

**AVRUPA BİRLİĞİ ÜLKELERİ İÇİN VERİ İŞLEME GRUP YÖNTEMİ (GMDH) tipi  
SİNİR AĞI İLE NÜFUS TAHMİNİ**

POPULATION FORECAST WITH THE DATA PROCESSING GROUP METHOD  
(GMDH) type NEURAL NETWORK FOR EUROPEAN UNION COUNTRIES

**Eda FENDOĞLU**

Dr. Öğr. Üyesi, Malatya Turgut Özal Üniversitesi, Sosyal ve Beşeri Bilimler Fakültesi,  
Uluslararası İşletme Yönetimi Bölümü  
ORCID ID: 0000-0003-4092-7137

**Abstract**

Population is a critically important factor in a country's planning, policy making, and setting its social and economic goals. Population estimation and planning in advance are of great importance for policy makers, since the natural resources, which are the production areas where people can meet their basic needs, are limited and they need to protect the areas they live in in order to continue their lives. In this study, the Group Method of Data Handling (GMDH) type Neural Network (NN) approach was used for the annual population estimation of 27 European Union (EU) countries (Germany, Austria, Belgium, Bulgaria, Czech Republic, Denmark, Estonia, Finland, France, Cyprus, Croatia, Netherlands, Ireland, Spain, Sweden, Italy, Latvia, Lithuania, Luxembourg, Hungary, Malta, Poland, Portugal, Romania, Slovenia, Slovak Republic, Greece). The data set was obtained from the World Data Bank and analyzed using data from the years 1960 - 2020. The test performances obtained are generally below 10% of the Root Mean Square Percentage Error (RMSPE). The coefficient of determination ( $R^2$ ) is above 0.90 and generally around 0.99. In addition, the mean absolute percentage error (MAPE) value is below 10%. According to these values, it is concluded that the model predicts extremely accurately. In addition, the analysis was compared with the 2021 - 2032 forecast values in the World Bank Database. According to the findings and comparison results, it has been concluded that the GMDH type Neural Network is a very good approach for the annual population estimation of 27 EU countries, it has almost exactly the same results with the real values in the past years, therefore it is consistent and successful in its predictions for the future years.

**Keywords:** Population, Forecasting, Group Method of Data Processing (GMDH) Neural Network, Artificial Neural Network, Time Series Analysis.

**Özet**

Nüfus, bir ülkenin planlamasında, politika oluşturmasında, sosyal ve ekonomik hedeflerini belirlenmesinde kritik derecede önemli bir faktördür. Yeryüzünde insanların temel ihtiyaçlarını giderecekleri üretim alanı olan doğal kaynakların kısıtlı olması ve yaşamlarını devam ettirebilmeleri için yaşadıkları alanları korumaları gerekliliği nedeniyle bir ülkenin politika yapıcıları için nüfus tahmini ve gerekli planlamaların önceden yapılması büyük bir öneme sahiptir. Bu çalışmada 27 Avrupa Birliği (AB) ülkelerinin (Almanya, Avusturya,

Belçika, Bulgaristan, Çek Cumhuriyeti, Danimarka, Estonya, Finlandiya, Fransa, Kıbrıs, Hırvatistan, Hollanda, İrlanda, İspanya, İsveç, İtalya, Letonya, Litvanya, Lüksemburg, Macaristan, Malta, Polonya, Portekiz, Romanya, Slovenya, Slovak Cumhuriyeti, Yunanistan) yıllık nüfus tahmini için Veri İşleme Grup Yöntemi (Group Method of Data Handling-GMDH) tipi Sinir Ağı (Neural Network-NN) yaklaşımı kullanılmıştır. Veri seti Dünya Veri Bankasından elde edilmiş olup 1960 - 2020 yıllarına ait veriler kullanılarak analiz yapılmıştır. Elde edilen test performansları, genel olarak ortalama yüzde karekök hatası (Root Mean Square Percentage Error-RMSPE) için %10 altındayken ve belirleme katsayısı ( $R^2$ ) için 0.90 üzeri hatta genel olarak 0.99 civarındadır. Ayrıca, ortalama mutlak yüzde hatası (Mean Absolute Percentage Error-MAPE) değeri ise %10'un altındadır. Bu değerlere göre modelin son derece doğru tahmin ettiği sonucuna ulaşılmaktadır. Ayrıca yapılan analiz Dünya Bankası Veri tabanında bulunan 2021 - 2032 tahmin değerleri ile de karşılaştırılmıştır. Elde edilen bulgular ve karşılaştırma sonuçlarına göre GMDH tipi Sinir Ağı'nın 27 AB ülkesinin yıllık nüfus tahmini için çok iyi bir yaklaşım olduğu geçmiş yıllardaki gerçek değerlerle neredeyse birebir sonuç elde ettiği, bu nedenle gelecek yıllar için elde edilen tahminlerinde tutarlı ve başarılı olduğu sonucuna varılmıştır.

**Anahtar Kelimeler:** Nüfus, Tahmin, Veri İşleme Grup Yöntemi (GMDH) Sinir Ağı, Yapay Sinir Ağı, Zaman Serisi Analizi.

## 1. GİRİŞ

Dünya nüfusunun sürekli artması ve artan kentleşme süreci, dünya çapında çevre kalitesine ve sürdürülebilir kalkınmaya meydan okumaktadır (Zhang, 2008:717). Nüfus artışı insan kaynağı arzını direkt olarak etkileyen üretim için son derece önemli olan temel faktörlerdendir. Nüfus artışı ve ekonomik performans arasındaki ilişkinin olumlu olarak tanımlanabileceği gelişmekte olan ülkelerde, demografik eğilimler ekonomik kalkınmayı teşvik etmekte ve yaşam standartlarında bir yükselmeyi teşvik etmektedir. Bunun nedeni, nüfus artışının ticari faaliyetlerde rekabeti teşvik etmesi ve ülke nüfusu arttıkça potansiyel pazarının boyutunun da genişlemesidir. Pazarın genişlemesi de girişimcileri yeni işler kurmaya teşvik etmektedir (Furuoka, 2009:1). Kısacası, nüfus artışı bir ülkenin ekonomik büyümesi/kalkınması için en önemli belirleyicilerden birisidir. Bu nedenle ülkelerdeki politika yapıcıların nüfus tahmini yapmaları o ülke için kritik öneme sahiptir.

Geweke ve Whiteman'ın (2006) belirttiği gibi, tahmin, kişinin eldeki bilgiyi olayların olası gidişatı hakkında açıklamalar yapmak için kullanması veya bildiğimiz şeye bağlı olarak gelecekteki sonuçları tahmin etmek için farklı bir şekilde ifade etmesi anlamına gelmektedir. Nüfus tahminine Bayesci yaklaşım, Bayes hiyerarşik modeli hızla zemin kazandırmaktadır (Gerland ve vd., 2014). Model, tüm ülkeler için tek bir modeli dikkate aldığı için "hiyerarşiktir", ancak model yapısında bir "hiyerarşiye" yol açan ülkeye özgü parametreler vardır. Günümüzde, birkaç algoritma (Markov Chain Monte Carlo (MCMC), Hamiltonian Monte Carlo, Variational Bayes gibi) hızlı çözümlere izin vermektedir. Nüfus büyüklüğü, yaş yapısı, bölgesel dağılım ve diğer demografik değişkenlerdeki gelecekteki eğilimler, çok çeşitli planlama durumları için büyük önem taşımaktadır. Demografik projeksiyonlar ve tahminler, nüfus büyüklüğü, yani doğumlar ve doğurganlık, ölümler ve ölüm oranı ve bir

ülkenin bütünü için nüfusta ilgi olduğunda uluslararası göç için değişimin bileşenleri için gelecekteki gelişmelerin varsayımlarına dayanmaktadır. Gelecekteki demografik eğilimlerde içgörünün önemi göz önüne alındığında, birçok istatistik kurumu rutin olarak ulusal nüfus tahminlerini hesaplamaktadır. Nüfus tahminlerini hesaplayan dünyadaki çoğu istatistik kurumu bunu deterministik bir yaklaşım kullanarak yapmaktadır. Yani, nüfus tahmininde standart yaklaşım haline gelen kohort bileşen modeli aracılığıyla yapmaktadırlar (Ulusal Araştırma Konseyi – NRC 2000; UNECE 2018). Bu model, doğurganlık, ölüm oranı ve uluslararası göçün gelecekteki eğilimleri hakkında varsayımlar gerektirmektedir. Nüfus tahmincileri, demografik bileşenlerin gelecekteki yörüngelerine ilişkin varsayımlarını formüle ederken genellikle uzmanların görüşlerine güvenmektedirler. Bununla birlikte, bazı durumlarda bu yörüngeler tamamen veriye dayanmaktadır. Olasılıksal nüfus tahmini, son zamanlarda araştırmacılardan ve daha az bir ölçüde, geleneksel olarak nüfus projeksiyonlarını deterministik olarak türeten resmi kurumlardan artan bir ilgi görmektedir. Olasılığa dayalı nüfus tahmini için çeşitli yöntemler 1960'lı yıllardan itibaren geliştirilmiştir, ancak Törnquist (1949) muhtemelen olasılıkçı düşüncüyü nüfus tahminine ilk entegre eden kişi olmuştur. Bu yaklaşımda, doğurganlık ve ölüm oranları ile göç parametreleri rastgele değişkenler olmaktadır. Lutz ve Scherbov (1998) uzman yargısına dayalı bir olasılıksal yöntem önerene kadar, uzman görüşüne dayalı yöntemler genellikle deterministik yöntemlerin eş anlamlısı olarak anılmaktaydı. Bununla birlikte, olasılıklı bir yaklaşım kullanılması durumunda bile, uzmanlara dayalı yöntem hala kullanılmaktadır, ancak rastgele değişkenlik ve belirsizlik niceleme sağlayan istatistiksel modellere entegre edilmiştir. Örneğin, Birleşmiş Milletler nüfus tahminleri hala güçlü bir şekilde uzmanların görüşlerine dayanmaktadır ve demografik geçiş teorisine dayalı olarak, BM Dünya Nüfus Beklentileri (Birleşmiş Milletler 2017) tüm ülkelerin ölüm, doğurganlık ve göç oranlarının eninde sonunda birbirine yaklaşacağını öne sürmektedir (Mazzuco ve Keilman, 2020:1-10, Graziani, 2020:21).

Grup Veri İşleme Yöntemi (GMDH), tümevarımsal kendi kendine organizasyon veri odaklı yaklaşımlar kategorisine aittir. Küçük veri örnekleri gerektirir ve modellerin yapısını objektif olarak optimize edebilir (Anastasakis ve Mort, 2001:1). GMDH algoritması, 1968 yılında Kiev Ukrayna'daki Sibernetik Enstitüsü'nde Prof Ivakhnenko tarafından oluşturuldu. Bu yaklaşım en başından beri bilgisayar tabanlı bir yöntemdi, bu nedenle bir dizi bilgisayar programı ve algoritması, yeni teorik ilkeler temelinde elde edilen birincil pratik sonuçlardı. GMDH'nin Sovyetler Birliği dışında ilk araştırması 1972'de R. Shankar tarafından yapıldı. Daha sonra, Japon ve Polonyalı bilim adamları tarafından farklı GMDH'ın çeşitleri araştırıldı ve yayınlandı. 1994'ten beri; Hibrit GMDH algoritmaları (genetik programlama (GP), genetik algoritma (GA), diferansiyel evrim (DE), parçacık sürüsü optimizasyonu (PSO) ve adaptif model evrimi (GAME) grubuna dayalı) geliştirilmiş ve incelenmiştir. GMDH geliştirmenin mevcut aşaması, çok işlemcili bilgisayarlar için daha sağlam hibrit GMDH algoritmalarının ve paralel algoritmaların gerçekleştirilmesi olarak tanımlanabilir (Onwubolu, 2014: 2-3).

GMDH tarafından çözülebilen temel problemler şöyledir; fiziksel yasaların tanımlanması, çok boyutlu süreçlerin yaklaşımı, süreçlerin ve olayların kısa vadeli kademeli tahmini, uzun vadeli adım adım tahmin, fiziksel alanların ekstrapolasyonu, veri örneklerinin kümelenmesi ve bir nesnenin fiziksel modeline karşılık gelen fiziksel bir kümelemenin

aranması, sürekli veya ayrık değişkenler durumunda örüntü tanıma, olasılıksal sıralama algoritmalarını kullanarak teşhis ve tanıma, aktif nöronlarla çok katmanlı sinir ağlarının kendine organizasyonu, süreçlerin normatif vektör tahmini, analog kompleksi kullanan modeller olmadan süreç tahmini. GMDH teorisinin ana sonucu, hatalı gürültülü veriler ve kısa örnekler için minimum kriterinin doğruluğu daha yüksek ve yapısı tam bir fiziksel modelden daha basit olan fiziksel olmayan bir modeli (karar kuralı) göstermesidir. Aktif nöronlara sahip sinir ağı, doğruluğu daha da, sınırların ötesinde geliştirmenin ve regresyon alanının genişlemesi nedeniyle uzun vadeli tahminlerin sağlama süresini artırmanın bir yolu olarak kabul edilmektedir (Ivakhnenko ve Ivakhnenko, 1995:1).

GMDH tipi sinir ağı, geleneksel Çok Katmanlı Yinelemeli GMDH algoritmasının (MIA) varyasyonu ile çok katmanlı yinelemeli sinir ağıdır. Çok katmanlı iki girdili nöronlara sahip ileri beslemeli bir sinir tarafından uygulanmaktadır (Li ve vd., 2017: 130). GMDH tipi Sinir Ağı'nın (GMDH-NN) eğitim prosedürü, geleneksel sinir ağından farklı olarak evrimsel mekanizmaya dayanmaktadır. Temelde ileri beslemeli ve çok katmanlı bir sinir ağı olan GMDH tipi NN, çeşitli mühendislik problemlerine uygulanmıştır (Akkaya, 2021:54). GMDH Sinir Ağı, önemli sayıda katmandan oluşan ve her katmanda birçok nöron bulunduran, otomatik olarak organize edilen ve tek yönlü bir ağıdır (Anastasakis ve Mort, 2001). Tüm nöronlar, iki girdi ve bir çıktıya sahip oldukları için benzer yapılara sahiptir (Moradi ve vd., 2015:32).

