kathmandu'ya ait su talebini tahmin etmişlerdir. Yıllık olarak kullanılan veriler 1988 - 2001 yıllarını kapsamaktadır. Su tüketimini etkileyen dokuz faktörün olduğu değerlendirilmiştir. Bunlar bağlantı sayısı, su fiyatı, nüfus, kişi başına GSYH, üniversite öğrencilerinin nüfusa oranı, hanehalkı sayısı, ortalama aile büyüklüğü, ortalama yıllık sıcaklık ve ortalama yağış miktarıdır. Sonuç olarak bağlantı sayısı, su fiyatı, üniversite öğrenci sayısının nüfusa oranı ve yağış miktarı değişkenlerinin su tüketimini açıklayabildiği tespit edilmiştir.

Alvisi vd. (2007) kısa vadedeki su talebi tahmini yapmaya çalışmışlardır. Bunun için Castelfranco Emilia şehrine ait kısa vadeli su talebi gözlenmiştir. Çalışmada 1998 yılına ait günlük ve saatlik veriler kullanılmıştır. Saatlik tahmin günlük modül ve saatlik modülden oluşmaktadır. Günlük modülde mevsimsel ve haftalık model ve kısa vadeli hafıza, saatlik modülde ise günlük model ve kısa vadeli hafıza yer almaktadır. Analiz sonuçları modelin saatlik su talebi tahmini için uygun olduğunu göstermektedir.

Jain vd. (2001) IIT Kanpur'a ait kısa dönemli su talebi tahmini için Yapay Sinir Ağları yöntemini uygulamışlardır. Bu amaçla haftalık su talebi, yağış miktarı ve haftalık ortalama en yüksek

sıcaklık değerleri kullanılmıştır. Farklı gecikmelere sahip yapay sinir ağları, zaman serisi ve regresyon modelleri denenmiştir. Sonuç olarak haftalık su talebi miktarını tahmin etmekte yapay sinir ağları yönteminin diğer tahmin yöntemlerine göre daha uygun olduğu tespit edilmiştir.

Wentz ve Gober (2007) Phoenix için küçük alan su tüketiminin belirleyicilerini en küçük kareler ve coğrafi ağırlıklı regresyon yöntemleriyle araştırmışlardır. Konutlarda su tüketimi belirleyicileri olarak hanehalkı büyüklüğü, havuzun mevcudiyeti, lot büyüklüğü ve nemli ortam gerektiren peyzaj yaygınlığı değişkenleri seçilmiştir. En küçük kareler yöntemi sonuçlarına göre istatistiksel olarak anlamlı olmalarına rağmen hanehalkı büyüklüğü ve peyzaj seçiminin diğer bağımsız değişkenlere göre su tüketimini açıklamada daha az etkili olduğu tespit edilmiştir.

Liu vd. (2003), Weinan'da su talebini yapay sinir ağları modeli ile tahmin etmişlerdir. Bu amaçla 1991 - 2000 arasındaki aylık su tüketim miktarı, su ve atıksu fiyatları, hanehalkı büyüklüğü ve hanehalkı geliri verileri kullanılmıştır. Genel olarak gelirdeki artışın su tüketimini artırdığı görülmüştür. Düşük gelir grubundaki kişilerin su talebinin yüksek gelir grubundaki kişilerin su talebine göre daha esnek olduğu tespit edilmiştir.

Zhou vd. (2000) Melbourne'e ait günlük kentsel su tüketimini tahmin etmişlerdir. Bu amaçla trend, mevsimsellik, iklimsel korelasyon ve otokorelasyondan oluşan zaman serisi formüle edilmiştir. Çalışmada Melbourne'e ait Temmuz 1989 - Haziran 1996 arasındaki günlük kişi başına su tüketimi, maksimum sıcaklık, yağış ve buharlaşma verileri kullanılmıştır. Sonuç olarak Aralık 1996 - Ocak 1997 arasındaki 62 günlük su tüketim değerleri tahmin edilerek gerçek değerleriyle karşılaştırılmıştır.

Sebri (2016) meta-analitik yaklaşımla kentsel su talebi tahminine ilişkin ampirik literatürü araştırmıştır. Bu amaçla 23 çalışmadan elde edilen 601 gözlem kullanılmıştır. Kentsel su talebindeki tahmin doğruluğunu talep periyodu, tahmin genişliği, tahmin yöntemi, model spesifikasyonları ve diğer çalışma karakteristiklerinin etkilediği belirlenmiştir. Çalışma sonucunda, kısa ve orta vadeli tahminlerin uzun vadeli tahminlere göre daha doğru olduğu görülmüştür. Ayrıca ekonometrik modelin yapısı da tahmin doğruluğunu etkilemektedir.

Bougadis vd. (2005) Ottawa'ya ait kısa zamanlı su talebi tahmini için regresyon, zaman serisi ve yapay sinir ağları modellerini karşılaştırmışlardır. Çok değişkenli regresyon modellerinde su talebi, sıcaklık ve yağış verilerinin gecikmeli değerlerinin yer aldığı farklı modeller karşılaştırılmıştır. Zaman serileri analizinde farklı ARIMA modelleri karşılaştırılmıştır. Yapay sinir ağları modellerinde de regresyon modelleri gibi su talebi, sıcaklık ve yağış verilerinin gecikmeli değerlerinin yer aldığı farklı modeller karşılaştırılmıştır. Model karşılaştırmaları sonucunda zaman serisi modellerinin regresyon modellerine göre daha iyi performans gösterdiği tespit edilmiştir. Ancak yapay sinir ağları modellerinin diğer modellere göre oldukça iyi olduğu gözlemlenmiştir.

Literatürde Türkiye'de kentsel su talebi öntahmini üzerine yürütülen az sayıda çalışmaya da rastlanmaktadır. Yapay sinir ağları ve bulanık mantık yöntemlerinin kullanıldığı bu çalışmalardan birinde Altunkaynak vd. (2005), İstanbul'a ait su tüketimini Takagi Sugeno (TS) bulanık mantık yöntemiyle tahmin etmişlerdir. Çalışma aylık zaman boyutunda yapılmış olup 1995 - 2004 yılları arasındaki İstanbul'un toplam su tüketimi verilerinden oluşmaktadır. 1995 - 2002 yılları arasındaki aylık veriler deneme periyodu, son 18 aylık veriler ise tahmin periyodu olarak ikiye ayrılmıştır. Bağımsız değişkenler önceki üç ayın su tüketim miktarları olarak belirlenmiştir. TS bulanık mantık yönetiminde stokastik yöntemlerde gereklilik arz eden

durağanlık gibi kısıtlayıcı varsayımların olmadığı belirtilerek % 10 düzeyinden daha az hata ile tahmin yapıldığı tespit edilmiştir. Çalışmada son olarak TS bulanık mantık tahmin sonuçlarıyla AR(3) tahmin sonuçları ile karşılaştırılmış ve TS bulanık mantık yönteminin daha geçerli olduğuna karar verilmiştir.

Fırat vd. (2008) ve Yurdusev ve Fırat (2009) İzmir'e ait aylık su tüketimini tahmin ettikleri çalışmışlarında Uyarlamalı Sinirsel Bulanık Mantık Sistemi (USBMS) yönetimini 1997 - 2005 yıllarını kapsayan 108 adet aylık veriye uygulamışlardır. Model karşılaştırmaları sonucunda en uygun modelin aylık su faturası, aylık ortalama sıcaklık ve nüfus değişkenlerini içeren model olduğuna karar vermişlerdir. Bu çalışmada ayrıca daha güvenilir ve etkili bir karşılaştırma ve değerlendirme yapmak amacıyla aynı değişkenleri içeren çoklu regresyon yöntemi uygulanmıştır. Sonuçlar, Uyarlamalı Sinirsel Bulanık Mantık yönetiminin daha başarılı tahminler oluşturduğunu göstermiştir.

Fırat vd. (2009a) İzmir'e ait su tüketimini Bulanık Mantık Sisteminin iki türü olan USBMS ve Mamdani Bulanık Mantık Sistemi (MBMS) ile tahmin etmişlerdir. Çalışmada İzmir'in 1997 - 2005 yıllarını kapsayan aylık su tüketim miktarları verisi kullanılmıştır. Model için uygun gecikme sayısının her iki model için de beş olduğuna karar verilmiştir. Beş gecikmeli USBMS ve MBMS sonuçları karşılaştırıldığında ise USBMS modelinin ortalama hata karekökü ve ortalama mutlak görelî hata değerleri MBMS modeline göre daha küçük, korelasyon katsayısı değerinin daha büyük olduğu bulunmuştur. Buna göre gecikmeli USBMS modelinin aylık su tüketimi tahmininde daha uygun olduğu sonucuna ulaşılmıştır.

Fırat vd. (2009b), İzmir'e ait su tüketimi modeli için yapay sinir ağları modellerinin performanslarını değerlendirmişlerdir. Girdi değişkenlerin tekil su tüketimini açıklama performanslarına göre aylık su faturası, sıcaklık, nüfus ve yağış değişkenlerinin Genelleştirilmiş Regresyon Sinir Ağları yöntemiyle en iyi sonuçları verdiği tespit edilmiştir. Girdiler çoklu olarak modele alındığında ise en iyi uyumun aylık su faturası, aylık ortalama sıcaklık ve nüfus değişkenlerini içeren model olduğuna karar vermişlerdir. Burada da Genelleştirilmiş Regresyon Sinir Ağları modeli diğer yapay sinir modeli ağları modellerine göre daha iyi sonuç vermiştir. Son olarak aynı değişkenler kullanılarak çok değişkenli doğrusal regresyon modeli oluşturulmuştur. Ancak Genelleştirilmiş Regresyon Sinir Ağları modelinin bu modelden de dahi iyi sonuçlar verdiği tespit edilmiştir. Aynı verilerle yine İzmir'e ait su tüketimini çeşitli yapay sinir ağları yöntemleri ile tahmin eden Fırat vd. (2010), Basamak Korelasyon Sinir Ağları yönteminin diğer yöntemlere göre az da olsa daha iyi olduğu sonucuna varmıştır.

Şen ve Altunkaynak (2009) içme suyu tüketimi tahminini bulanık mantık modeli ile araştırmışlardır. Modelin girdi değişkenleri fiziksel aktivite, vücut ağırlığı ve sıcaklık, çıktı değişkeni ise su tüketim seviyesi olarak seçilmiştir. Vücut ağırlığı arttıkça kilogram başına düşen su tüketimi azalmaktadır. Fiziksel aktivitenin ve sıcaklığın artması su kaybını artırmaktadır.

4. AMPİRİK ANALİZ

4.1 Değişkenler ve Veriler

4.1.1. Su Tüketimi Miktarı

Çalışmanın konusu itibarıyla, Manisa il merkezinde gerçekleşen su tüketim miktarı temel değişkeni oluşturmaktadır. Bu noktada, tüketilen su miktarını temsilen kullanılan veriler hakkında birkaç hususu belirtmek gerekmektedir.

MASKİ'den alınan su tüketimi verileri Manisa merkezi genelinde MASKİ tarafından şebekeden su verilen tüm abonelerin kullandıkları aylık su miktarının toplamından oluşmaktadır. Sonraki altbölümde daha detaylı olarak üzerinde durulduğu üzere farklı abone türlerinin toplam tüketim içindeki payları bilinmediğinden daha rafine bir gösterge kullanılamamıştır.

Aylık tüketim değerleri incelendiğinde örneklem döneminde Manisa merkezde su tüketiminin üç kattan fazla artış gösterdiği görülmekte ve üç farklı davranış biçimi göze çarpmaktadır. Bu artışın çeşitli ekonomik ve sosyal nedenleri olabilirse de burada belli başlı birkaçına yer verilmektedir. 2003 Ocak – 2009 Aralık döneminde sayaç okumaları iki ayda bir yapıldığından aylık veriler elde etmek için iki aylık tüketim değeri ikiye bölünerek her bir ayın tüketim miktarı bulunmuştur. Aslında her bir ayın kendine göre bir tüketim dinamiği bulunduğu ve bu şekilde bir dönüştürmenin verilerde içerilen bilgi miktarını tam yansıtmayacağı kabul edilmekle birlikte örneklem dönemini mümkün olduğunca geniş tutmak amacıyla bu yol tercih edilmiştir. Nitekim sözü edilen aylara özgü tüketim kalıbı, aylık okuma yapılan 2010 Ocak – 2014 Kasım dönemi verilerinde açıkça görülmektedir. Bu dönem değerleri, su tüketiminde bariz bir mevsimselliğin mevcudiyetini ortaya koymaktadır.

Veri setinin en problematik kısmı 2014 Aralık ayından itibaren ortaya çıkmaktadır. 6360 sayılı Kanun ile 30 Mart 2014 tarihinde yapılan Mahalli İdareler Seçimi'nden itibaren Büyükşehir Belediyesi statüsü kazanan Manisa Belediyesi'nin sınırları değişim göstermiştir. Her ne kadar önceki merkez ilçe ile Büyükşehir statüsünden sonra teşkil edilen merkez ilçeler (Şehzadeler ve Yunusemre) sınır olarak büyük oranda örtüşse de bazı köy ve beldelerin idari bölümlendirme içindeki konumları nedeniyle merkez ilçelerin ve MASKİ'nin hizmet alanı kapsamında bir miktar genişleme söz konusudur². Bu genişleme su abone sayısı, tüketim miktarı ve toplam su bedeli tahsilatında da kendini göstermektedir.

Zaman içinde abone sayısı giderek artmış ve büyükşehir sonrası abone sayısında bir sıçrama meydana gelmiştir. MASKİ'den edinilen bilgiye göre bu anormal hareket biçiminin arkasında yatan neden, merkez ilçelere bağlanan köy ve beldelerdeki abone kayıtlarında gözlenen karmaşa, kayıtdışılık ve sonradan tesbit edilen mükerrer kayıtlardır. Tahminlerin güvenilirliği açısından, her ne kadar 2014 Aralık ayından sonra elde gerçek veriler bulunsa da bu verilerin sıhhati konusundaki şüpheler ve kapsamdaki değişim dikkate alınarak örneklem dönemi 2003 Ocak – 2014 Kasım olacak şekilde belirlenmiştir.

Etik Onay: Çalışma konusu etik kurul iznini gerektirmemektedir. Bu çalışmanın tüm hazırlanma süreçlerinde etik kurallara uyulduğunu yazarlar beyan eder.

4.1.2. Fiyat

İktisat teorisine göre bir malın talep (tüketim) miktarını etkileyen en önemli değişkenlerden biri malın fiyatıdır ve normal mallarda talep miktarı ile fiyat arasında ters yönlü bir ilişki öngörülmektedir. MASKİ tarafından meskenlerde su tüketim miktarına göre (blok tarife sistemi³) ve abone türü itibarıyla farklı fiyatlandırma yapılmaktadır. MASKİ'nin tüketim birimlerine ilişkin genel sınıflandırması verilmiştir:

² Aslında 6360 sayılı Kanun ile Büyükşehir Belediyesi'nin ve MASKİ gibi bağlı organların hizmet alanı tüm ilin sınırları düzeyine çıkarılmıştır. Ancak burada kastedilen MASKİ'nin yeni oluşturulan merkez ilçeler kapsamındaki faaliyetleridir.

³ Meskenler için blok tarife sisteminde, su tüketim miktarı itibarıyla 0 – 10, 11 – 20, 21 ve üzeri biçiminde üç farklı blok itibarıyla her bir tüketim grubuna farklı birim fiyatı uygulanmaktadır. Buradaki temel amaç fazla tüketimi daha yüksek fiyat ödemeye mecbur bırakarak aşırı su tüketimini caydırmaktır, su kullanımında tasarrufu teşvik etmektir.

- Kamu yararına faaliyet gösteren abone
- Mesken
- Resmi daire
- Ticarethane
- Umumi su
- Gazi-şehit-engelli ailesi
- Resmi-özel okul, resmi yurt
- İnşaat (2006'dan itibaren)
- Hamam (2008'den itibaren)
- Park-bahçe (2010'dan itibaren)
- Turistik tesis (2013'ten itibaren)

2015 Ocak ayından itibaren kartlı akıllı sayaçların kullanılmasıyla birlikte bu tür sayaç kullanan her bir abone türü için farklı bir tarife de uygulanmaya başlamıştır. 2017 Kasım itibariyle alt gruplar ve bloklar dikkate alındığında toplam 106 abone türü ayrıştırılmakta ve bunlara 0 - 11,7 TL aralığından çeşitli fiyatlar uygulanmaktadır. Bu durum, her ne kadar arz edilen ürün türdeş bir mal olsa da, fiyat değişkeni olarak hangi değer dikkate alınacağı şeklinde bir zorluk doğurmaktadır. Abone türlerinin genel içindeki paylarına ilişkin bilgi mevcut olmadığından ağırlıklı bir gösterge oluşturmak da mümkün değildir. Bununla birlikte meskenlerin toplam abone sayısı içinde en büyük paya sahip olduğu açıktır. MASKİ'den edinilen bilgiye göre meskenlerin çoğunluğu 0 - 10 bloğuna tâbidir. Bu nedenle çalışmada aylar itibariyle 0 - 10 bloğuna uygulanan birim fiyatı dikkate alınmıştır.