Bu çalışmada da 27 AB ülkeleri için yapay sinir ağı temelli GMDH tipi Sinir Ağı yöntemi ile nüfus tahmini yapılmak istenmiştir. Bu nedenle analizde kullanılan 1960-2020 yıllarına ait gerçek veriler Dünya Bankası veri tabanından elde edilmiştir. Çalışmada önce GMDH yöntemi ile yapılan çalışmalar ve nüfus tahmini üzerine yapılan çalışmalar olmak üzere iki kısımda geniş bir literatür taraması yapılmıştır. Sonra çalışmanın veri seti ve yöntemi tanıtılmış olup daha sonra analizden elde edilen ampirik bulgular tablolar ve grafiklerle paylaşılmıştır. En sonda da sonuç ve öneriler kısmı paylaşılarak çalışma tamamlanmıştır.

## 2. LİTERATÜR TARAMASI

Literatürde nüfus artış tahmini ve üzerine ampirik çok fazla çalışma bulunmaktadır. Özellikle bir ülkenin nüfus artışı o ülkenin ekonomik kalkınması üzerinde çok önemli bir faktördür. Bir ülkenin politika yapıcıları ekonomik büyüme/kalkınma politikalarını belirlerken nüfus politikalarına da önemli bir yer ayırmaktadırlar. Bu nedenle ülkelerin nüfus tahminlerine yönelik araştırmaları yapmak için belirledikleri devlet planlama teşkilatları, istatistik kurum merkezleri bulunmaktadır. Bu çalışma da AB Birliği ülkeleri için Veri İşleme Grup Yöntemi (GMDH) ile nüfusları tahmin edilmeye ve Dünya Bankası tahmin verileri ile karşılaştırılmaya gidilmiştir. Literatürde bu yöntem ile böyle bir tahmin çalışmasına rastlanmadığından literatür taraması GMDH yöntemi ile yapılan çalışmalar ve nüfus tahmini üzerine yapılan çalışmalar olmak üzere iki bölümde ele alınmıştır.

### 2.1.GMDH İle Yapılan Çalışmalar;

GMDH algoritması, 1968 yılında Kiev, Ukrayna'daki Sibernetik Enstitüsü'nde Prof Ivakhnenko tarafından oluşturuldu. Bu yaklaşım en başından beri bilgisayar tabanlı bir

yöntemdi, bu nedenle bir dizi bilgisayar programı ve algoritması, yeni teorik ilkeler temelinde elde edilen birincil pratik sonuçlardı. GMDH'nin Sovyetler Birliği dışında ilk araştırması 1972'de R. Shankar tarafından yapıldı. Daha sonra, Japon ve Polonyalı bilim adamları tarafından farklı GMDH varyantları araştırılmış ve yayınlanmıştır (Onwubolu, 2014:2).

Farlow (1981) çalışmasında, 1966'da Rus sibernetikçi A.G. Ivakhnenko'nun yüksek dereceli regresyon tipi bir polinom oluşturmak için bir teknik tanıttığını, algoritma, Veri İşleme Grup Yöntemi (GMDH), yüzlerce dereceli birçok terim oluştururken, standart çoklu regresyon hesaplama ve doğrusal bağımlılıkta çıkmaza girdiğini ve GMDH yönteminin araştırmacının yalnızca yüksek dereceli bir girdi-çıkı ilişkisi elde etmekle ilgilendiği karmaşık, yapılandırılmamış sistemler için ideal olduğunu, ayrıca, Ivakhnenko'nun algoritmasının doğası gereği sezgisel ve regresyon analizi gibi sağlam bir temele dayanmadığından bahsetmiştir.

Ivakhnenko ve Ivakhnenko (1995) bu çalışmada, deneysel veri işlemenin çeşitli problemlerini çözmeye Grup Veri İşleme Yöntemi (GMDH) algoritmalarının kullanımını açıklamışlardır. Farklı uygulamalar için GMDH algoritmalarını göstermeyi amaçlamışlardır.

Anastasakis ve Mort, (2001) yaptıkları çalışmada, GMDH geliştirmenin aşamaları ve geniş bir GMDH algoritması yelpazesi ve çeşitli uygulamaları incelemişlerdir. Ayrıca GMDH'de önemli bir özellik olan dış kriterler üzerine özel bir çalışma da sunmuşlar ve sinir ağları ve GMDH algoritmaları arasındaki bazı önemli farklılıklar tartışmışlardır.

Chen ve Xu (2006) çalışmada, bir ilçe için iyi durumdaki inşaatları etkileyen faktörler analiz edilerek, etkileyen faktörlerin çoğunun ekonomik, sosyal ve çevre dostu olarak nitelendirildiği iyi durumda inşaat için bir değerlendirme indeksi oluşturmuşlardır, bunun için yapay zeka yöntemi ve kapsamlı entegre araştırmalar yapmışlardır. Yaptıkları araştırma sonuçları, bu yöntemle elde ettiğimiz modellerin oldukça etkili olduğunu ve birçok faydalı bilgiyi içerdiğini göstermiştir. Araştırmada GMDH'nin ekonomik sistemde iyi bir uygulamaya sahip olduğuna dair kanıt elde etmişlerdir.

Zhang ve diğerleri (2012) bu çalışmada, gürültü bağımsızlığı yeteneğini geliştirmek için çeşitlilik kavramını GMDH'ye getirerek, D-GMDH olarak adlandırılan yeni bir tür GMDH tahmin modeli oluşturmak için harici kriterler olarak beş çeşitlilik metriği kullanmışlardır. D-GMDH'nin etkinliğini değerlendirmek için bunları geleneksel GMDH yöntemi, otoregresif tümlşik hareketli ortalama (ARIMA) ve yapay sinir ağı (ANN) ile karşılaştırmışlardır ve iki modelin D-GMDH (chi) ve D-GMDH ( cor) beş D-GMDH modeli arasında diğerlerinden daha iyi olduğu sonucuna varmışlardır. Elde ettikleri sonuçlar, önerilen iki yeni modelin gürültülü ortamlarda yüksek tahmin doğruluğu sağlayabildiğini göstermiştir.

Fallahi ve diğerleri (2014) bu çalışmada, çimento sektörünün hisse senedi fiyat tahmini için GMDH tipi bir sinir ağı ve genetik algoritma geliştirmişlerdir. Tahran borsasından (TSE) on çimento şirketinin on yıllık (1999-2008) aralığındaki verileri kullanmışlardır. Çalışma analizinden elde ettikleri bulguların deneysel sonuçlarla uyumlu olduğu sonucuna varmışlardır.

Ahmad ve diğerleri (2014) yaptıkları bu çalışmada, destek vektör makinesi (SVM) ve yapay sinir ağları (ANN) gibi yapay zekâ (AI) yöntemlerini kullanan bina elektrik enerjisi tahmin yöntemini incelemişlerdir. Yazarlar iki tahmin yönteminin hibridizasyonu, daha doğru

sonuçlar için uygulanma potansiyeline sahip olduğunu düşünmüşlerdir. Bu incelemede önerilen GMDH ve LSSVM (Least Square Support Vector Machine) GLSSVM'nin hibrit modeli, bu iki yöntemin diğer zaman serisi tahmin alanlarında başarılı bir şekilde uygulanmasıyla ilgili olarak tahminde parlak bir potansiyele sahip olmuştur. GLSSVM kullanarak tahmin yapma potansiyeli, GLSSVM'nin binanın elektrik enerjisi tüketimine analizi yapılarak değerlendirilecektir. Tahmin sonuçlarının RMSE (Root Mean Square Error) ve korelasyon katsayısı gibi hata analizleri kullanılarak değerlendirildiği bu çalışmada, tahmin analizinin kesinliğine öncelik verilmiştir.

Ahmedi ve diğerleri (2015) çalışmada, deneysel veriler kullanılarak tork ve güç dağılımı belirlemek istemişlerdir. Spesifik olarak, önceki deneysel çalışma temelinde tork ve gücü belirlemek için yeni bir polinom yaklaşımı önermişlerdir. Belirlenen parametrelere dayalı olarak tork ve gücü tahmin etmek için GMDH (grup veri işleme yöntemi) tipi sinir ağlarının kullanılıp kullanılmayacağı sorusunu ele almışlardır. Yaptıkları testlere göre GMDH yaklaşımı, enerji uzmanlarının yüksek düzeyde performans, güvenilirlik ve sağlamlık ve düşük derecede belirsizlik ile Stirling ısı motorları tasarlamasına yardımcı olabileceği sonucuna varmışlardır.

Moradi ve diğerleri (2015) bu çalışmada, GMDH sinir ağı ve Çok Katmanlı Algılayıcı Sinir Ağı (MLP) kullanılarak altın fiyatı tahmin modellemesinin yanı sıra performans değerlendirme kriterleri kullanılarak üst modelin belirlenmesini amaçlamışlardır. Yaptıkları araştırmada, söz konusu aralık için altın fiyatı üzerinde etkili olan sekiz endeksin haftalık ortalamalarını seçmişlerdir. GMDH sinir ağından elde edilen performans değerlendirme kriterlerinin iyi ve kabul edilebilir sonuçlar olduğunu tespit etmişlerdir.

Ghazanfari ve diğerleri (2017) çalışmada, betonun karma tasarımını etkileyen çok sayıda parametre ve test numunelerinin sayısındaki azalma göz önüne alındığında, günümüzde ilişkileri keşfetmek, mekanik özellikleri tahmin etmek ve beton karışımlarını optimize etmekle birlikte doğrusal olmayan kalıpları belirlemek için teorik temeli olmayan ve tersine mühendislik (IE) veya kara kutu modelleri olarak bilinen (Çok Katmanlı Algılayıcı /Multi-Layer Perceptron) MLP ve (Veri İşleme Grup Yöntemi/Group Method of Data Handling) GMDH yapay sinir ağlarını kullanmışlardır. Yapılan araştırmada GMDH modelinin performansı, laboratuvar sonuçlarını tahmin edilen değerlerle karşılaştırırken, bu modelin basınç dayanımı ve çökme değerlendirmesinde kabul edilebilir doğruluğunu ortaya çıkarmışlardır.

Li ve diğerleri (2017) bu çalışmada, Gayrimenkul Yatırım Ortaklıkları (GYO- Real estate investment trusts (REITs)) fiyatlarının ve hisse senedi endekslerinin tahmini için Grup Yöntemi Veri İşleme Sinir Ağı yaklaşımını kullanmışlardır. Yaptıkları analiz ile elde ettikleri bulgulara göre GMDH sinir ağının Tek Üstel Düzgün, Çift Üstel Düzgün, ARIMA ve geri yayımlı sinir ağı gibi klasik tahmin algoritmalarından daha iyi performans gösterdiği sonucuna varmışlardır.

Jia ve diğerleri (2018) çalışmada, Sanal metroloji (VM) yarı iletken üretimi için grup veri işleme (GMDH) tipi polinom sinir ağlarına dayalı bir uyarlamalı metodoloji önermişlerdir. Önerilen metodolojinin etkinliğini göstermek için, yarı iletken imalatında kimyasal-mekanik düzlemselleştirme süreci için malzeme kaldırma oranını tahmin etmek için

prognostik ve sađlık ynetimi (PHM) veri zorluđu 2016'dan alınan veri setini kullanmışlardır. Elde ettikleri sonuçları birkaç aday yöntemle karşılaştırıldığında dođruluđu arttığını, nerilen yntemin yarı iletken retiminde sanal metroloji iin etkili bir ara olabileceđi sonucuna varmışlardır.

Rezaei ve diđerleri (2018) alıřmada, eřitli yakıtların, yenilenebilir enerjilerin ve GSYİH'nın tketiminin bir fonksiyonu olarak CO2 emisyonunu modellemek iin Grup veri iřleme yntemi (GMDH) uygulamışlardır. Elde ettikleri verilere gre GMDH'nin CO2 emisyonunu tahmin etmek iin uygun bir yaklařım olduđu sonucuna varmışlardır.

elik (2019) alıřmasında, GMDH yntemi algoritması ile 2010-2019 yılları arasındaki 3253 gnlk Bitcoin kapanıř fiyatları analiz edilerek son 35 gnlk fiyatlar Bitcoin fiyatlarını tahmin etmeyi amalamıştır. GMDH yntemi ile elde ettiđi sonuçlar diđer yntemlere gre daha iyi performans sergilediđi sonucuna ulařmıştır.

Adeyinka ve Muhajarine (2020) alıřmasında, 1964'ten 2017'ye kadar Nijerya'daki yıllık U5MR'nin tarihsel veri seti, Dnya Bankası'nın resmi web sitesinden elde etmişlerdir. 2030 yılına kadar (Srdrlebilir Kalkınma Hedefi dneminin sonu) lm oranlarını tahmin etmek iin her tahmin yntemi iin en uygun modelleri kullanmışlardır.  yntemin tahmin performansları, ortalama karesel hatalar (RMSE), kk ortalama mutlak hata (RMAE) ve modifiye Nash-Sutcliffe verimlilik (NSE) katsayısına dayalı olarak deđerlendirmişlerdir. ARIMA ve Holt-Winters modellerinin her birine kıyasla GMDH-tipi YSA modelinin tahminleri arasındaki kayıp fonksiyonunda istatistiksel olarak anlamlı farklılıklar, Diebold-Mariano (DM) testi ve Deming regresyonu ile deđerlendirmişlerdir. GMDH tipi sinir ađı, ARIMA ve Holt-Winters modellerine kıyasla Nijerya iin beř yař altı lm oranlarını tahmin etme ve tahmin etmede daha iyi performans gsterdiđi sonucuna varmışlardır.