MASKİ'den elde edilen su birim fiyatları bilgisine göre 2003 - 2014 döneminde birim fiyatın belirlenmesinde belirli bir düzene uyulmadığı anlaşılmaktadır. Ancak 2015 ocak ayından itibaren 12 ay geçerli olacak yeni fiyat belirlenmektedir. Su birim fiyatlarının zaman içindeki seyri ve fiyat düzeyinin gelişimi incelendiğinde düzensiz sayılabilecek değişim görülmektedir. Örneklem döneminde su birim fiyatı Manisa'nın da içinde yer aldığı 6. bölge (Manisa, Uşak, Afyon, Kütahya) enflasyon oranının oldukça üzerinde bir artış göstermiştir⁴.

4.1.3. Sıcaklık

Genel olarak su tüketimi üzerinde etkili olması beklenen faktörlerin en önemlilerinden biri de hava sıcaklığıdır. Gerek evsel su tüketiminde (özellikle banyo, araç ve ev temizliği amaçlı olarak) gerekse de açık alanlardaki (çim ve bahçe sulama, süs havuzu vs.) su tüketiminde hava sıcaklığındaki artışa bağlı olarak bir yükselme meydana gelmesi beklenebilir.

Manisa il merkezine ilişkin aylık sıcaklık verileri Meteoroloji Genel Müdürlüğü'nden yazılı talep ile elde edilmiştir. İl merkezindeki 17186 nolu istasyondan elde edilen ölçümlere göre Manisa il merkezinde 2003 Ocak - 2017 Eylül döneminde aylık ortalama sıcaklık en düşük 4,07 (2006 Ocak ayı) ile 30,18 (2012 Temmuz ayı) arasında değişmektedir. Zaman içindeki seyir incelendiğinde aylık sıcaklık ortalamalarının yatay bir seyir izlediği, herhangi bir artan/azalan trend bulunmadığı görülmektedir.

4.1.4. Yağış Miktarı

Su tüketimini etkilemesi beklenen bir diğer meteorolojik faktör yağış miktarıdır. Aslında yağış miktarı hem arz hem de talep yönlü olarak su piyasasını etkileme potansiyeline sahiptir. Yağış rejimindeki seyre bağlı olarak şebeke suyu tüketimi de dalgalanma gösterebilmektedir. Yağışın yetersiz olması halinde yeraltı su kaynaklarındaki verim ve su miktarındaki (su arzındaki) düşüşe nedeniyle su tüketiminde (talebinde) de potansiyelin altında bir seviye gözlenebilir. Manisa gibi kentsel su talebinin neredeyse tamamının sondaj kuyularından karşılandığı kentlerde yağış rejiminin istikrarı daha büyük önem arz etmektedir.

⁴ 2017 Kasım ayı itibariyle 6. Bölge için 2003 bazlı TÜFE 316,85'tir. 2003-2017 döneminde su birim fiyatındaki artış ise % 805'tir.

Konuyla ilgili veriler Meteoroloji Genel Müdürlüğü'nden yazılı talep ile elde edilmiştir. Örneklem dönemindeki aylık toplam yağış verileri incelendiğinde Manisa merkez ilçede Temmuz, Ağustos ve kısmen Eylül aylarının kurak geçtiği görülmüştür. Yağış verilerine ilişkin zaman grafiği incelendiğinde ise Manisa il merkezinde dönem dönem kurak yılların yaşandığı (örneğin 2006 ve 2007 yılları), ancak uzun dönemde yağış rejiminde kayda değer bir değişimin bulunmadığı görülmüştür⁵.

4.1.5. Enflasyon Oranı

Enflasyon oranı belediyenin girdi maliyetlerini etkilemesi beklenen bir değişkendir. Genel fiyat seviyesindeki artış içme suyu arz maliyetlerinde de bir artışa yol açacağından gecikmeli olarak su birim fiyatlarına bu artış yansıtılabilir. Birim fiyattaki artış ise hanehalklarının daha düşük su tüketmesine neden olacaktır. Diğer taraftan, enflasyondaki yükseliş hanehalklarının satın alma güçlerinde belirli bir süre daralmaya sebep olacağından su talebinde de bir düşüş gözlenebilir. Dolayısıyla enflasyonun su tüketimi üzerinde fiyat kanalıyla dolaylı, harcamalar kanalıyla doğrudan bir etkide bulunması beklenmektedir. Enflasyon oranı bölgelere göre farklılık arz edebileceğinden çalışmada Manisa'nın da içinde yer aldığı bölgesel enflasyon oranı kullanılmıştır.

4.2. Öntahmin Sonuçları

4.2.1. Yapay Sinir Ağı Yönteminden Elde Edilen Öntahminler

Bu bölümde, kullanılan girdi (bağımsız) ve çıktı (bağımlı) değişkenlerine ait veriler kullanılarak en uygun YSA modelinin tasarımı yapılmaya çalışılmıştır. Modelde, çıktı değişkeni olarak Manisa ili aylık su talep miktarı, girdi değişkenleri olarak; ortalama hava sıcaklığı, ortalama yağış toplamı, kentin nüfusu, TÜFE, su fiyatı ve abone başına düşen su faturası tutarı alınmıştır. Modeldeki girdi ve çıktı değişkenlerine ait fonksiyonel ilişki aşağıdaki gibi ifade edilebilir.

Su talebi = f (ortalama hava sıcaklığı, ortalama yağış toplamı, kentin nüfusu, TÜFE, su fiyatı, abone başına düşen su faturası tutarı)

Çalışmada her bir değişkene ait 12 yıllık (143 aylık) veri ile çalışılmıştır. Yapay sinir ağlarının geliştirilmesinde farklı modeller uygulanmıştır. Bu modeller arasından en uygun olanı seçilmiştir. İlgili YSA algoritmasının tercih edilmesinin nedeni, doğrusal ve doğrusal olmayan modellerdeki tahmin başarısı, kullanım kolaylığı ve yakınsama hızının yüksek olmasıdır. Girdi değişkenlerine ait veri setlerinde belirtilen değerler modelin kurulmasından önce program tarafından normalizasyon işlemine tabi tutularak [-1,1] aralığına dönüştürülmüştür. Çıktı değişkenine ait değerler ise çıktı katmanı aktivasyon fonksiyonu tarafından normalizasyon işlemine tabi tutularak [0, 1] aralığına indirgenmiştir.

Çıktı ve girdi değişkenlerine ait tanımlayıcı istatistikler Tablo 1'de görüldüğü gibidir.

⁵ Bu değerlendirme, Manisa il merkezine ilişkin 1960 - 2017 dönemini kapsayan daha geniş bir veri setine dayanmaktadır.

Tablo 1. Çıktı ve Girdi Değişkenlerine Ait Tanımlayıcı İstatistikler

	Örnek hacmi	Ortalama	Std. Sapma	Min.	Max.
Su talep miktarı	143	801148,3	140175,7	513233	1138432
Fiyat	143	1,425	0,624	0,36	2,2
Abone başına fatura tutarı	143	26,757	5,899	15,040	40,755
Sıcaklık	143	17,255	8,057	4,036	30,658
Yağış	143	58,768	61,767	0,0001	268,5
Nüfus	143	335934,4	21638,3	298847,3	373021,5
TÜFE	143	0,658	0,681	-0,92	2,86

Bu çalışmada, YSA modellerinin oluşturulmasında Neurosolutions 7 paket programından faydalanılmıştır. Modelin eğitimi, testi ve tahmin üretimi gibi tüm aşamalar yine bu yazılım ile gerçekleştirilmiştir. Yapay sinir ağları analizini uygulayabilmek için veri seti eğitim, geçerlilik ve test kısımlarına ayrılmış ve farklı girdi katman nöron sayılarına göre model performansları ölçülmüştür. Bunun için literatürde en çok kullanılan üç farklı veri ayırma yüzdesi denenmiştir. Bu yüzdeler ayrı ayrı ele alınarak aşağıda incelenmiştir.

i) Veri Setinin %70 Eğitim, %15 Geçerlilik ve %15 Test Olarak Ayrılması ile Analiz Sonuçları

İlk olarak, %70 eğitim, %15 geçerlilik ve %15 test olmak üzere üç kısma ayrılan veri seti, yapay sinir ağları modelleri kullanılarak analiz edilmiştir. Bu işlemlerin amacı, öngörü amacı ile kullanılacak olan en iyi yapay sinir ağına ilişkin veri setini ve bu veri seti kullanılarak oluşturulan ağıdaki en düşük RMSE değerine sahip girdi katmanı nöron sayısını belirleyebilmektir. Analiz sonuçlarına göre en iyi performansı gösteren model YSA (70-15-15) MLPR-1-B-R (Regression MLP) modelidir⁶.