Akkaya (2021) alıřmasında, 2003-2018 dnemi iin aylık elektrik talebini ieren byk bir veri seti kullanılarak orta vadede Trkiye'nin aylık elektrik talebi iin dođrusal olmayan bir zaman serisi tabanlı tahmin modelini yapılandırmak iin Grup Veri İřleme Yntemi (GMDH) tipi Sinir Ađı (NN) yaklařımı kullanmıştır. Yazar analizden elde ettiđi bulgular dođrultusunda geliřtirilen modelin gerek deđerlere ok yakın olduđu sonucuna varmıştır.

## 2.2.Nfus Tahmini İle Yapılan alıřmalar;

Smith (1987) yaptıđı alıřmasında, Amerika Birleřik Devletleri'ndeki 2.971 ile iin nfus projeksiyonlarının tahmin dođruluđu ve nyargısı ile ilgilenmiştir. Tahmin hatalarının boyutu, yn ve dađılımı, yerin byklđine, byme hızına ve projeksiyon ufkunun uzunluđuna gre analiz etmişlerdir. Analizden nfus tahmin hataları ile temel nfusun byklđ, baz dnemindeki byme hızı ve projeksiyon ufkunun uzunluđu arasında birkaç gl iliřkiyi tespit etmişlerdir.

Shen ve Spence (1997) bu alıřmada, bir dizi ok blgeli nfus hesabı temelinde ileriye dnk demografik oranlara dayalı ok blgeli bir nfus modeli geliřtirmişler ve bu modeli, 1987-2087 dnemi iin in'in eyalet dzeyinde tutarlı ok blgeli nfus projeksiyonlarını yapmak iin kullanmışlardır. Elde ettikleri bulgular dođrultusunda Ulusal nfus eđiliminin, eřitli blgesel nfus eđilimlerinin bir kombinasyonu olduđu sonucuna varmışlardır.

Tayman ve Swanson (1999) bu çalışmada, nüfus tahminlerinin doğruluğunu değerlendirmek için en sık kullanılan özet ölçümü olan Ortalama mutlak yüzde hatası (MAPE)'nin normatif olarak geçerlilik kriterini karşılamadığını savunmuşlardır. Değerlendirme araç setine Mestimators'ı dahil edilmesi gerektiğini savunmuşlardır. Ayrıca M-tahmin edicileri, MAPE'nin yanı sıra istenen yorumlama kolaylığı kriterini karşılamadığından, hata dağılımının doğrusal olmayan dönüşümlerine odaklanan başka bir yaklaşımda önermişlerdir.

Zhang (2008) çalışmasında, son demografik eğilimlere dayalı olarak, dünya çapında yakın gelecekteki kentleşme ile ilgili nüfus artışının bir tahmin analizini yapmaya çalışmıştır. Nüfus dinamiklerinin tarihsel yörüngelerine uyması için en uygun polinom fonksiyonları kullanmış ve ağırlıklı olarak 2010-2030 dönemi boyunca nüfusun ayrıntılı tahminleri yürüterek analiz yapmıştır. Yaptığı analize göre dünya nüfusunun artması ve kentleşme, yakın gelecekte çevre kalitesi ve sürdürülebilir kalkınma üzerinde sürekli olarak daha güçlü bir baskı oluşturacağı, ancak bu durumun 21. yüzyılın ortalarından itibaren toplam nüfusun maksimumuna ulaşmasıyla değişmeye başlayacağı yönünde olacağı sonucuna varmıştır.

Selçuk (2014) yaptığı bu çalışmada, nüfus kestirim yöntemlerinden matematiksel yöntemlerin neler olduğunu ele almıştır. Yazar çalışmada, şehir plancılar için önemli olan yeni gelişmekte olan nüfus kestirim yöntemlerini de ele alarak; en gerçekçi sonuca ulaşması olası yöntemin seçimini ve şehir planlama çalışmalarında söz konusu yöntemin kullanımını sağlayarak, nüfus tahminlerinde matematiksel yöntemlerin detaylandırılması ve söz konusu yöntemlerin şehir planlama çalışmalarında kullanım alanlarını tarif etmişlerdir.

Wei ve diğerleri (2015) çalışmada, iki nüfus artış modelini gözden geçirmişler ve nüfus artışını açıklamanın ve tahmin etmenin uygun bir yolunu bulmaya çalışmışlardır. Nüfus artışını tahmin etmek için üstel büyüme modeli ve lojistik büyüme modelinin kullanarak insan nüfusu artışı ile biyolojik nüfus artışı arasındaki farkı vurgulayarak ve mevcut verilere dayanarak nüfus artışını etkileyen faktörleri zaman serisi analizi ile incelemişlerdir. Analizden elde ettikleri bulgulara göre kentleşme derecesi ve cinsiyet oranı olmak üzere iki faktörün Çin'deki nüfus artışı üzerinde önemli etkileri olduğu sonucuna ulaşmışlardır.

Öztürk ve diğerleri (2018) bu çalışmada Türkiye geneli ve Konya ili için 2016 yılına ait nüfus artış tahminini yapay zekâ temelli genetik algoritma kullanarak incelemişlerdir. Daha sonra yine Türkiye geneli ve Konya ili için 2020 yılına ait nüfus artış tahmin oranını hesaplamışlardır. Çalışma nüfus tahmininde genetik algoritmanın kullanılması ile ilk ve tek çalışma olup gerçek kodlu genetik algoritmaların sistem kimliklendirme ve model uydurma çalışmalarında oldukça başarılı sonuçlar verdiği sonucuna ulaşmışlardır.

Wang ve Lee (2021) çalışmada, çok bölgesel nüfus artışını objektif olarak tahmin etmek için makine öğrenimine dayalı bir yöntem önermişlerdir. Bu nedenle, yeni geliştirilen makine öğrenimi teknolojilerinden yararlandıkları bu çalışmada, Tayvan'daki büyük şehirlerin nüfus artışını analiz etmeye ve tahmin etmeye çalışmışlardır. XGBoost algoritmasının avantajını etkin bir şekilde kullanarak, özellik önemini değerlendirilmesi ve çok bölgesel nüfus artışının bugün ile yakın gelecek arasındaki nüfus tahminini objektif olarak gözlemlenebilir ve ayrıca bölgesel şehir planlamasına objektif bir referans sağlayabilir sonucuna ulaşmışlardır.



Jiang ve diğeri (2021) çalışmada, 2005'ten sonraki 45 yıl boyunca Çin'in nüfus artışını tahmin etmek istemişlerdir. Kısa vadeli, orta vadeli ve uzun vadeli ölçmek için tahmin aralığını 2006'dan 2020'ye, 2021'den 2035'e ve 2036'dan 2050'ye kadar üç aralığa bölmüşlerdir. Modeldeki ilgili parametreler ve girdi koşulları ayarlanarak erkek-kadın cinsiyet oranı, yaşlanma ve kırsal nüfus kentleşmesinin ülkenin nüfus artışı üzerindeki etkileri nicel olarak analiz etmişlerdir. Analizden elde ettikleri bulgulara göre kısa vadede Çin'in doğum cinsiyet oranının önemli ölçüde değişmediğini ve kısa vadede temelde değişmeden kalacağı sonucuna varmışlardır.

Yapılan literatür taramasına göre ülke ekonomisi için çok önemli faktörlerden biri olan nüfus tahmini üzerine bir çok yöntemlerle yaklaşılarak yapılan çalışmalar bulunmaktadır. Aynı şekilde Yapay Sinir Ağı Temelli GMDH yönteminin de birçok alanda kullanıldığı ve başarılı sonuçlara ulaşıldığı literatür taraması sonucunda elde edilmiştir. Bu çalışma nüfus tahmini üzerine GMDH-Sinir Ağı yönteminin uygulanması ve başarılı sonuçlar elde edilmesi sebebiyle literatüre katkı sağlamaktadır.

### 3. VERİ SETİ VE YÖNTEM

Bu çalışmada 27 AB üyesi ülkeler için nüfus tahmini yapılmak istenmektedir. Bu amaçla Ivakhnenko tarafından literatüre kazandırılan Veri İşleme Grup tipi Sinir Ağı yöntemi (GMDH-NN) kullanılmıştır. Veriler Dünya Bankası Veri Tabanından elde edilmiştir (<https://databank.worldbank.org/source/health-nutrition-and-population-statistics>). 1960-2020 yıllarına ait veriler analizde kullanılmıştır. Dünya bankası veri tabanında 1960-2050 yılına kadar veriler mevcut olup analiz ile elde edilen nüfus tahminleri (2032 yılına kadar) ile karşılaştırılmıştır.

### 4. GMDH TİPİ SINIR AĞI

Ivakhnenko'nun literatüre kazandırdığı grup veri işleme yöntemi (GMDH), kendi kendine organizasyon ilkelerine dayanan tipik bir endüktif modelleme yöntemidir. Ortaya çıkmasından bu yana, tümevarımsal modelleme, tahmin, modelleme, kümeleme, sistem tanımlama gibi çeşitli kilit alanlarda ve ayrıca veri madenciliği ve bilgi çıkarma teknolojileri gibi sosyal bilimler, bilim, mühendislik, tıp vb. gibi çeşitli alanlarda karmaşık sistemlere geliştirilmekte ve uygulanmaktadır. Tanıtımından bu yana GMDH'nin teorisi, algoritmaları, uygulamaları, çözümleri ve yeni gelişmeleri kamuoyuna tanıtılmaya çalışılmıştır. Grup veri işleme yöntemi (GMDH), bilgisayar tabanlı matematiksel modelleme ve yapısal tanımlama için bir algoritma ailesidir. Çoğu GMDH algoritması, multiparametrik bir model elde etmek için kullanılan endüktif kendi kendini organize eden prosedür ile karakterize edilir. GMDH'nin belirli davranış özellikleri, veri madenciliği, bilgi keşfi, tahmin, karmaşık sistem modelleme, optimizasyon ve örüntü tanıma gibi alanlarda başarılı bir şekilde kullanılmasını sağlamıştır. GMDH ile incelenen bir nesnenin birden çok girdi ve en az bir çıktı ile temsil edildiği varsayılmaktadır. Ayrıca nesnenin, temel fonksiyonun (1) bileşenlerinin belirli bir alt kümesi tarafından modellenebileceği varsayılmaktadır (Onwubolu, 2014:2):

$$Y(x_1, \dots, x_n) = a_0 + \sum_{i=1}^k a_i f_i \quad (1)$$

burada;  $x$  = girdiler,  $Y$  = çıktı,  $a$  = katsayılar,  $f$  = farklı girdi setlerine bağlı temel fonksiyonlar ve  $k$  = temel fonksiyon bileşenlerinin sayısını ifade etmektedir. GMDH algoritması bazı kısmi modelleri - temel fonksiyonun (1) bileşen alt kümelerini dikkate almalı ve harici bir kriterin minimum değeri ile gösterilen optimal bir model yapısı seçmelidir. Böyle bir prosedürden elde edilen ana avantaj, tanımlanan modelin girdi verilerindeki (gürültüye dayanıklı modelleme) gürültü düzeyine yeterli bir optimal karmaşıklığa sahip olmasıdır.

*Temel GMDH Algoritması* (Onwubolu, 2014:4)

Temel bir GMDH algoritması aşağıdaki adımları gerçekleştirir:

Adım 1: Veri örneğini A ve B bölümlerine böler.

Adım 2: Kısmi modeller için yapılar oluşturur.

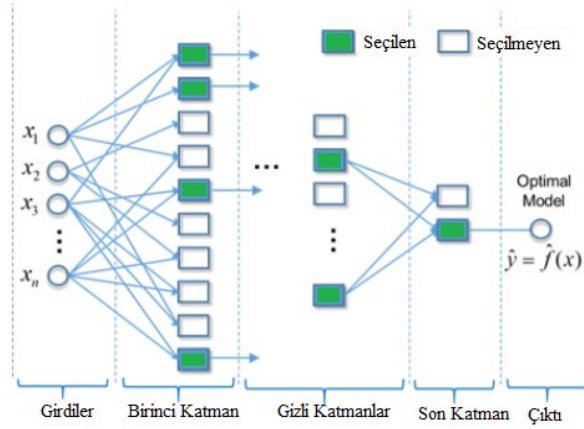
Adım 3: En küçük kareler yöntemini ve örnek A'yı kullanarak kısmi modellerin katsayılarını tahmin eder.

Adım 4: Örnek B'yi kullanarak kısmi modeller için dış kriterin değerini hesaplar.

Adım 5: Kriterin minimum değeri ile gösterilen en iyi modeli (model seti) seçer.

Sinir ağı deyiminde, GMDH algoritması tarafından büyütülen yüksek dereceli polinom ağları, esasen ileri beslemeli, çok katmanlı sinir ağlarıdır. Düğümler gizli birimlerdir, yapraklar girdilerdir ve aktivasyon polinom katsayıları ağırlıklardır. Belirli bir gizli düğüme ulaşan ağırlıklar, sıradan en küçük kareler (OLS) uydurma ile tahmin edilir. GMDH Tipi Sinir Ağları; Kısmi modellerin değerlendirilmesi için bir sipariş seçmenin birçok farklı yolu vardır. En yaygın yollar şunlardır: Çok katmanlı yinelemeli algoritma (MIA), Kombinatoryal (COMBI) algoritması, Harmonik algoritma, Objektif sistem analizi (OSA), Objektif bilgisayar kümeleme (OCC), İşaret parmağı (PF) kümeleme algoritması, Analoglar kompleksi (AC), Harmonik yeniden ayrıştırma, İki seviyeli (ARIMAD), Çarpımsal-katkılı (MAA), İstatistiksel kararların çok katmanlı teorisi temelinde algoritma (MTSD), Uyarlanabilir model evrimi grubu (GAME) (Onwubolu, 2014:2-6).

GMDH tipi Sinir Ağı'nın eğitim prosedürü, geleneksel sinir ağından farklı olarak evrimsel bir yapıya dayanmaktadır. Her katmanın eğitiminde, giriş değişkenlerinin tüm olası kombinasyonlarına dayalı olarak nöron adayları oluşturulmaktadır. Daha sonra bu nöron adayları, hedef değişkeni tahmin etme yeteneklerine göre otomatik olarak taranır. Bir sonraki katmanın eğitimi için yalnızca iyi tahmin güçleri olan (kriteri karşılayan) nöronlar ileri beslenir ve geri kalanlar atılır. Her katmandaki nöronların sayısı, kullanıcı tarafından belirtilebilir veya deneysel olarak orijinal girdi değişkenlerinin sayısına göre ayarlanabilmektedir (Jia ve vd., 2018:45). Yinelemeli bir yapı kullanan bu model, veri tahmininde herhangi bir aşırı uyumsuzluk yoksa maksimum doğruluğu üretecek şekilde uyarlanmıştır. Yani ağı optimize etmek için ilgili ağın nöronları arasındaki bağlantılar sabit değildir, aksine eğitim sürecinde seçilmektedirler. Seçilen nöronlar birleştirilir ve yeni nöronlar üretilir. Bu genetik, hayatta kalma rekabeti ve evrimsel süreç tekrarlanarak, yeni nesil nöron öncekilerden daha iyi performans göstermeyene, optimal model (Şekil 1) seçilene kadar süreç devam etmektedir (Li ve vd., 2017:130).

**Şekil 1.** GMDH tipi Sinir Ağı'nın Yapılandırma Süreci**Kaynak:** Akkaya, 2021:55

Bu ağ, minimum hata ile  $\hat{y}$ 'nin tahmin edilen çıktısı aracılığıyla  $\hat{f}$ 'nin yaklaşık fonksiyonunu tanımlar. Çoklu girdi vektörü  $X = (x_{i1}, x_{i2}, \dots, x_{in})$  için tüm nöronlardan elde edilen kuadratik polinomlar birleştirilir ve tahmin edilen çıktı  $y$ 'nin gerçek tekli çıkışı ile karşılaştırılır ve gerçek çıktı  $y$ 'ye yakındır. Çoklu girdili-tek çıkışlı veri çiftlerinin belirtilen  $M$  gözlemleri için gerçek hedef aşağıdaki gibi ifade edilebilir (Ahmadi, 2015:2245-2246);

$$y_i = f(x_{i1}, x_{i2}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (2)$$

GMDH tipi Sinir Ağı,  $X = (x_{i1}, x_{i2}, \dots, x_{in})$  herhangi bir girdi vektörü için  $\hat{y}$ 'nin değerini tahmin etmek için aşağıdaki gibi eğitilir (Akkaya, 2021:55);

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, \dots, x_{in}) \quad (i = 1, 2, \dots, M) \quad (3)$$

Daha sonra gerçek değerler ile tahmini değerler arasındaki karesi alınmış hatayı en aza indirmek için GMDH Sinir Ağı aşağıdaki gibi belirtilir (Ahmadi, 2015:2245-2246);

$$\sum_{i=1}^M (\hat{y}_i - y_i)^2 \rightarrow \min \quad (4)$$

Çok girdili tek çıkışlı kendi kendini organize eden bir ağın girdileri ve çıktısı arasındaki ilişki, denklem 2'deki gibi formun sonsuz bir Volterra–Kolmogorov Gabor (VKG) polinomu ile temsil edilen fonksiyonel serilerin karmaşık ayrık bir prosedürü kullanılarak formüle edilmiştir (Onwubolu, 2014:2);

$$y_n = a_0 + \sum_{i=1}^M a_i x_i + \sum_{i=1}^M \sum_{j=1}^M a_{ij} x_i x_j + \sum_{i=1}^M \sum_{j=1}^M \sum_{k=1}^M a_{ijk} x_i x_j x_k \dots \quad (5)$$

burada;  $X = (x_1, x_2, \dots, x_M)$  girdi değişkenlerinin vektörü,  $A = (a_0, a_i, a_{ij}, a_{ijk} \dots)$  katsayıların veya ağırlıkların vektörünü temsil etmektedir. Bu polinom ifadesinin yalnızca iki

parametre (nöron) içeren kısmi ikinci dereceden polinomlar sistemi aşağıdaki gibi verilen toplam cebirsel düzenleme ile kullanılır (Akkaya, 2021:55);

$$\hat{y}_i = G(x_i, x_j) = a_0 + a_1x_i + a_2x_j + a_3x_i^2 + a_4x_j^2 + a_5x_ix_j \quad (6)$$

Denklem 5’de belirtilen girdi ve çıktı parametrelerinin genel matematiksel ilişkisini oluşturmak için bu tür kısmi ikinci dereceden bir taslak, ilişkili nöronlardan oluşan bir ağ boyunca tersine kullanılır. Denklem 6’daki katsayılar gerçek çıktı  $y$  ile her bir girdi parametresi  $x_i, x_j$  çifti için belirlenen bir  $\hat{y}$  arasındaki farkı en aza indirmek regresyon yaklaşımlarıyla belirlenir. Denklem 6’daki sabitler en küçük kareler mantığı ile elde edilmiş olup ikinci dereceden form kullanılarak bir polinom grubu meydana getirilmiştir. Sonra ise tüm çıktı-girdi veri çiftleri kümesi boyunca çıktıya en iyi şekilde uyumu sağlaması için toplam nöron hatasını en aza indirmek için her ikinci dereceden  $G_i$  fonksiyonunun sabitleri aşağıdaki gibi elde edilmektedir (Rezaei, 2018:267-268);

$$E = \frac{\sum_{i=1}^M (y_i - G_i)^2}{M} \rightarrow \min \quad (7)$$

GMDH yönteminde, seçilen  $n$  girdi parametresinin tamamından iki adet bağımsız parametrenin olasılıkları sağlanmaktadır. Denklem 6’daki bağımlı gözlemlere ( $y_i = 1, 2, \dots, M$ ) uygun şekilde uyan regresyon polinomunu en küçük kareler mantığı ile tasarlamak için yapılır. Ayrıca bu belirtilen teknik  $n(n-1)/2$  nöron gözlemlerden farklı  $p, q \in \{1, 2, \dots, n\}$  adına  $\{(y_i, x_{ip}, x_{iq}); (i = 1, 2, \dots, M)\}$ ’den hesaplanan ilk gizli katman üzerinden kurulacaktır. Yani daha sonra  $M$  veri üçlüleri  $\{(y_i, x_{ip}, x_{iq}); (i = 1, 2, \dots, M)\}$ ,  $p, q \in \{1, 2, \dots, n\}$  kümeleri gibi gözlemlerin etkin bir şekilde oluşturulmasını vaat etmektedir (Ahmadi, 2015:2245-2247);

$$\begin{bmatrix} x_{1p} & x_{1q} & y_1 \\ x_{2p} & x_{2q} & y_2 \\ x_{3p} & x_{3q} & y_M \end{bmatrix} \quad (8)$$

Her  $M$  veri üçlü satırı için Denklem 6’nın ikinci dereceden alt formülasyon tipini kullanarak, sonraki matris formülü hemen şu şekilde elde edilmektedir (Ahmadi, 2015:2247);

$$Aa = Y \quad (9)$$

$$a = (a_0, a_1, a_2, a_3, a_4, a_5) \quad (10)$$

$$Y = (y_1, y_2, y_3, \dots, y_M)^T \quad (11)$$

Denklem 6’da belirtilen bilinmeyen katsayıların vektörünü  $a$  ifade ederken,  $Y$  ise gözlemlerden elde edilen çıktıların vektörünü belirtmektedir. Bu nedenle formüle edilen korelasyon aşağıdaki gibi olmaktadır (Rezaei, 2018:268);

$$\begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}x_{Mq} & x_{Mp}^2 & x_{Mq}^2 \end{bmatrix} \quad (12)$$

Çoklu regresyon etkisinin analizinden elde edilen sonucun incelenmesiyle en küçük kareler yönteminin dikkate alınması ile aşağıdaki şekilde standardize haline gelir (Rezaei, 2018:268);

$$a = (A^T A)^{-1} A^T \quad (13)$$

Böylece,  $M$  üçlü veri seti için denklem 6'da verilen katsayıların en kesin değerleri denklem 13 ile belirlenmektedir. Bu yöntem Sinir Ağı'nın bağlantı yapısının eşlik ettiği daha sonraki gizli katmanın her nöronu için yinelenmektedir, yani eşleştirilmiş Sinir Ağı yapısı ile birleştirilen bir sonraki gizli katmanın her bir nöronu için olduğu belirtilmektedir. Standart denklemlerden gelen böyle bir cevap, sapmaları iyileştirmeye ve daha da önemlisi, yukarıda belirtilen formüllerin bireyselliğini artırmaya karşı daha hassas olmaktadır (Akkaya, 2021:56; Rezaei, 2018:268; Ahmadi, 2015:2247).

## 5. AMPİRİK BULGULAR

27 AB ülkesi (Almanya, Avusturya, Belçika, Bulgaristan, Çek Cumhuriyeti, Danimarka, Estonya, Finlandiya, Fransa, Kıbrıs, Hırvatistan, Hollanda, İrlanda, İspanya, İsveç, İtalya, Letonya, Litvanya, Lüksemburg, Macaristan, Malta, Polonya, Portekiz, Romanya, Slovenya, Slovak Cumhuriyeti, Yunanistan) için GMDH-Sinir Ağı yöntemi ile elde edilen nüfus tahmin sonuçları ve dünya bankası veri tabanındaki değerler ile karşılaştırılmış hali Tablo 1'de paylaşılmıştır.

Tablo 1'den de görüldüğü gibi 27 AB ülkesi için geçmiş yıllardaki (2006-2020) gerçek değerler ile GMDH-Sinir Ağı yöntemi ile elde edilen sonuçlar neredeyse birebir uymaktadır. Buradan yola çıkılarak bu yöntemden elde edilen (2021-2032 yıllarındaki) nüfus tahmin değerlerinin de başarılı sonuçlar elde ettiği söylenebilmektedir. Ayrıca Tablo 1'de Dünya veri bankasında bulunan tahmin değerleri de yine yöntemimizden elde edilen ((2021-2032 yıllarındaki) değerler ile karşılaştırılmış olup buradaki değerler ile de tutarlı olduğu sonucuna varılmış olduğundan GMDH-Sinir Ağı yönteminin nüfus tahmininde doğru ve başarılı bir yöntem olduğu söylenebilmektedir.

**Tablo 1.** 2006-2032 Yıllarına ait AB Ülkeleri için Nüfus Gerçek Değerleri - GMDH Sınır Ağı Sonuçları ve Dünya Bankası Verileri Karşılaştırması

Almanya				Avusturya				Belçika				Bulgaristan			
Yıllar	Gerçek Değerler	GMDH-Sınır Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sınır Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sınır Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sınır Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri
2006	82376451	81906940		2006	8268641	8267173		2006	10547958	10559384		2006	7601022	7638096	
2007	82266372	81890171		2007	8295487	8298189		2007	10625700	10645406		2007	7545338	7575905	
2008	82110097	81874506		2008	8321496	8318456		2008	10709973	10735995		2008	7492561	7515694	
2009	81902307	81567960		2009	8343323	8338933		2009	10796493	10832868		2009	7444443	7457453	
2010	81776930	81378114		2010	863404	8362471		2010	10895586	10928862		2010	7395599	7401169	
2011	80274983	81253990		2011	8391643	8391861		2011	11038264	11010496		2011	7348328	7347739	
2012	80425823	81255434		2012	8429991	8436355		2012	11106932	11081670		2012	7305888	7298465	
2013	80645605	81363713		2013	8479823	8491931		2013	11159407	11146355		2013	7265115	7250536	
2014	80982500	81547628		2014	8546356	8556521		2014	11209057	11207163		2014	7223938	7204868	
2015	81686611	81787458		2015	8642699	8634476		2015	11274196	11269087		2015	7177991	7159477	
2016	82348669	82052908		2016	8736668	8719390		2016	11331422	11322828		2016	7127822	7112961	
2017	82657002	82312921		2017	8797566	8792291		2017	11375158	11372344		2017	7075947	7067336	
2018	82905782	82531439		2018	8840521	8844622		2018	11427054	11430171		2018	7025037	7022595	
2019	83092962	82748544		2019	8879920	8882236		2019	11502704	11501463		2019	6975761	6978732	
2020	83152000	82964235		2020	8915000	8916892		2020	11543000	11551531		2020	6923000	6935740	
2021		83178514	83100000	2021		8958099	8936000	2021		11598231	11579000	2021		6893612	6871000
2022		83378123	82977000	2022		9009806	8950000	2022		11649305	11611000	2022		6855118	6819000
2023		83567697	82819000	2023		9070088	8958000	2023		11712342	11640000	2023		6819869	6767000
2024		83712737	82667000	2024		9155920	8965000	2024		11767667	11669000	2024		6793249	6714000
2025		83757415	82548000	2025		9278747	8975000	2025		11793546	11698000	2025		6768910	6660000
2026		83700651	82461000	2026		9426146	8988000	2026		11805259	11728000	2026		6757574	6605000
2027		83568205	82396000	2027		9385724	9001000	2027		11865024	11757000	2027		6737472	6549000
2028		83159404	82342000	2028		9426145	9015000	2028		11667377	11784000	2028		6702747	6493000
2029		82633968	82287000	2029		9306262	9027000	2029		11244601	11810000	2029		6688617	6437000
2030		81874506	82221000	2030		9025377	9038000	2030		10294434	11834000	2030		6640039	6380000
2031		81890171	82143000	2031		8330962	9047000	2031		8475233	11856000	2031		6615338	6323000
2032		81906940	82053000	2032		8302996	9054000	2032		7311541	11877000	2032		6585888	6267000