Tablo 4'te görüldüğü gibi örnekleme-içi su talebi için girdi katmanında 1 adet gizli katmana sahip, eğitim türü Batch olan ve öğrenme algoritması ise RDRÖP olan MLPR modeli diğer modeller ile karşılaştırıldığında en düşük RMSE değerine sahip olan model olmuştur.

ii) Veri Setinin %70 Eğitim, %20 Geçerlilik ve %10 Test Olarak Ayrılması ile Analiz Sonuçları

Bu bölümde %70 eğitim, %20 geçerlilik ve %10 test olmak üzere üç kısma ayrılan veri seti analiz edilmiştir. Analiz sonuçlarına göre en düşük RMSE değerine sahip ağın sonucuna ilişkin sonuçlar Tablo 5'te görülmektedir. Bu sonuçlara göre, 1 adet gizli katmana sahip, eğitim türü Batch olan ve öğrenme algoritması RDRÖP olan MLPRPC modeli en düşük RMSE değerine sahip olan modeldir.


iii) Veri Setinin %80 Eğitim, %10 Geçerlilik ve %10 Test Olarak Ayrılması ile Analiz Sonuçları

Son olarak, %80 eğitim, %10 geçerlilik ve %10 test olmak üzere üç kısma ayrılan veri seti analiz edilmiştir. Analiz sonuçlarına göre en iyi sonuçları veren ağa ait tüm modellere ilişkin bilgiler Tablo 6'da verilmiştir. Bu sonuçlara göre, girdi katmanında 1 adet gizli katmana sahip, eğitim türü Batch olan ve öğrenme algoritması RDRÖP olan GFFR modeli en düşük RMSE değerine sahip olan model olarak bulunmuştur.


⁶ Yer tasarrufu amacıyla bu bundan sonraki kısımlarda uygun bulunan modele ilişkin seçim kriteri değerleri verilmemiştir. Talep üzerine sorumlu yazardan temin edilebilir. Tahmin sonuçlarına ilişkin tablolar çalışmanın sonunda ek olarak sunulmuştur.

Veri setinin üç farklı yüzde kullanılarak kısımlara ayrılması ile elde edilen tüm modeller, model seçim kriterlerine bakılıp birlikte değerlendirildiğinde *su talebi* serisi için, %80 eğitim, %10 geçerlilik ve %10 test verisinden oluşan ve sırasıyla, girdi katmanında 1 adet gizli katmana sahip, eğitim türü Batch olan ve öğrenme algoritması RDROP olan GFFR modeli en düşük RMSE değerine sahip olan model en iyi model olarak elde edilmiştir. Tüm yüzde değerlerine göre elde edilen tahmin sonuçları Tablo 7’de ve bunlara ait grafik Şekil 1’de verilmiştir. Ayrıca gerçekleşen değerler ile tahminlenen değerler arasındaki farkı veren mutlak hataya ait grafik Şekil 2’de verilmiştir. Şekilden de görüldüğü gibi bahar ve yaz aylarında hataların en çok olduğu gözlenmektedir.

Şekil 1. Modellerden Elde Edilen Tahminî Değerler İle Gerçek Değerler



Şekil 2. Tahminî Değerler İle Gerçekleşen Değerler Arasındaki Mutlak Fark



Öntahmin için oluşturulan modeller Tablo 8-9’da ve tahmin sonuçları Tablo 11’de sunulmuştur. Öntahmin yapabilmeye yapay sinir ağları analizini uygulayabilmek için veri seti eğitim, geçerlilik ve test kısımlarına ayrılmış ve farklı girdi katman nöron sayılarına göre model performansları ölçülmüştür. Bunun için daha önce örneklem içi tahminde kullanılan üç farklı veri ayırma yüzdesi denenmiştir. Elde edilen sonuçlara göre model seçim kriterleri baz alınarak YSA(80-10-

10) için en uygun modelin GFFR-1-B-L (Reg Gen Feedforward, 1 gizli katmanlı, eğitim türü Batch olan ve öğrenme algoritması Levenberg Marquardt), YSA(70-20-10) için en uygun modelin LinR-0-B-L (Linear Regression, 0 gizli katmana sahip, eğitim türü Batch olan ve öğrenme algoritması Levenberg Marquardt) ve YSA(70-20-10) için ise en uygun modelin GFFR-1-O-M (Reg Gen Feedforward, 1 gizli katmana sahip, eğitim türü On-Line olan ve öğrenme algoritması Momentum) olduğu görülmektedir. Bu üç model RMSE kriterine göre karşılaştırıldığında en uygun modelin YSA(80-10-10) için GFFR-1-B-L modeli olduğu görülmektedir. Modellere ait öntahmin değerlerinin grafiksel bir gösterimi ise Şekil 5'te sunulmuştur. Ayrıca örneklem içi ve örneklem dışı tahmin için en uygun modelden elde edilen tahmin değerleri Şekil 6'da verilmiştir.

4.2.2. ARIMA Modelinden Elde Edilen Öntahminler

Bu bölümde aylık su tüketimi için ARIMA (p,d,q) modeli yardımıyla öntahminler elde edilmektedir. ARIMA modelinde öncelikle serinin bütünleşme derecesi (d) belirlenmektedir. Her ne kadar geleneksel Box – Jenkins metodolojisinde bütünleşme derecesini belirlemek amacıyla serinin *acf* ve *pacf* grafikleri inceleniyorsa da günümüzde bunun için genellikle biçimsel birim-kök testleri kullanılmaktadır. Burada da aylık su tüketimi serisinin bütünleşme derecesini belirlemek için Genişletilmiş Dickey-Fuller testine başvurulmuştur. Test sonuçlarına göre seri düzey değerleri itibariyle durağan değilken birinci farkları itibariyle durağanlaşmaktadır (bkz. Tablo 2). Buna göre su tüketimi serisinin 1. dereceden bütünleşik olduğu anlaşılmaktadır.

Tablo 2. ADF birim kök testi sonuçları.

Değişken Adı	Düzyey		1. Fark	
	Sabit	Sabit ve trend	Sabit	Sabit ve trend
Su tüketimi	- 1,0299 (0,7413)	- 1,9465 (0,6244)	- 11,3115 (0,0000)	- 11,2848 (0,0000)

Uygun ARIMA modelinin p ve q parametrelerini belirlemek üzere farklı modeller denenerek bunlar arasından en küçük Akaike Bilgi Kriteri değerine sahip olan ARIMA (1,1,4) modeli benimsenmiştir⁷. Modelin tahmini aşağıdaki gibidir:


$$\Delta Y_t = 2503,357 - 0,993\Delta Y_{t-1} + e_t + 0,595e_{t-1} - 0,982e_{t-2} - 0,635e_{t-3} + 0,022e_{t-4}$$

Burada Δ birinci fark operatörü, Y_t aylık su tüketimi, e_t hata terimidir.

ARIMA (1,1,4) modeli kullanılarak elde edilen öntahmin değerleri ise aşağıdaki Şekil 3'te verilmiştir. Tahmin edilen model fark serisine dayandığından y serisi aylık su tüketimine ilişkin orijinal değerleri, f ise öntahmin değerlerini ifade etmektedir. Dolayısıyla görülen grafik su tüketimindeki aylık değişimlere ilişkindir.

⁷ Birim-kök testi ve uygun ARIMA modelinin otomatik seçimi OxMetrics yazılımı ile gerçekleştirilmiştir.


Şekil 3. ARIMA(1,1,4) Modelinden Elde Edilen Öntahmin Değerleri



4.2.3. Holt-Winters Üstel Düzleştirme Yönteminden Elde Edilen Öntahminler

Aylık su tüketiminin örneklem-içi öntahminleri Holt-Winters üstel düzleştirme yöntemiyle elde edilmiştir. Otomatik seçim yoluyla elde edilen en uygun denklemde α katsayısı 0,9, β ve δ katsayıları ise sıfır alınmıştır. 2013 Ocak - 2014 Aralık dönemi için düzleştirme denkleminde elde edilen öntahminler Şekil 4'te verilmiştir. Görüldüğü gibi benimsenen denklem aracılığıyla seri önemli derecede düzleşmiştir. Öntahmin değerleri bazı dönemler için oldukça düşük hatalı iken, gerçek değerlerin aşırı dalgalanma gösterdiği bazı dönemlerde ise bu hareketi yakalamakta yetersiz kalmaktadır.

Şekil 4. Holt-Winters Üstel Düzleştirme Yöntemiyle Elde Edilen Öntahminler



4.3. Yöntemlerin Öntahmin Performanslarının Karşılaştırılması

Yapay sinir ağı algoritması, ARIMA modeli ve üstel düzleştirme yöntemiyle elde edilen aylık su tüketimi öntahminlerinin her birinin kendine göre bir öntahmin hatası dağılımı vardır. Uygulamada her zaman birkaç yöntemle başvurularak öntahmin üretmek zaman alıcı ve maliyetli olabilmektedir. Bunun yerine, alternatif yöntemlerin öntahmin performanslarını

değerlendirmek ve uygun yöntemin hangisi olduğuna karar vererek sonraki tahmin çalışmalarında belirlenen yöntemi kullanmak daha doğru bir yoldur. Bu nedenle bu aşamada kullanılan üç farklı öntahmin yönteminin performans değerlendirilmesi çeşitli ölçütler kullanılarak yapılmaktadır.