Çek Cumhuriyeti				Danimarka				Estonya				Finlandiya			
Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri
2006	10238905	10290315		2006	5437272	5443621		2006	1346810	1346782		2006	5266268	5265586	
2007	10298828	10316158		2007	5461438	5464747		2007	1340680	1341174		2007	5288720	5289175	
2008	10384603	10357044		2008	5493621	5488587		2008	1337090	1336888		2008	5313399	5313581	
2009	10443936	10393231		2009	5523095	5515867		2009	1334515	1335067		2009	5338871	5338357	
2010	10474410	10417511		2010	5547683	5543106		2010	1331475	1331123		2010	5363352	5364287	
2011	10496088	10440070		2011	5570572	5568632		2011	1327439	1326463		2011	5388272	5389966	
2012	10510785	10458046		2012	5591572	5593814		2012	1322696	1321778		2012	5413971	5413872	
2013	10514272	10495244		2013	5614932	5619659		2013	1317997	1318048		2013	5438972	5437203	
2014	10525347	10534467		2014	5643475	5650544		2014	1314545	1315937		2014	5461512	5460275	
2015	10546059	10564922		2015	5683483	5685854		2015	1315407	1315499		2015	5479531	5479799	
2016	10566332	10581801		2016	5728010	5723732		2016	1315790	1316729		2016	5495303	5494893	
2017	10594438	10596953		2017	5764980	5758194		2017	1317384	1318854		2017	5508214	5507287	
2018	10629928	10621849		2018	5793636	5788273		2018	1321977	1321505		2018	5515525	5516813	
2019	10671870	10646707		2019	5814422	5814981		2019	1326898	1324428		2019	5521606	5522934	
2020	10690000	10668003		2020	5834000	5840277		2020	1325000	1326485		2020	5529000	5528180	
2021		10677329	10704000	2021		5867734	5855000	2021		1327332	1322000	2021		5535032	5536000
2022		10681351	10715000	2022		5902433	5876000	2022		1328819	1317000	2022		5541026	5542000
2023		10680403	10722000	2023		5938759	5897000	2023		1331701	1311000	2023		5542909	5548000
2024		10651688	10726000	2024		5975758	5918000	2024		1338516	1305000	2024		5546254	5552000
2025		10612735	10726000	2025		6012897	5938000	2025		1344559	1300000	2025		5552825	5555000
2026		10475873	10724000	2026		6031842	5957000	2026		1348784	1295000	2026		5564036	5556000
2027		10469162	10719000	2027		6063674	5975000	2027		1351692	1290000	2027		5586915	5556000
2028		10463056	10711000	2028		6082177	5993000	2028		1347509	1285000	2028		5620770	5554000
2029		10030962	10701000	2029		6140401	6009000	2029		1345592	1280000	2029		5640093	5551000
2030		10007538	10689000	2030		6059755	6025000	2030		1339304	1274000	2030		5658399	5548000
2031		10090462	10674000	2031		5929520	6040000	2031		1351215	1268000	2031		5650066	5543000
2032		10401224	10659000	2032		5956178	6056000	2032		1362597	1262000	2032		5747319	5539000

Fransa				Kıbrıs				Hrvatistan				Hollanda			
Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri
2006	63621381	63344179		2006	1045507	1046344		2006	4311159	4306156		2006	16346101	16303767	
2007	64016225	63658836		2007	1063713	1064077		2007	4310217	4304974		2007	16381696	16368217	
2008	64374984	63973493		2008	1081563	1081489		2008	4309705	4307257		2008	16445593	16439692	
2009	64707040	64288151		2009	1098083	1097367		2009	4305181	4304114		2009	16530388	16533115	
2010	65027507	64602808		2010	1112612	1111535		2010	4295427	4297812		2010	16615394	16622340	
2011	65342780	64917465		2011	1124833	1124131		2011	4280622	4283601		2011	16693074	16698327	
2012	65659809	65232122		2012	1135046	1134935		2012	4267558	4265079		2012	16754962	16763440	
2013	65998687	65608752		2013	1143866	1144378		2013	4255689	4255958		2013	16804432	16816372	
2014	66312067	65990046		2014	1152285	1152985		2014	4238389	4231411		2014	16865008	16872289	
2015	66548272	66293112		2015	1160985	1161453		2015	4203604	4200642		2015	16939923	16945456	
2016	66724104	66555907		2016	1170187	1170310		2016	4174349	4165922		2016	17030314	17034263	
2017	66864379	66814858		2017	1179680	1179548		2017	4124531	4130205		2017	17131296	17133493	
2018	66965912	67069967		2018	1189265	1189047		2018	4087843	4097092		2018	17231624	17232203	
2019	67055854	67321233		2019	1198575	1198447		2019	4065253	4069164		2019	17344874	17320362	
2020	67202000	67568656		2020	1207000	1206974		2020	4041000	4043611		2020	17380000	17394022	
2021		67812236	67366000	2021		1213632	1216000	2021		4025011	4018000	2021		17453830	17417000
2022		68111117	67538000	2022		1217448	1223000	2022		3987035	3997000	2022		17511950	17454000
2023		68449628	67707000	2023		1217692	1231000	2023		3918031	3976000	2023		17574075	17489000
2024		68829129	67866000	2024		1213753	1238000	2024		3826951	3955000	2024		17638329	17522000
2025		69322666	68012000	2025		1204814	1245000	2025		3689144	3933000	2025		17692263	17552000
2026		69637324	68142000	2026		1189685	1251000	2026		3720194	3911000	2026		17738211	17578000
2027		69951981	68259000	2027		1168295	1257000	2027		4638343	3889000	2027		17742047	17600000
2028		70266638	68363000	2028		1160328	1263000	2028		3030729	3866000	2028		17740665	17619000
2029		70581295	68456000	2029		1176907	1269000	2029		3804767	3843000	2029		17801113	17634000
2030		70895953	68542000	2030		1199332	1275000	2030		3791224	3819000	2030		17855836	17646000
2031		71210610	68620000	2031		1171401	1280000	2031		3792937	3795000	2031		17922378	17655000
2032		71525267	68692000	2032		1073049	1286000	2032		3920581	3771000	2032		17922925	17662000



İrlanda				İspanya				İsveç				İtalya			
Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri
2006	4273591	4258344		2006	44397319	43815706		2006	9080505	9087090		2006	58143979	58472599	
2007	4398942	4319646		2007	45226803	44087215		2007	9148092	9146492		2007	58438310	58620054	
2008	4489544	4422775		2008	45954106	44358723		2008	9219637	9217378		2008	58826731	58725679	
2009	4535375	4495953		2009	46362946	44630232		2009	9298515	9294923		2009	59095365	59074714	
2010	4560155	4525996		2010	46576897	44901741		2010	9378126	9371940		2010	59277417	59262386	
2011	4580084	4562029		2011	46742697	45397907		2011	9449213	9447671		2011	59379449	59440571	
2012	4599533	4595864		2012	46773055	45750890		2012	9519374	9522042		2012	59539717	59685657	
2013	4623816	4633387		2013	46620045	46012175		2013	9600379	9602372		2013	60233948	59887891	
2014	4657740	4674534		2014	46480882	46221166		2014	9696110	9695388		2014	60789140	60078087	
2015	4701957	4719146		2015	46444832	46404560		2015	9799186	9804849		2015	60730582	60174635	
2016	4755335	4766882		2016	46484062	46577852		2016	9923085	9924831		2016	60627498	60264067	
2017	4807388	4817151		2017	46593236	46750373		2017	10057698	10047959		2017	60536709	60346384	
2018	4867316	4869893		2018	46797754	46937140		2018	10175214	10163809		2018	60421760	60421586	
2019	4934040	4923609		2019	47133521	47123007		2019	10278887	10264910		2019	60302093	60489671	
2020	4983000	4978299		2020	47133000	47307975		2020	10340000	10362021		2020	60177000	60550642	
2021		5033962	5023000	2021		47492045	47108000	2021		10459421	10399000	2021		60604497	60057000
2022		5089353	5055000	2022		47687250	47063000	2022		10574852	10456000	2022		60710947	59935000
2023		5145545	5083000	2023		47884625	47004000	2023		10711234	10510000	2023		60792211	59806000
2024		5203223	5109000	2024		48099232	46937000	2024		10799221	10563000	2024		60893621	59665000
2025		5263978	5135000	2025		48352166	46867000	2025		10800967	10614000	2025		61044785	59508000
2026		5330844	5162000	2026		48679883	46795000	2026		10906749	10662000	2026		60950499	59337000
2027		5409153	5189000	2027		49136015	46718000	2027		10851301	10707000	2027		60740140	59156000
2028		5514669	5216000	2028		49788896	46637000	2028		11597506	10750000	2028		61375272	58967000
2029		5527768	5242000	2029		50060404	46550000	2029		11836686	10790000	2029		62670944	58776000
2030		5472127	5267000	2030		50331913	46457000	2030		12250969	10829000	2030		62891752	58585000
2031		5289626	5290000	2031		50603422	46359000	2031		12792516	10866000	2031		63115749	58395000
2032		5655910	5313000	2032		50874930	46257000	2032		14577244	10902000	2032		63342935	58207000

Letonya				Litvanya				Lüksemburg				Macaristan			
Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri
2006	2218357	2216105		2006	3269909	3281543		2006	472637	472037		2006	10071370	10073279	
2007	2200325	2199179		2007	3231294	3236176		2007	479993	479543		2007	10055780	10057745	
2008	2177322	2176576		2008	3198231	3196282		2008	488650	487936		2008	10038188	10036468	
2009	2141669	2142627		2009	3162916	3149300		2009	497783	497656		2009	10022650	10014580	
2010	2097555	2097815		2010	3097282	3092910		2010	506953	508221		2010	10000023	9989584	
2011	2059709	2060276		2011	3028115	3039594		2011	518347	519187		2011	9971727	9961265	
2012	2034319	2035205		2012	2987773	2996549		2012	530946	530874		2012	9920362	9931687	
2013	2012647	2013802		2013	2957689	2960234		2013	543360	543331		2013	9893082	9900066	
2014	1993782	1994583		2014	2932367	2928722		2014	556319	556361		2014	9866468	9870114	
2015	1977527	1977785		2015	2904910	2898709		2015	569604	569362		2015	9843028	9842595	
2016	1959537	1960602		2016	2868231	2864431		2016	582014	582373		2016	9814023	9817964	
2017	1942248	1942663		2017	2828403	2832160		2017	596336	595104		2017	9787966	9795488	
2018	1927174	1925388		2018	2801543	2806787		2018	607950	607766		2018	9775564	9776291	
2019	1913822	1910391		2019	2794137	2786266		2019	620001	619616		2019	9771141	9761706	
2020	1894000	1895755		2020	2760000	2763920		2020	629000	630201		2020	9743000	9741993	
2021		1876133	1876000	2021		2739290	2731000	2021		639800	636000	2021		9716649	9713000
2022		1854547	1858000	2022		2718724	2706000	2022		648785	643000	2022		9685549	9682000
2023		1831074	1842000	2023		2710093	2683000	2023		657537	649000	2023		9661218	9650000
2024		1810645	1825000	2024		2714995	2661000	2024		666537	655000	2024		9626108	9618000
2025		1794235	1809000	2025		2731237	2640000	2025		673598	661000	2025		9593365	9584000
2026		1773684	1793000	2026		2758394	2620000	2026		680486	667000	2026		9564497	9550000
2027		1749776	1778000	2027		2792085	2599000	2027		690382	672000	2027		9539394	9515000
2028		1726946	1763000	2028		2850879	2579000	2028		696177	678000	2028		9511424	9479000
2029		1677384	1748000	2029		2893048	2559000	2029		701775	684000	2029		9498126	9441000
2030		1662592	1733000	2030		3105448	2540000	2030		706448	689000	2030		9494053	9401000
2031		1651753	1718000	2031		3017272	2520000	2031		695086	695000	2031		9483473	9360000
2032		1772750	1704000	2032		3449199	2500000	2032		835868	700000	2032		9418134	9317000

Malta				Polonya				Portekiz				Romanya			
Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri
2006	405308	403472		2006	38141267	38119470		2006	10522288	10529027		2006	21193760	21069037	
2007	406724	405152		2007	38120560	38108584		2007	10542964	10541624		2007	20882982	20894642	
2008	409379	407474		2008	38125759	38102104		2008	10558177	10548617		2008	20537875	20679549	
2009	412477	410030		2009	38151603	38095232		2009	10568247	10550600		2009	20367487	20488407	
2010	414508	413564		2010	38042794	38065372		2010	10573100	10543049		2010	20246871	20348778	
2011	416268	418012		2011	38063255	38062900		2011	10557560	10522871		2011	20147528	20210118	
2012	420028	422529		2012	38063164	38038304		2012	10514844	10490545		2012	20058035	20075391	
2013	425967	428287		2013	38040196	38032047		2013	10457295	10448669		2013	19983693	19957360	
2014	434558	436309		2014	38011735	38015266		2014	10401062	10405809		2014	19908979	19849942	
2015	445053	446240		2015	37986412	38010267		2015	10358076	10369762		2015	19815616	19746500	
2016	455356	456142		2016	37970087	37996204		2016	10325452	10344684		2016	19702267	19643786	
2017	467999	468465		2017	37974826	37979962		2017	10300300	10328157		2017	19587290	19546242	
2018	484630	483858		2018	37974750	37974305		2018	10283822	10313941		2018	19472545	19462289	
2019	504062	498111		2019	37965475	37976510		2019	10286263	10301193		2019	19366221	19385437	
2020	505000	508019		2020	37914000	37949747		2020	10254000	10292301		2020	19248000	19314691	
2021		514496	506000	2021		37953616	37860000	2021		10282136	10223000	2021		19253263	19148000
2022		520986	508000	2022		37953607	37801000	2022		10279004	10193000	2022		19249710	19061000
2023		543771	509000	2023		37925871	37734000	2023		10296326	10164000	2023		19562638	18981000
2024		539584	510000	2024		37882673	37658000	2024		10336163	10135000	2024		21799042	18902000
2025		513588	511000	2025		37858404	37571000	2025		10400650	10105000	2025		32070231	18819000
2026		574653	511000	2026		37843158	37472000	2026		10471007	10074000	2026		69960087	18732000
2027		572790	511000	2027		37830772	37360000	2027		10505984	10043000	2027		19173003	18641000
2028		670871	511000	2028		37817101	37237000	2028		10538171	10011000	2028		19006886	18546000
2029		834325	511000	2029		37777836	37101000	2029		10524799	9979000	2029		18935503	18450000
2030		1013394	510000	2030		37753507	36954000	2030		10522791	9946000	2030		19126255	18352000
2031		1409333	509000	2031		37744002	36797000	2031		10592501	9912000	2031		19606277	18253000
2032		2634620	508000	2032		37695041	36631000	2032		10633389	9878000	2032		19687821	18152000