Zaman serisi literatüründe öntahmin değerlendirmesinde kullanılan birçok ölçüt bulunmakla birlikte burada bunlardan en çok kullanılan üç tanesine yer verilmiştir: kök ortalama hata kare (RMSE), ortalama mutlak hata (MAE) ve korelasyon katsayısı (r). Bu ölçütlere ilişkin hesaplama formülleri aşağıdaki gibidir:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad r = \frac{\sum_{t=1}^n (Y_t - \bar{Y})(F_t - \bar{F})}{\sqrt{\sum_{t=1}^n (Y_t - \bar{Y})^2 \sum_{t=1}^n (F_t - \bar{F})^2}}$$

Burada, n serideki gözlem sayısı, Y_t öntahmini yapılan seri, F_t öntahmin değerleri, $e_t = Y_t - F_t$ dir. \bar{Y} ve \bar{F} ise sırasıyla orijinal ve öntahmin serilerinin ortalamalarıdır.

Her üç ölçüte göre alternatif yöntemlerin performans bilgileri aşağıda Tablo 3'te verilmiştir.

Tablo 3. Değerlendirme ölçütlerine göre yöntemlerin performansları.

	Yöntem		
	YSA(80-10-10)	ARIMA(1,1,4)	Holt-Winters
RMSE	43914,58	45281,07	80813,63
MAE	37197,36	36633,61	63266,74
r	0,97	0,62	0,40

Tablodan da açıkça görüldüğü üzere YSA(80-10-10) modeli öntahmin performansı açısından diğer iki yöntemle nazaran bariz bir üstünlüğe sahiptir. Buna göre YSA(80-10-10) kullanılarak Manisa il merkezi için aylık su tüketimine ilişkin projeksiyonlar hazırlanabilir.

5. SONUÇ

Su, yaşamın kaynağı ve belirtisidir. Öyle ki, dünya dışı gök cisimlerinde yaşama dair bir belirti için ilk olarak aranan koşul suyun varlığıdır. Suyun yaşam için önemini bilmesi ve kabul edilmesine rağmen kullanılabilir tatlı su kaynakları yıldan yıla azalma eğilimi göstermektedir. Bu süreç kısmen dünyanın içinde bulunduğu iklim değişikliği döngüsüne bağlanabilirse de 20. yüzyılda ivme kazanan sanayileşme ve kentleşmenin yol açtığı kirlilik ve aşırı su kullanımının etkisi de gözardı edilemez. Bu itibarla kentsel su yönetimi ve kaynakların etkin kullanımı eskisinden daha önemli gelmiştir denebilir.

Ülkenin üçüncü büyük kenti olan İzmir'e yakınlığı ve son yıllarda aldığı yoğun iç göçün etkisiyle nüfusu hızla artan Manisa içme suyu kaynakları açısından dezavantajlı bir konumdadır. Hâlihazırda kentin içme suyu sondaj kuyuları vasıtasıyla yeraltı kaynaklarından temin edilmektedir. Bu durum istikrarsız ve yetersiz yağış koşulları karşısında kentin su yönetimini kırılgan hâle getirmektedir. Bu bakımdan kentsel su tüketimine ilişkin gelecek yıllara dönük projeksiyonların hazırlanması alınacak kararlar ve izlenecek politikalar konusunda ışık tutacaktır. Bu tür projeksiyonların ayrılmaz bir parçası ise geleceğe dönük tahmin çalışmalarıdır. Bu araştırmada, alternatif yöntemler kullanılarak Manisa il merkezi için 2014 Aralık - 2018 Aralık dönemini kapsayan 49 aylık öntahmin değerleri belirlenmiştir.

Çalışmada Yapay Sinir Ağı (YSA), ARIMA modeli ve Holt-Winters üstel düzleştirme yöntemleri kullanılarak öntahminler elde edilmiş, örnek-içi tahmin performansları açısından karşılaştırma yapılmıştır. Değerlendirme ölçütlerine göre YSA(80-10-10) modeli öntahmin performansı açısından diğer iki yönteme nazaran bariz bir üstünlüğe sahiptir. Buna göre, YSA(80-10-10) modeli kullanılarak Manisa il merkezi için aylık su tüketimine ilişkin projeksiyonlar hazırlanabilir.

Kentsel su talep tahmininin yapay sinir ağları metoduyla modelinin oluşturulmasının ulusal literatüre faydalı bir model katacağı inancındayız. MASKİ'nin aylık olarak gelecek dönemlere ilişkin su talebini bilmesi, yapacağı yatırımlara, sistem tasarımlarına, işletme ve yatırım politikalarına ve maliyet analizlerine yön verici nitelik taşıyacaktır. Bununla birlikte belki de en önemlisi bu konunun, Manisa'da ikamet eden ve mobil nüfusun içme ve kullanma suyu sıkıntısı çekmemesi için gerekli önlemlerin alınmasında yararlı olması mümkündür. Özellikle diğer büyükşehirlerdeki aynı misyona sahip idarelerin bu çalışmayı örnek alarak kendi illerine uygun modellerin kurulmasında, tahmin edilmesinde ve sonuçlarından faydalanmalarında önemli katkısı olacaktır.

Araştırma bulgularının su tüketim karakteristiklerinin tespit edilmesinde, su talep ve hizmetlerinin optimal olarak karşılanmasında, ilgili yatırım planlamalarının yapılmasında, su sistemlerinin tasarımında (arıtma tesisi, depolama, iletim ve dağıtım hatları), mevcut sistemlerin optimal kapasitede işletilmesinde, işletme ve yatırım maliyetlerinin hesaplanması ve kentsel su yönetimi politikalarının belirlenmesinde önemli katkılar sağlaması beklenmektedir. Ayrıca Manisa ili için yapılan bu çalışmadan elde edilen çıktılar, ileride bölgedeki diğer illerde yapılacak bilimsel çalışmalara kaynaklık etmesi, böylelikle proje çıktılarının faydalarının yaygınlaştırılması hedeflenmektedir.

KAYNAKÇA

- Altunkaynak, A., Özger, M. & Çakmakçı, M. (2005). Water consumption prediction of Istanbul city by using fuzzy logic approach. *Water Resources Management*, 19(5), 641-654. <https://doi.org/10.1007/s11269-005-7371-1>
- Alvisi, S., Franchini, M. & Marinelli, A. (2007). A short-term, pattern-based model for water-demand forecasting. *Journal of Hydroinformatics*, 9(1), 39-50. <https://doi.org/10.2166/hydro.2006.016>
- Arbués, F., Garcia-Valiñas, M. Á. & Martinez-Espiñeira, R. (2003). Estimation of residential water demand: A state-of-the-art review. *The Journal of Socio-Economics*, 32(1), 81-102. [https://doi.org/10.1016/S1053-5357\(03\)00005-2](https://doi.org/10.1016/S1053-5357(03)00005-2)
- Babel, M. S., Gupta, A. D. & Pradhan, P. (2007). A multivariate econometric approach for domestic water demand modeling: An application to Kathmandu, Nepal. *Water Resources Management*, 21(3), 573-589. <https://doi.org/10.1007/s11269-006-9030-6>
- Bougadis, J., Adamowski, K. & Diduch, R. (2005). Short-term municipal water demand forecasting. *Hydrological Processes*, 19(1), 137-148. <https://doi.org/10.1002/hyp.5763>
- Firat, M., Yurdusev, M. A. & Mermer, M. (2008). Uyarlamalı sinirsel bulanık mantık yaklaşımı ile aylık su tüketiminin tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 23(2), 449-457.
- Firat, M., Turan, M. E. & Yurdusev, M. A. (2009a). Comparative analysis of fuzzy inference systems for water consumption time series prediction. *Journal of Hydrology*, 374(3), 235-241. <https://doi.org/10.1016/j.jhydrol.2009.06.013>