Slovenya				Slovak Cumhuriyeti				Yunanistan			
Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri	Yıllar	Gerçek Değerler	GMDH-Sinir Ağı Tahmin Sonuçları	Dünya Bankası Tahminleri
2006	2006868	2015719		2006	5373054	5376023		2006	11020362	11027470	
2007	2018122	2021723		2007	5374622	5379162		2007	11048473	11047464	
2008	2021316	2028269		2008	5379233	5382355		2008	11077841	11080532	
2009	2039669	2033314		2009	5386406	5387526		2009	11107017	11104318	
2010	2048583	2042494		2010	5391428	5393567		2010	11121341	11102923	
2011	2052843	2047172		2011	5398384	5400095		2011	11104899	11076473	
2012	2057159	2051668		2012	5407579	5406853		2012	11045011	11028857	
2013	2059953	2056512		2013	5413393	5412873		2013	10965211	10960364	
2014	2061980	2059980		2014	5418649	5418929		2014	10892413	10901057	
2015	2063531	2062159		2015	5423801	5425046		2015	10820883	10847780	
2016	2065042	2064401		2016	5430798	5430368		2016	10775971	10798150	
2017	2066388	2067470		2017	5439232	5436502		2017	10754679	10758979	
2018	2073894	2073393		2018	5446771	5442075		2018	10732882	10730579	
2019	2088385	2081772		2019	5454147	5446504		2019	10717169	10696258	
2020	2088000	2086769		2020	5456000	5450785		2020	10658000	10658648	
2021		2093838	2087000	2021		5454106	5456000	2021		10615127	10600000
2022		2098730	2086000	2022		5457460	5455000	2022		10568780	10543000
2023		2102730	2084000	2023		5460453	5452000	2023		10522179	10489000
2024		2105822	2081000	2024		5462878	5448000	2024		10504325	10436000
2025		2107642	2079000	2025		5464358	5443000	2025		10461454	10384000
2026		2106408	2076000	2026		5461490	5436000	2026		10395177	10335000
2027		2109463	2073000	2027		5454693	5427000	2027		10360743	10286000
2028		2113506	2069000	2028		5469569	5417000	2028		10298280	10239000
2029		2126627	2065000	2029		5488645	5405000	2029		10160914	10192000
2030		2150166	2060000	2030		5496820	5391000	2030		9984733	10147000
2031		2172658	2056000	2031		5471880	5376000	2031		9085921	10102000
2032		2221800	2050000	2032		5481818	5359000	2032		7346581	10059000

**Not:** Tablo uzunluğunun fazla olmaması için geçmiş değerler olarak 2006 yılından itibaren paylaşılmıştır. Grafik 1’de her bir ülke için geçmiş değerler ile GMDH-Sinir Ağı yönteminden elde edilen tahmin değerlerinin birbirlerine yakınlığı 1980’li yıllardan itibaren görülebilmektedir.

### 5.1. Performans Kriteri

Bir modelden tahmin edilen değerlerin mümkün olduğunca gerçek değerlere yakın olması beklenir. Bu nedenle amaç, hatayı en aza indirmek, diğer bir deyişle gerçek ve tahmini değerler arasındaki farkı azaltmaktır. Bu çalışmada, zaman serisi tabanlı GMDH tipi NN modelinin hem model geliştirme hem de test aşamaları için tahmin performans sonuçları, maksimum negatif hata (MNE), maksimum negatif yüzde hata (MNPE), maksimum negatif yüzde hata (MNPE), maksimum pozitif hata (MPE), maksimum pozitif yüzde hata (MPPE), ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), ortalama karekök hata (RMSE), ortalama karekök hata (RMSPE), korelasyon ( $R$ ) ve belirleme katsayısı ( $R^2$ ). Bunlar arasında, birliğe yakın  $R$  ve  $R^2$  değerleri tatmin edici bir sonuca işaret etmektedir. Bu nedenle, bu kriterler için en yüksek değerler beklenmektedir. Buna karşılık, belirtilen diğer kriterler için, tahmin modelinde düşük değer veya sifıra yakın değer istenir (Akkaya, 2021:057).

Lewis 1982' de yaptığı çalışmasında tahminin doğruluğunun değerlendirilmesinde MAPE sonuçlarını yorumlamanın doğru bir yol olduğunu göstermiştir. Buna göre MAPE değeri %10'un altında olan modellerin "çok iyi", %10 ile %20 arasında olan modellerin "iyi", %20 ile %50 arasında olan modellerin "kabul edilebilir" ve %50'nin üzerinde olan modelleri ise "yanlış ve hatalı" olarak sınıflandırılmaktadır (Metin, 2021:604).

AB ülkelerinin 2032 yılına dair gelecek nüfus tahminleri için GMDH-Sinir Ağı modelinin performans sonuçları her bir ülke için ayrı ayrı tablo 2'de paylaşılmıştır.

**Tablo 2. GMDH-Sinir Ağı'nın 27 AB Ülkesi için Performans Sonuçları**

Almanya		Avusturya		Belçika		Bulgaristan	
Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu
Gözlem sayısı	15	Gözlem sayısı	35	Gözlem sayısı	28	Gözlem sayısı	27
Maks. Negatif Hata (MNE)	-0,569958 %	Maks. Negatif Hata (MNE)	-0,659529 %	Maks. Negatif Hata (MNE)	-0,588043 %	Maks. Negatif Hata (MNE)	-1,42851 %
Maks. Pozitif Hata (MPE)	1,21957 %	Maks. Pozitif Hata (MPE)	0,69624 %	Maks. Pozitif Hata (MPE)	0,336915 %	Maks. Pozitif Hata (MPE)	0,937717 %
Ortalama mutlak yüzde hatası (MAPE)	0,536013 %	Ortalama mutlak yüzde hatası (MAPE)	0,140698 %	Ortalama mutlak yüzde hatası (MAPE)	0,160602 %	Ortalama mutlak yüzde hatası (MAPE)	0,410363 %
Ortalama kare kök yüzde hatası (RMSPE)	0,610805 %	Ortalama kare kök yüzde hatası (RMSPE)	0,240712 %	Ortalama kare kök yüzde hatası (RMSPE)	0,210896 %	Ortalama kare kök yüzde hatası (RMSPE)	0,538003 %
Kalan toplam	-0,0136849 %	Kalan toplam	0,0132951 %	Kalan toplam	-0,0225268 %	Kalan toplam	0,0502631 %
Kalanların standart sapması	0,610757 %	Kalanların standart sapması	0,240246 %	Kalanların standart sapması	0,209532 %	Kalanların standart sapması	0,535582 %
Belirleme katsayısı ( $R^2$ )	0,704909	Belirleme katsayısı ( $R^2$ )	0,997671	Belirleme katsayısı ( $R^2$ )	0,997981	Belirleme katsayısı ( $R^2$ )	0,991809
Korelasyon ( $R$ )	0,9021	Korelasyon ( $R$ )	0,998851	Korelasyon ( $R$ )	0,999035	Korelasyon ( $R$ )	0,995947
Çek Cumhuriyeti		Danimarka		Estonya		Finlandiya	
Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu
Gözlem sayısı	38	Gözlem sayısı	28	Gözlem sayısı	37	Gözlem sayısı	34
Maks. Negatif Hata (MNE)	-0,543219 %	Maks. Negatif Hata (MNE)	-0,151697 %	Maks. Negatif Hata (MNE)	-0,888837 %	Maks. Negatif Hata (MNE)	-0,0735225 %
Maks. Pozitif Hata (MPE)	0,672034 %	Maks. Pozitif Hata (MPE)	0,12526 %	Maks. Pozitif Hata (MPE)	0,711757 %	Maks. Pozitif Hata (MPE)	0,070868 %
Ortalama mutlak yüzde hatası (MAPE)	0,259018 %	Ortalama mutlak yüzde hatası (MAPE)	0,0653917 %	Ortalama mutlak yüzde hatası (MAPE)	0,195356 %	Ortalama mutlak yüzde hatası (MAPE)	0,0216624 %
Ortalama kare kök yüzde hatası (RMSPE)	0,325127 %	Ortalama kare kök yüzde hatası (RMSPE)	0,076781 %	Ortalama kare kök yüzde hatası (RMSPE)	0,279875 %	Ortalama kare kök yüzde hatası (RMSPE)	0,0291779 %
Kalan toplam	-0,00192899 %	Kalan toplam	-0,00380941 %	Kalan toplam	-0,0171243 %	Kalan toplam	0,000137404 %
Kalanların standart sapması	0,325127 %	Kalanların standart sapması	0,0766796 %	Kalanların standart sapması	0,279332 %	Kalanların standart sapması	0,0291779 %
Belirleme katsayısı ( $R^2$ )	0,937902	Belirleme katsayısı ( $R^2$ )	0,999505	Belirleme katsayısı ( $R^2$ )	0,997994	Belirleme katsayısı ( $R^2$ )	0,999932
Korelasyon ( $R$ )	0,971166	Korelasyon ( $R$ )	0,999754	Korelasyon ( $R$ )	0,999003	Korelasyon ( $R$ )	0,999967

Fransa		Kıbrıs		Hırvatistan		Hollanda	
Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu
Gözlem sayısı	50	Gözlem sayısı	37	Gözlem sayısı	38	Gözlem sayısı	38
Maks. Negatif Hata (MNE)	-0,653107 %	Maks. Negatif Hata (MNE)	-0,273886 %	Maks. Negatif Hata (MNE)	-1,50504 %	Maks. Negatif Hata (MNE)	-1,46828 %
Maks. Pozitif Hata (MPE)	1,06594 %	Maks. Pozitif Hata (MPE)	0,325062 %	Maks. Pozitif Hata (MPE)	2,14471 %	Maks. Pozitif Hata (MPE)	0,577788 %
Ortalama mutlak yüzde hatası (MAPE)	0,392327 %	Ortalama mutlak yüzde hatası (MAPE)	0,0804683 %	Ortalama mutlak yüzde hatası (MAPE)	0,390047 %	Ortalama mutlak yüzde hatası (MAPE)	0,322672 %
Ortalama kare kök yüzde hatası (RMSPE)	0,480297 %	Ortalama kare kök yüzde hatası (RMSPE)	0,11503 %	Ortalama kare kök yüzde hatası (RMSPE)	0,639618 %	Ortalama kare kök yüzde hatası (RMSPE)	0,461734 %
Kalan toplam	0,00126225 %	Kalan toplam	0,00124717 %	Kalan toplam	0,0118158 %	Kalan toplam	-0,0511198 %
Kalanların standart sapması	0,480289 %	Kalanların standart sapması	0,115023 %	Kalanların standart sapması	0,639458 %	Kalanların standart sapması	0,458838 %
Belirleme katsayısı ( $R^2$ )	0,995831	Belirleme katsayısı ( $R^2$ )	0,99997	Belirleme katsayısı ( $R^2$ )	0,982765	Belirleme katsayısı ( $R^2$ )	0,993761
Korelasyon ( $R$ )	0,997914	Korelasyon ( $R$ )	0,999985	Korelasyon ( $R$ )	0,991375	Korelasyon ( $R$ )	0,996937
İrlanda		İspanya		İsveç		İtalya	
Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu
Gözlem sayısı	19	Gözlem sayısı	50	Gözlem sayısı	38	Gözlem sayısı	50
Maks. Negatif Hata (MNE)	-1,80262 %	Maks. Negatif Hata (MNE)	-3,73728 %	Maks. Negatif Hata (MNE)	-0,349872 %	Maks. Negatif Hata (MNE)	-1,20162 %
Maks. Pozitif Hata (MPE)	2,66352 %	Maks. Pozitif Hata (MPE)	3,99033 %	Maks. Pozitif Hata (MPE)	0,246391 %	Maks. Pozitif Hata (MPE)	2,3069 %
Ortalama mutlak yüzde hatası (MAPE)	0,746141 %	Ortalama mutlak yüzde hatası (MAPE)	1,68665 %	Ortalama mutlak yüzde hatası (MAPE)	0,101472 %	Ortalama mutlak yüzde hatası (MAPE)	0,696951 %
Ortalama kare kök yüzde hatası (RMSPE)	1,03728 %	Ortalama kare kök yüzde hatası (RMSPE)	2,07639 %	Ortalama kare kök yüzde hatası (RMSPE)	0,129903 %	Ortalama kare kök yüzde hatası (RMSPE)	0,85739 %
Kalan toplam	0,0747511 %	Kalan toplam	0,026006 %	Kalan toplam	0,043044 %	Kalan toplam	0,0512371 %
Kalanların standart sapması	1,03145 %	Kalanların standart sapması	2,07548 %	Kalanların standart sapması	0,129812 %	Kalanların standart sapması	0,855476 %
Belirleme katsayısı ( $R^2$ )	0,979643	Belirleme katsayısı ( $R^2$ )	0,953494	Belirleme katsayısı ( $R^2$ )	0,999575	Belirleme katsayısı ( $R^2$ )	0,921519
Korelasyon ( $R$ )	0,991136	Korelasyon ( $R$ )	0,976474	Korelasyon ( $R$ )	0,999788	Korelasyon ( $R$ )	0,9602