- Firat, M., Yurdusev, M. A. & Turan, M. E. (2009b). Evaluation of artificial neural network techniques for municipal water consumption modeling. *Water Resource Management*, 23, 617-632. <https://doi.org/10.1007/s11269-008-9291-3>
- Firat, M., Turan M. E. & Yurdusev, M. A. (2010). Comparative analysis of neural network techniques for predicting water consumption time series. *Journal of Hydrology*, 384, 46-51. <https://doi.org/10.1016/j.jhydrol.2010.01.005>
- House-Peters, L. A. & Chang, H. (2011). Urban water demand modeling: Review of concepts, methods, and organizing principles. *Water Resources Research*, 47(5), 1-15. <https://doi.org/10.1029/2010WR009624>
- Jain, A., Varshney, A. K. & Joshi, U. C. (2001). Short-term water demand forecast modelling at IIT Kanpur using artificial neural networks. *Water Resources Management*, 15(5), 299-321.
- Liu, J., Savenije, H. H. & Xu, J. (2003). Forecast of water demand in Weinan City in China using WDF-ANN model. *Physics and Chemistry of the Earth, Parts A/B/C*, 28(4), 219-224. [https://doi.org/10.1016/S1474-7065\(03\)00026-3](https://doi.org/10.1016/S1474-7065(03)00026-3)
- MASKİ. (2015). *Manisa büyükşehir belediyesi manisa su ve kanalizasyon idaresi genel müdürlüğü. 2014 Yılı Faaliyet Raporu.* <https://www.manisasu.gov.tr/Resources/Documents/2014%20Y%20c4%b1%20Faaliyet%20Raporu.pdf>
- MASKİ. (2017). *Manisa büyükşehir belediyesi manisa su ve kanalizasyon idaresi genel müdürlüğü. 2016 Yılı Faaliyet Raporu.* https://www.manisasu.gov.tr/Resources/Documents/faaliyet_raporu_2016.pdf
- MÇŞM. (2015). *Manisa valiliği çevre ve şehircilik il müdürlüğü. Manisa İli 2014 Yılı Çevre Durum Raporu.* <https://webdosya.csb.gov.tr/db/ced/editor/dosya/2014%20Manisa.pdf>
- Sebri, M. (2016). Forecasting urban water demand: A meta-regression analysis. *Journal of Environmental Management*, 183, 777-785. <https://doi.org/10.1016/j.jenvman.2016.09.032>
- Şen, Z. & Altunkaynak, A. (2009). Fuzzy system modelling of drinking water consumption prediction. *Expert Systems with Applications*, 36(9), 11745-11752. <https://doi.org/10.1016/j.eswa.2009.04.028>
- Wentz, E. A. & Gober, P. (2007). Determinants of small-area water consumption for the city of Phoenix, Arizona. *Water Resources Management*, 21(11), 1849-1863. <https://doi.org/10.1007/s11269-006-9133-0>
- Wong, J. S., Zhang, Q. & Chen, Y. D. (2010). Statistical modeling of daily urban water consumption in Hong Kong: Trend, changing patterns, and forecast. *Water Resources Research*, 46(3), 1-10. <https://doi.org/10.1029/2009WR008147>
- Yurdusev, M. A. & Fırat, M. (2009). Adaptive neuro fuzzy inference system approach for municipal water consumption modeling: An application to Izmir, Turkey. *Journal of Hydrology*, 365(3), 225-234. <https://doi.org/10.1016/j.jhydrol.2008.11.036>
- Zhou, S. L., McMahon, T. A., Walton, A. & Lewis, J. (2000). Forecasting daily urban water demand: A case study of Melbourne. *Journal of Hydrology*, 236(3), 153-164. <https://doi.org/10.1029/2009WR008147>

Çıkar Çatışması Beyanı: Bu çalışmada taraf olabilecek herhangi bir kişi, kurum veya kuruluş arasında bir çıkar çatışması bulunmamaktadır.

Destek ve Teşekkür: Bu araştırma, Manisa Celal Bayar Üniversitesi Rektörlüğü Bilimsel Araştırma Projeleri Birimi tarafından BAP 2017-056 no'lu proje ile desteklenmiştir. Destek için

MCBÜ-BAP birimine, ilgi ve yapıcı önerileri için Dicle Akademi Dergisi Editörlerine ve hakemlere teşekkür ederiz.

Etik Kurul İzni: Çalışma konusu etik kurul iznini gerektirmemektedir. Bu çalışmanın tüm hazırlanma süreçlerinde etik kurallara uyulduğunu yazarlar beyan eder.

Katkı Oranı: Makaleye, birinci yazarın katkı oranı %75, ikinci yazarın katkı oranı ise %25'tir.

* * * * *

EXTENDED ABSTRACT

Introduction

Water is the source and sign of life. Although the importance of water for life is known and accepted, usable freshwater resources tend to decrease from year to year. Although this process can be partially attributed to the climate change cycle that the world is in, the effects of pollution and excessive water use caused by industrialization and urbanization that accelerated in the 20th century cannot be ignored. In this respect, it can be said that urban water management and effective use of resources have become more important than before.

Manisa, whose population is rapidly increasing due to its proximity to Izmir, the third largest city in the country, and the intense internal migration it has received in recent years, is in a disadvantaged position in terms of drinking water resources. Currently, the city's drinking water is supplied from underground sources through boreholes. This situation makes the city's water management fragile in the face of unstable and insufficient rainfall conditions. In this regard, the preparation of projections regarding urban water consumption for the coming years will shed light on the decisions to be made and the policies to be followed. An integral part of such projections is future forecast studies. In this research, 49-month forecast values covering the period between December 2014 and December 2018 were determined for Manisa city center by using alternative methods.

Method

Artificial neural network (ANN), ARIMA model and Holt-Winters exponential smoothing methods were used in forecasting. First of all, in-sample predictions were obtained with these methods and the forecasting performances of the methods were compared.

Findings

According to the results obtained from the evaluation criteria, the ANN (80-10-10) model has a clear superiority compared to the other two methods in terms of prediction performance. Accordingly, projections regarding monthly water consumption for Manisa city centre can be prepared by using the ANN (80-10-10) model. In addition, based on the behaviour in the in-sample period, it can be said that the water demand in the Manisa centre will follow a stable course without a significant increase in the out-of-sample period.

Discussion, Conclusion and Recommendations

We believe that creating a model of urban water demand forecasting using the artificial neural networks method will add a useful model to the national literature. Knowing MASKİ's monthly water demand for future periods will guide its investments, system designs, operating and investment policies and cost analyses. However, perhaps most importantly, this issue may be useful will be useful in taking the necessary precautions to prevent the resident and mobile

population of Manisa from suffering from drinking and potable water shortage. In particular, administrations with the same mission in other metropolitan cities will make a significant contribution to taking this study as an example in establishing and predicting models suitable for their provinces and benefiting from the results.

Research findings are useful in determining water consumption characteristics, optimally meeting water demand and services, making relevant investment plans, designing water systems (treatment facilities, storage, transmission and distribution lines), operating existing systems at optimal capacity, calculating operating and investment costs and urban water supply. It is expected to make significant contributions to the determination of management policies. In addition, it is aimed that the outputs obtained from this study conducted for Manisa province will serve as a source for scientific studies to be conducted in other provinces in the region in the future, thus disseminating the benefits of the project outputs.

EKLER

Tablo 4. YSA(70-15-15) için Elde Edilen Model Sonuçları

Model Adı	Performans Ölçütleri								
	Eğitim			Geçerlilik			Test		
	RMSE	r	MAE	RMSE	r	MAE	RMSE	r	MAE
MLPR-1-B-R (Regression MLP)	105110,7	0,640357	85819,6	93739,21	0,347767	66563,44	68247,72	0,840004	57323,54
MLPR-2-O-M (Regression MLP)	86501,76	0,82335	70478,06	142331,2	0,045511	128533,2	198427,3	0,806494	190610,6
MLPR-2-B-R (Regression MLP)	77794,84	0,753015	59177,6	93990,05	0,369964	72921,17	108333,6	0,889217	98700,83
MLPRPC-1-O-M (Reg MLP with PCA)	88252,95	0,678219	64083,8	86371,62	0,531106	68863,79	106141,2	0,876783	92334,59
MLPRPC-1-B-R (Reg MLP with PCA)	82167,68	0,73261	64182,25	96542,47	0,125859	70726,47	115042	0,76068	100413
GFFR-1-O-M (Reg Gen Feedforward)	140953,8	0,536077	109478,1	256511,7	-0,11305	248921,3	374675,6	0,767698	371066,9
GFFR-1-B-R (Reg Gen Feedforward)	92940,63	0,705413	77628,71	140226	0,188533	118720	151653,8	0,743217	142437,6
MLPR-1-O-M (Regression MLP)	91369,88	0,86214	73075,51	269887,7	0,072576	263392	349224,3	0,93096	346821,9
LinR-0-B-R (Linear Regression)	86454,14	0,76811	67535,82	107143,3	0,163429	75456,52	92144,98	0,912498	84971,95
LinR-0-B-L (Linear Regression)	51337,14	0,899943	38469,26	332216,1	0,00137	328816,5	389651,4	0,975932	388337,7
MLPR-1-B-L (Regression MLP)	157613,8	0,696768	131993,5	73784,14	0,686818	60318,21	72705,14	0,761681	57650,47
GFFR-1-B-L (Reg Gen Feedforward)	186948,2	0,696626	157199,1	167456,3	0,504486	128069,5	176242	0,54477	143011,4
MLPRPC-1-B-L (Reg MLP with PCA)	108883,1	0,565668	90102,69	88295,21	0,72504	71971,55	77406,27	0,615859	62436,79
MLPR-2-B-L (Regression MLP)	106821,2	0,758265	80625,54	158352,2	0,249428	145768,1	124355,5	0,951477	119698,8



Tablo 5. YSA(70-20-10) İçin Elde Edilen Model Sonuçları

Model Adı	Performans Ölçütleri								
	Eğitim			Geçerlilik			Test		
	RMSE	r	MAE	RMSE	r	MAE	RMSE	r	MAE
MLPR-1-B-R (Regression MLP)	44713,9	0,93087	31531,19	241817,1	0,110355	233119,8	306875	0,89165	300653,2
MLPR-2-O-M (Regression MLP)	96368,7	0,606883	70223,44	72875,37	0,728499	57580,91	69044,03	0,891576	58675,15
MLPR-2-B-R (Regression MLP)	51337,14	0,899943	38467,98	347004,4	0,125002	343407,9	390666,6	0,976519	389117,3
MLPRPC-1-O-M (Reg MLP with PCA)	20389,67	0,985477	16625,63	182652,1	0,261114	170100,6	202806	0,453546	189017,4
MLPRPC-1-B-R (Reg MLP with PCA)	3524,264	0,999552	2482,499	88677,66	0,437935	75551,58	89112,7	0,688575	75391,18
GFFR-1-O-M (Reg Gen Feedforward)	116724	0,610057	94767,73	87798,36	0,678843	70715,44	118054,9	0,891468	103041,3
GFFR-1-B-R (Reg Gen Feedforward)	37030,5	0,954672	29795,52	122201,1	0,290534	96233,57	100638,7	-0,01231	80904,8
MLPR-1-O-M (Regression MLP)	87674,73	0,672818	66920,25	98639,21	0,419911	79217,25	124572,8	0,931993	113341,5
LinR-0-B-R (Linear Regression)	91673,61	0,810313	75806,46	126704,8	0,373888	111277,7	185357,1	0,912565	175020,2
LinR-0-B-L (Linear Regression)	80103,69	0,751278	62261,94	94464,33	0,441091	76197,67	112317,8	0,868942	97685,81
MLPR-1-B-L (Regression MLP)	88187,71	0,682819	66299,75	91500,05	0,524057	72232,31	115394,8	0,937148	98518,58
GFFR-1-B-L (Reg Gen Feedforward)	102407,2	0,696658	84140,75	106450,3	0,354134	77193,92	66021,23	0,729802	53786,86
MLPRPC-1-B-L (Reg MLP with PCA)	72424,52	0,830645	54582,9	320122,8	0,160062	311662,2	395684,6	0,960524	394686,7
MLPR-2-B-L (Regression MLP)	99605,11	0,744902	78788,45	135157,5	0,083741	109562,7	133604,9	0,708776	120072,1

Tablo 6. YSA(80-10-10) İçin Elde Edilen Model Sonuçları

Model Adı	Performans Ölçütleri								
	Eğitim			Geçerlilik			Test		
	RMSE	r	MAE	RMSE	r	MAE	RMSE	r	MAE
MLPR-1-B-R (Regression MLP)	99650,6	0,686351	80284,58	55609,6	0,759606	50140,68	60954,07	0,739202	49209,65
MLPR-2-O-M (Regression MLP)	76421,8	0,762135	59108,07	84245,18	0,937234	74631,31	88411,7	0,960046	78482,85
MLPR-2-B-R (Regression MLP)	76421,79	0,762135	59108,25	84193,15	0,937193	74574,83	88347,72	0,960023	78412,14
MLPRPC-1-O-M (Reg MLP with PCA)	32920,48	0,960383	25536,75	58752,42	0,757479	49948,89	50592,74	0,810638	42702,71
MLPRPC-1-B-R (Reg MLP with PCA)	51675	0,9429	40482,32	44676,48	0,852004	37265,89	57746,42	0,892414	52482,2
GFFR-1-O-M (Reg Gen Feedforward)	56118,71	0,880126	42609,88	51049,74	0,795125	41162,09	56992,69	0,887024	46811,14
GFFR-1-B-R (Reg Gen Feedforward)	14044,51	0,992949	11048,95	25943,75	0,956757	20914,42	83610,02	0,73213	72849,54
MLPR-1-O-M (Regression MLP)	28552,48	0,970321	21806,57	60282,28	0,791052	45205,57	77736,25	0,614973	60313,53
LinR-0-B-R (Linear Regression)	142514,4	0,723945	128014,6	59573,83	0,708522	50055,32	72340,65	0,774255	57434,51
LinR-0-B-L (Linear Regression)	115109,2	0,609767	89170,48	66616,74	0,88744	52274,53	72418,88	0,523407	58305,41
MLPR-1-B-L (Regression MLP)	102629,6	0,680956	80764,01	52678,85	0,909737	43624,74	56767,68	0,888078	42562,7
GFFR-1-B-L (Reg Gen Feedforward)	89370,83	0,688653	69030,07	90108,44	0,859063	79791,06	104554	0,917763	98778,27
MLPRPC-1-B-L (Reg MLP with PCA)	94698,24	0,690326	74361,25	56817,53	0,736939	43794,11	51296,99	0,799666	46072,8
MLPR-2-B-L (Regression MLP)	40819,41	0,938402	30595,13	40583,7	0,870927	34476,94	39021,89	0,899826	31214,74

Tablo 7. Modellerden Elde Edilen Tahminî Değerler İle Gerçek Değerler

Aylar	Gerçek değer	YSA(80-10-10)	YSA(70-20-10)	YSA(70-15-15)	Mutlak Hata
2013-1	845228,000	909516,061	929169,216	825995,237	64288,061
2013-2	889534,000	915083,418	938631,250	833843,508	25549,418
2013-3	784441,000	948053,335	933154,832	836347,005	163612,335
2013-4	935193,000	990239,812	953447,004	862208,794	55046,812
2013-5	970590,000	1038390,585	956781,030	897921,289	67800,585
2013-6	1024964,000	1072010,178	962368,979	920042,204	47046,178
2013-7	955699,000	1075038,754	954858,412	924374,807	119339,754
2013-8	1134948,000	1115428,908	975079,639	948037,465	19519,092
2013-9	950167,000	1060494,162	952182,918	896551,149	110327,162
2013-10	1020065,000	1037190,083	962770,229	869425,191	17125,083
2013-11	927867,000	1007722,092	948316,745	847082,491	79855,092
2013-12	921541,000	956338,065	924963,486	821720,452	34797,065
2014-1	921770,000	987854,967	939228,872	833555,465	66084,967
2014-2	931923,000	1006324,090	941319,380	835897,424	74401,09
2014-3	805457,000	1005922,747	930399,914	832692,995	200465,747
2014-4	981634,000	1056760,396	957178,727	865038,594	75126,396
2014-5	933581,000	1082962,485	951535,381	880049,076	149381,485
2014-6	1012985,000	1119024,252	958952,173	908125,641	106039,252
2014-7	990903,000	1131716,827	954973,408	923307,269	140813,827
2014-8	1138432,000	1175267,863	973230,083	945799,782	36835,863
2014-9	999744,000	1127727,624	958655,861	902923,124	127983,624
2014-10	1073291,000	1123292,338	969678,804	887918,393	50001,338
2014-11	882243,000	1067039,240	940800,164	840680,525	184796,24

Tablo 8. YSA(80-10-10) Ön Tahmin İçin Elde Edilen Model Sonuçları

Model Adı	Performans Ölçütleri								
	Eğitim			Geçerlilik			Test		
	RMSE	r	MAE	RMSE	r	MAE	RMSE	r	MAE
MLPR-1-B-R (Regression MLP)	20699,6	0,985697	16161,94	44540,22	0,8701	30127,47	30511,47	0,948589	26434,48
MLPR-2-O-M (Regression MLP)	72584,9	0,80323	53781,24	51221,97	0,875915	40607,08	70072,16	0,815844	57871,37
MLPR-2-B-R (Regression MLP)	72584,9	0,80323	53781,57	51219,88	0,875912	40605,4	70083,4	0,815833	57881,58
MLPRPC-1-O-M (Reg MLP with PCA)	46319,86	0,937339	38414,36	48327,63	0,84569	38750,92	94923,7	0,853774	85441,91
MLPRPC-1-B-R (Reg MLP with PCA)	31643,23	0,967113	24571,22	31557,12	0,943185	26458,89	26573,03	0,979649	21921,54
GFFR-1-O-M (Reg Gen Feedforward)	37820	0,950652	27045,7	47026,89	0,843414	38181,12	70844,19	0,632126	60638,14
GFFR-1-B-R (Reg Gen Feedforward)	16756,41	0,990522	12532,52	28729,86	0,960325	25657,79	37876,73	0,983424	32790,67
MLPR-1-O-M (Regression MLP)	27390,62	0,974484	20733,59	31619,41	0,936615	24418,83	39672,79	0,932465	32343,76
LinR-0-B-R (Linear Regression)	28824,84	0,972537	20983,59	57077,2	0,781836	44042,36	61544	0,710086	47344,19
LinR-0-B-L (Linear Regression)	30472,89	0,968242	24400,98	65922,1	0,673749	46936,19	66247,91	0,647832	50159,59
MLPR-1-B-L (Regression MLP)	57170,7	0,887819	43834,99	43904,34	0,897311	33027,51	47978,05	0,840171	37582,18
GFFR-1-B-L (Reg Gen Feedforward)	96562,25	0,689127	76076,16	85892,53	0,44575	67894,5	74002,78	0,968193	54546,44
MLPRPC-1-B-L (Reg MLP with PCA)	49113,1	0,916672	37258,67	33460,02	0,941875	29848,57	32472,51	0,929827	28725,38
MLPR-2-B-L (Regression MLP)	91407,12	0,716178	69576,24	69646,49	0,633526	58206,78	59701,94	0,755018	46273,79