Letonya		Litvanya		Lüksemburg		Macaristan	
Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu
Gözlem sayısı	34	Gözlem sayısı	19	Gözlem sayısı	33	Gözlem sayısı	29
Maks. Negatif Hata (MNE)	-0,273034 %	Maks. Negatif Hata (MNE)	-0,430489 %	Maks. Negatif Hata (MNE)	-0,206595 %	Maks. Negatif Hata (MNE)	-0,104917 %
Maks. Pozitif Hata (MPE)	0,326651 %	Maks. Pozitif Hata (MPE)	0,379081 %	Maks. Pozitif Hata (MPE)	0,250122 %	Maks. Pozitif Hata (MPE)	0,114159 %
Ortalama mutlak yüzde hatası (MAPE)	0,0998153 %	Ortalama mutlak yüzde hatası (MAPE)	0,198324 %	Ortalama mutlak yüzde hatası (MAPE)	0,0865374 %	Ortalama mutlak yüzde hatası (MAPE)	0,0378791 %
Ortalama kare kök yüzde hatası (RMSPE)	0,131867 %	Ortalama kare kök yüzde hatası (RMSPE)	0,222492 %	Ortalama kare kök yüzde hatası (RMSPE)	0,108421 %	Ortalama kare kök yüzde hatası (RMSPE)	0,0523231 %
Kalan toplam	-0,0100298 %	Kalan toplam	0,0129906 %	Kalan toplam	0,00942818 %	Kalan toplam	0,00509864 %
Kalanların standart sapması	0,131522 %	Kalanların standart sapması	0,222106 %	Kalanların standart sapması	0,107774 %	Kalanların standart sapması	0,0520792 %
Belirleme katsayısı ( $R^2$ )	0,999832	Belirleme katsayısı ( $R^2$ )	0,999021	Belirleme katsayısı ( $R^2$ )	0,99995	Belirleme katsayısı ( $R^2$ )	0,999298
Korelasyon ( $R$ )	0,999917	Korelasyon ( $R$ )	0,999513	Korelasyon ( $R$ )	0,999976	Korelasyon ( $R$ )	0,99965
Malta		Polonya		Portekiz		Romanya	
Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu
Gözlem sayısı	30	Gözlem sayısı	36	Gözlem sayısı	38	Gözlem sayısı	38
Maks. Negatif Hata (MNE)	-1,18061 %	Maks. Negatif Hata (MNE)	-0,383161 %	Maks. Negatif Hata (MNE)	-0,373367 %	Maks. Negatif Hata (MNE)	-0,943961 %
Maks. Pozitif Hata (MPE)	0,685744 %	Maks. Pozitif Hata (MPE)	0,439815 %	Maks. Pozitif Hata (MPE)	0,419277 %	Maks. Pozitif Hata (MPE)	0,747657 %
Ortalama mutlak yüzde hatası (MAPE)	0,451235 %	Ortalama mutlak yüzde hatası (MAPE)	0,0852101 %	Ortalama mutlak yüzde hatası (MAPE)	0,162347 %	Ortalama mutlak yüzde hatası (MAPE)	0,313891 %
Ortalama kare kök yüzde hatası (RMSPE)	0,515622 %	Ortalama kare kök yüzde hatası (RMSPE)	0,130544 %	Ortalama kare kök yüzde hatası (RMSPE)	0,199168 %	Ortalama kare kök yüzde hatası (RMSPE)	0,386761 %
Kalan toplam	-0,0264445 %	Kalan toplam	-0,000431142 %	Kalan toplam	0,0144169 %	Kalan toplam	-0,00445813 %
Kalanların standart sapması	0,514838 %	Kalanların standart sapması	0,130544 %	Kalanların standart sapması	0,198502 %	Kalanların standart sapması	0,386752 %
Belirleme katsayısı ( $R^2$ )	0,996664	Belirleme katsayısı ( $R^2$ )	0,974704	Belirleme katsayısı ( $R^2$ )	0,99136	Belirleme katsayısı ( $R^2$ )	0,995917
Korelasyon ( $R$ )	0,998343	Korelasyon ( $R$ )	0,987275	Korelasyon ( $R$ )	0,996245	Korelasyon ( $R$ )	0,997957

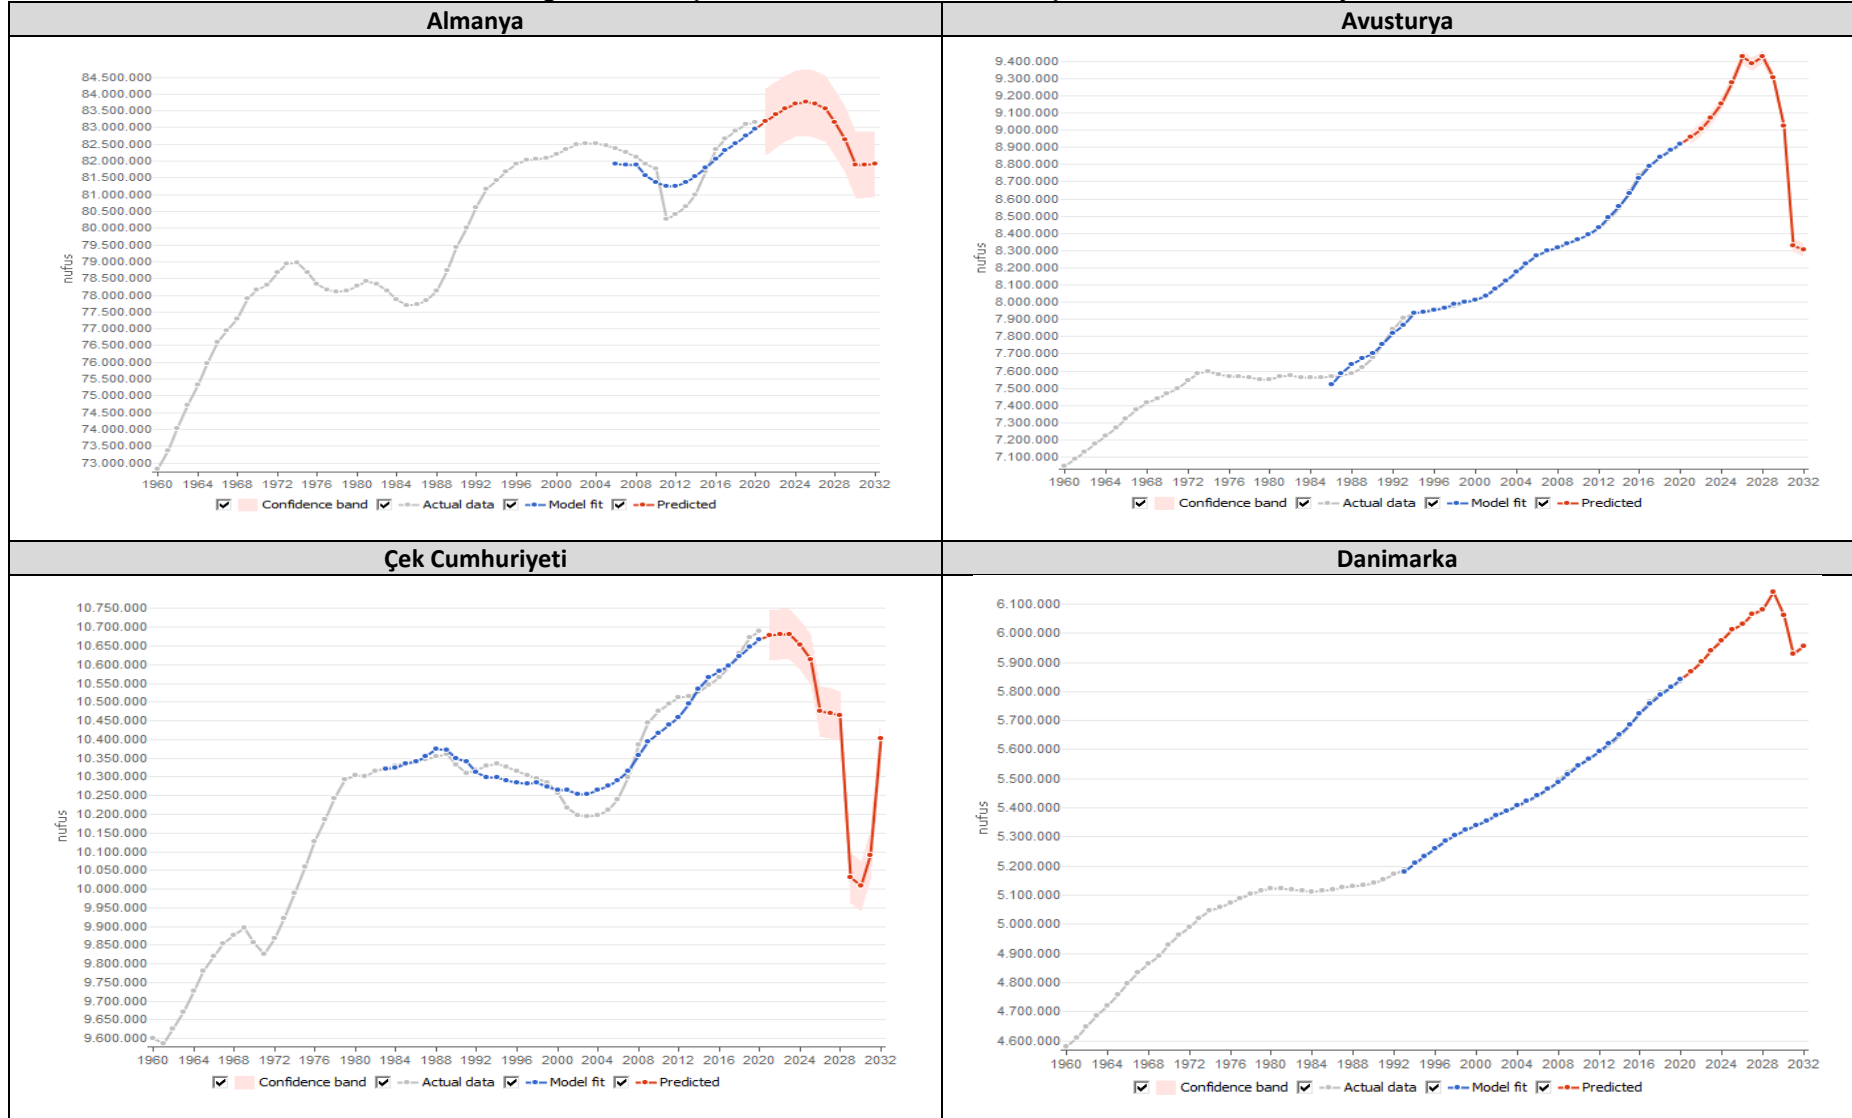



Slovenya		Slovak Cumhuriyeti		Yunanistan	
Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu	Sonradan işlenmiş sonuçlar	Model uyumu
Gözlem sayısı	38	Gözlem sayısı	38	Gözlem sayısı	38
Maks. Negatif Hata (MNE)	-0,742445 %	Maks. Negatif Hata (MNE)	-0,176602 %	Maks. Negatif Hata (MNE)	-0,686633 %
Maks. Pozitif Hata (MPE)	0,919253 %	Maks. Pozitif Hata (MPE)	0,25917 %	Maks. Pozitif Hata (MPE)	0,321433 %
Ortalama mutlak yüzde hatası (MAPE)	0,343803 %	Ortalama mutlak yüzde hatası (MAPE)	0,0874666 %	Ortalama mutlak yüzde hatası (MAPE)	0,150813 %
Ortalama kare kök yüzde hatası (RMSPE)	0,405678 %	Ortalama kare kök yüzde hatası (RMSPE)	0,10811 %	Ortalama kare kök yüzde hatası (RMSPE)	0,196502 %
Kalan toplam	0,0184631 &	Kalan toplam	0,00240327 %	Kalan toplam	0,00504654 %
Kalanların standart sapması	0,405098 %	Kalanların standart sapması	0,108077 %	Kalanların standart sapması	0,196429 %
Belirleme katsayısı ( $R^2$ )	0,961497	Belirleme katsayısı ( $R^2$ )	0,995749	Belirleme katsayısı ( $R^2$ )	0,997183
Korelasyon ( $R$ )	0,981419	Korelasyon ( $R$ )	0,997893	Korelasyon ( $R$ )	0,998592


Tablo 2’de 27 AB ülkesi için gerçek değerlerden elde edilen GMDH-Sinir Ağı yöntemi ile elde edilen tahminlerin performans sonuçları paylaşılmıştır. Elde edilen tahminlerin gerçek değerleri takip etme kabiliyetine sahip olduğu görülmektedir. Maksimum pozitif (MPE) ve Negatif yüzde (MNE) hataları %10’un çok altındadır. RMSPE genellikle tüm ülkelerde yaklaşık %10’nun altındadır,  $R$  ve  $R^2$  değerleri 0,90’nin üzeri hatta genelinde 0,99 civarındadırlar (Almanya  $R^2 = 0,704909$ ’si hariç). Ayrıca elde edilen tahmin değerleri ile gerçek değerler arasında meydana gelen sapmanın oransal ölçümü için uygulanan hata analizine göre ortalama mutlak yüzde hatası MAPE değerleri ise %10’nun altındadır. Bu da Lewis (1982)’e göre modelin çok iyi tahmin yaptığı anlamına gelmektedir.