Tablo 9. YSA(70-20-10) Ön Tahmin İçin Elde Edilen Model Sonuçları

Model Adı	Performans Ölçütleri								
	Eğitim			Geçerlilik			Test		
	RMSE	r	MAE	RMSE	r	MAE	RMSE	r	MAE
MLPR-1-B-R (Regression MLP)	102857,3	0,691502	77806,01	57937,66	0,750185	43551	67999,26	0,704391	52946,95
MLPR-2-O-M (Regression MLP)	104228,9	0,624366	80993,05	63925,46	0,759867	51360,82	79991,16	0,703822	65578,65
MLPR-2-B-R (Regression MLP)	75522,84	0,760188	57658,07	68817,37	0,880305	55803,32	44627,66	0,853674	33250,7
MLPRPC-1-O-M (Reg MLP with PCA)	42384,01	0,931269	31542,15	63275,65	0,673032	50107,16	104026,1	0,341215	94747,55
MLPRPC-1-B-R (Reg MLP with PCA)	81518,39	0,774276	68331,1	77723,97	0,832937	65164,87	139984,8	0,842464	133116,4
GFFR-1-O-M (Reg Gen Feedforward)	60087,54	0,860271	46482,31	61449,43	0,77145	52915,13	86482,64	0,498536	73623,51
GFFR-1-B-R (Reg Gen Feedforward)	37820,87	0,945629	29287,88	57984,38	0,734009	45044,16	71396,05	0,526761	53953,6
MLPR-1-O-M (Regression MLP)	118682,6	0,609222	96893,93	71352,96	0,672844	56729,93	87563,32	0,327964	76138,24
LinR-0-B-R (Linear Regression)	89235,79	0,674115	69273,42	67128,61	0,751167	51189,15	79859,73	0,707345	63908,03
LinR-0-B-L (Linear Regression)	24244,82	0,978092	18860,22	62340,7	0,758949	43529,29	80505,1	0,486353	65760,46
MLPR-1-B-L (Regression MLP)	71277,74	0,793669	54911,04	50737,83	0,807353	41296,71	70612,86	0,581405	59764,94
GFFR-1-B-L (Reg Gen Feedforward)	101929,2	0,68762	81809,76	89536,79	0,890001	80676,36	116958	0,870692	109985,6
MLPRPC-1-B-L (Reg MLP with PCA)	96257,98	0,703957	73572,81	46835	0,835878	37703,45	50698,52	0,801389	38775,47
MLPR-2-B-L (Regression MLP)	57849,25	0,868077	43923,5	88336,35	0,742572	75010,23	90776,17	0,598235	66525,07

Tablo 10. YSA(70-15-15) Ön Tahmin İçin Elde Edilen Model Sonuçları


Model Adı	Performans Ölçütleri								
	Eğitim			Geçerlilik			Test		
	RMSE	r	MAE	RMSE	r	MAE	RMSE	r	MAE
MLPR-1-B-R (Regression MLP)	63338,44	0,87509	52416,51	53444,04	0,756413	42502,41	70948,14	0,581457	55439,31
MLPR-2-O-M (Regression MLP)	101508,3	0,623976	80337,2	61497,77	0,702968	44027,59	74269,17	0,642065	56345,04
MLPR-2-B-R (Regression MLP)	75162,16	0,760761	57147,62	69697,63	0,851977	55968,73	52525,31	0,8298	40871,47
MLPRPC-1-O-M (Reg MLP with PCA)	36412,09	0,950486	28978,78	43873,59	0,816344	32477,06	79081,38	0,584729	64692,63
MLPRPC-1-B-R (Reg MLP with PCA)	74147,87	0,800931	58001,65	73762,05	0,744274	60720,51	85271,7	0,634401	71486,63
GFFR-1-O-M (Reg Gen Feedforward)	52954,83	0,889387	38268,84	46037,89	0,827044	37639,96	92678,16	0,562573	79922,56
GFFR-1-B-R (Reg Gen Feedforward)	30941,89	0,966813	22873,86	47064,66	0,785423	39493,74	87322	0,803031	73914,57
MLPR-1-O-M (Regression MLP)	95634,27	0,729172	78486,68	80339,78	0,746706	64139,26	91339,9	0,874969	78446,3
LinR-0-B-R (Linear Regression)	93923,92	0,660564	73982,82	53431,93	0,871227	43711,51	67041,84	0,776142	52571,3
LinR-0-B-L (Linear Regression)	124648,4	0,701695	101893,7	46998,14	0,8221	34357,24	68179,41	0,756816	52416,97
MLPR-1-B-L (Regression MLP)	43327,3	0,934136	35400,51	36826,89	0,894925	29995,7	54516,26	0,890717	39216,44
GFFR-1-B-L (Reg Gen Feedforward)	106670,2	0,711822	80931,17	50009,35	0,894555	42285,46	69803,16	0,866412	57896,82
MLPRPC-1-B-L (Reg MLP with PCA)	67582,38	0,821842	51237,74	32135,35	0,941642	24822,12	43914,58	0,972782	37197,36
MLPR-2-B-L (Regression MLP)	43199,09	0,92783	33825,15	98731,4	0,608805	81984,03	104226	0,670981	90359,57



Tablo 11. Modellerden Elde Edilen Ön Tahmin Değerleri

Aylar	YSA(80-10-10)	YSA(70-15-15)	YSA(70-20-10)	Aylar	YSA(80-10-10)	YSA(70-15-15)	YSA(70-20-10)
2014-12	1114290,735	1003167	1071757	2017-1	1286144,719	967772,3	1043078
2015-1	1066499,91	972068,9	1004526	2017-2	1323451,911	979470,4	1073615
2015-2	1108945,502	962650	995339,9	2017-3	1192714,341	875658,1	1005271
2015-3	994578,9893	887337,4	955891,6	2017-4	1321768,021	953239	1064647
2015-4	1125348,838	959689,6	1004830	2017-5	1345390,352	976073,4	1088698
2015-5	1108702,454	979122,7	1037684	2017-6	1414972,598	1027078	1132420
2015-6	1186447,276	1027612	1079499	2017-7	1406820,695	1017952	1125982
2015-7	1163662,755	1019977	1070088	2017-8	1532538,343	1098481	1180034
2015-8	1249431,289	1097423	1133690	2017-9	1432024,634	1033266	1139884
2015-9	1206732,98	1045478	1084442	2017-10	1458827,85	1058290	1158368
2015-10	1194494,587	1042982	1102465	2017-11	1385206,274	996195,1	1129376
2015-11	1137426,098	990122,2	1077013	2017-12	1452355,78	1046883	1157246
2015-12	1251195,377	1014698	1062170	2018-1	1375394,509	988293,6	1102708
2016-1	1119358,664	979202,5	1039378	2018-2	1430004,908	1013406	1141406
2016-2	1216479,748	965511,5	1039639	2018-3	1278935,195	895790,5	1065151
2016-3	1051042,057	877736,6	1002256	2018-4	1410686,842	972675,1	1125561
2016-4	1219148,916	955583	1040026	2018-5	1447961,601	1004390	1151450
2016-5	1206758,934	983118,3	1069091	2018-6	1515835,619	1055407	1193418
2016-6	1305084,272	1046263	1108027	2018-7	1513429,669	1046886	1188155
2016-7	1295703,974	1034545	1098728	2018-8	1638205,5	1124820	1245421
2016-8	1396865,36	1085960	1151908	2018-9	1536222,608	1062675	1202079
2016-9	1313069,483	1035476	1112261	2018-10	1567642,796	1090890	1225001
2016-10	1344672,946	1040418	1120448	2018-11	1489998,741	1027854	1196278
2016-11	1239662,158	1001606	1108635	2018-12	1564226,135	1084593	1227009
2016-12	1363524,658	1044744	1102643				

Şekil 5. Modellerden Elde Edilen Ön Tahmin Değerleri



Şekil 6. En Uygun Modelden Elde Edilen Örneklem-İçi Ve Örneklem-Dışı (2014M12-2018M12) Tahmin Değerler