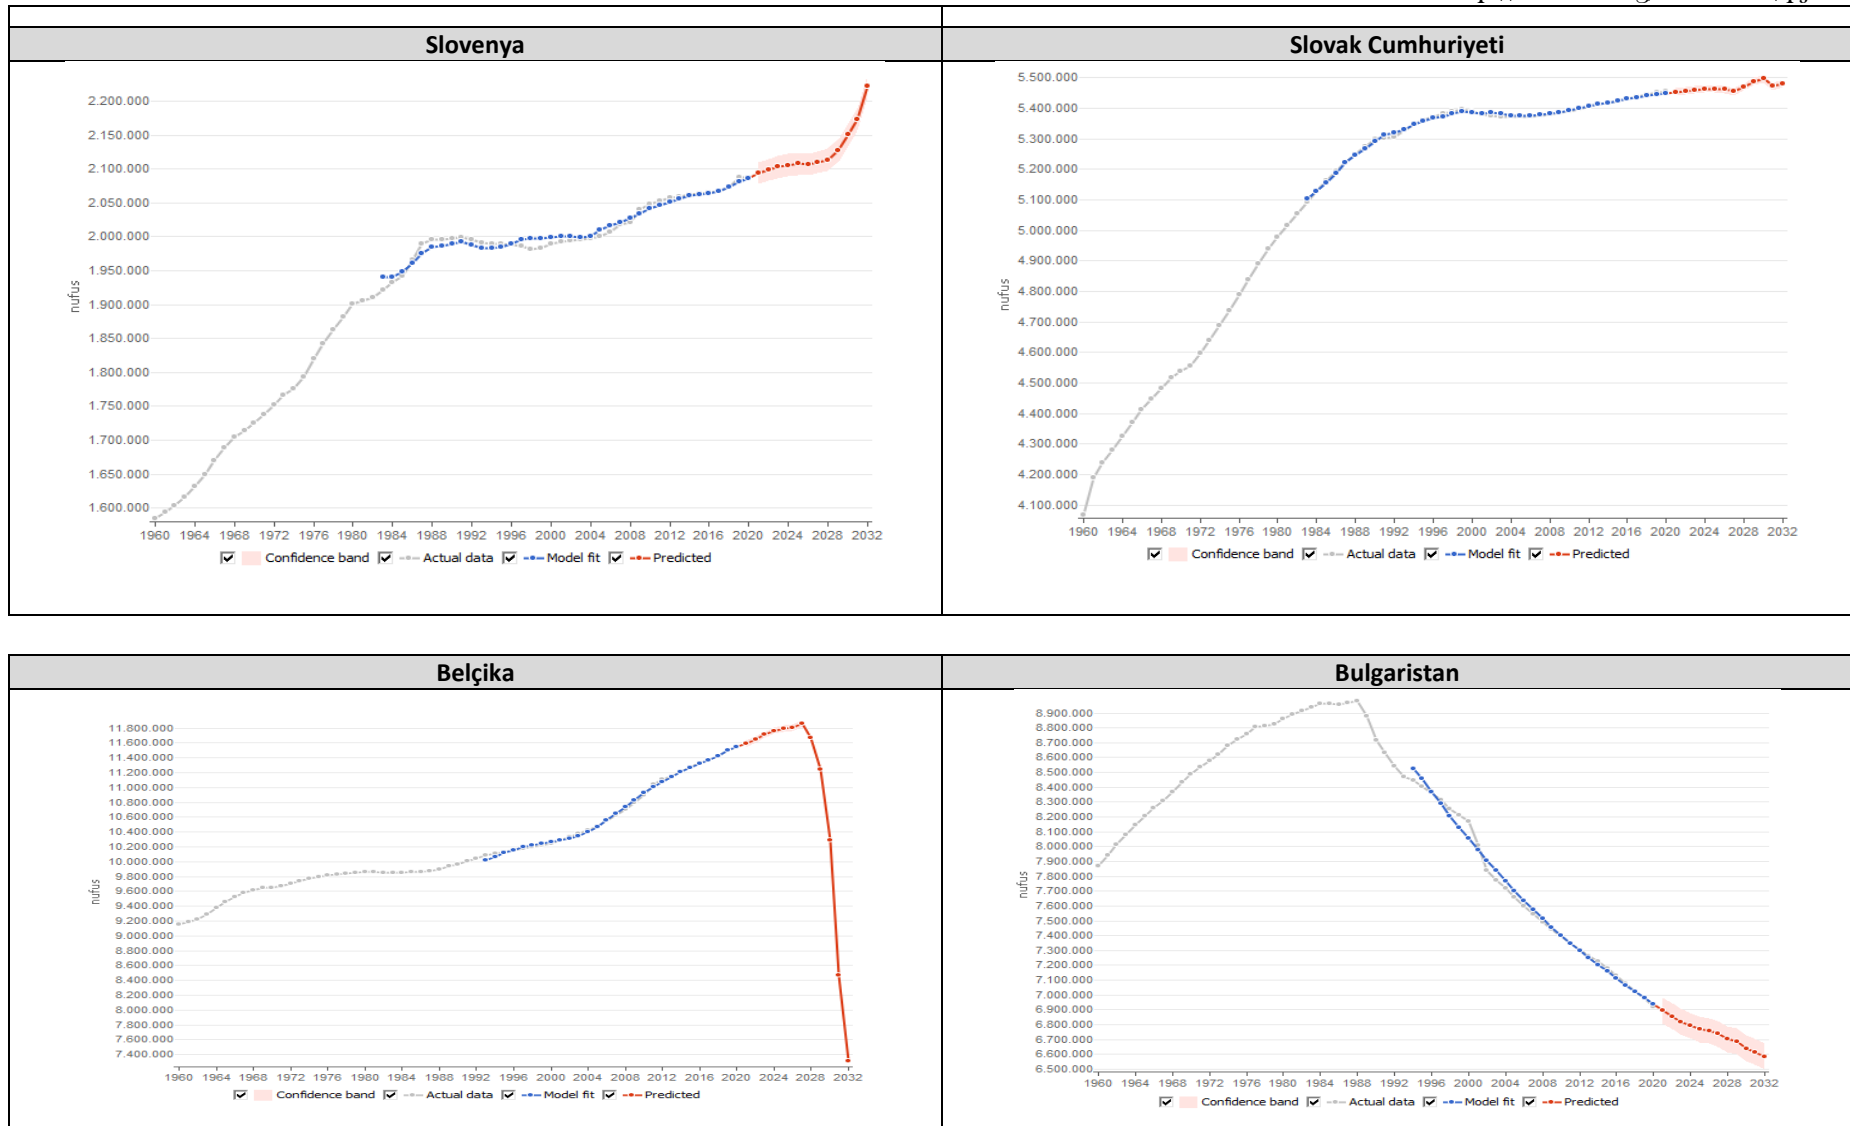
Elde edilen sonuçlar başlık 5.1. de ifade edildiği gibi performans kriterlerine göre GMDH-Sinir Ağı testi 27 AB ülkesinin nüfus tahminlerinde başarılı sonuç vermektedir. Bu test sonuçlarından elde edilen güven bandı, gerçek veriler, model uyumu ve tahmin edilen değerler görseli ise her bir ülke için ayrı ayrı Grafik 1’de paylaşılmış olup, bu yöntemin 27 AB ülkesi için güçlü bir tahmin aracı olduğu görsellerde de görülmektedir.

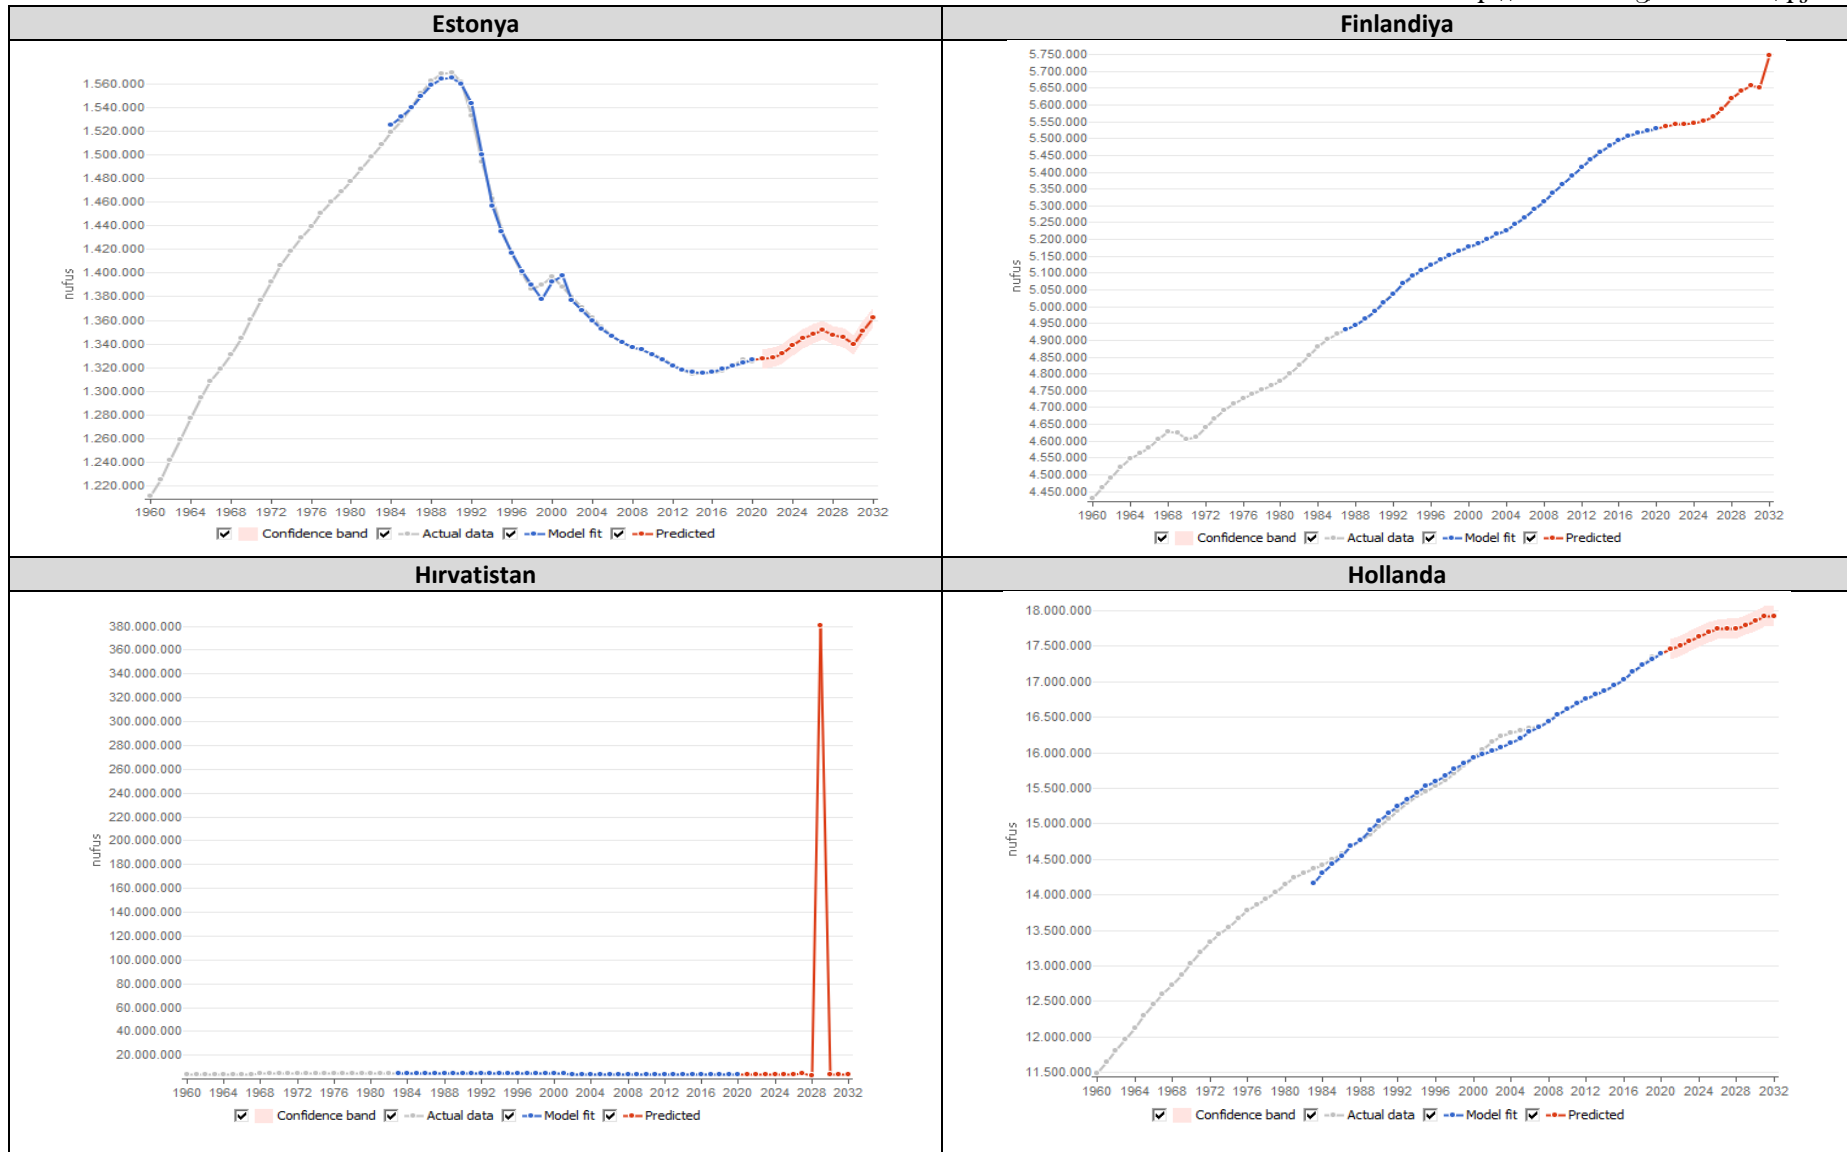
**Grafik 1. GMDH - Sinir Ağı Test Sonuçları:** ■ Güven bandı, --- Gerçek veriler, --●-- Model uyumu, -●- Tahmin Edilen

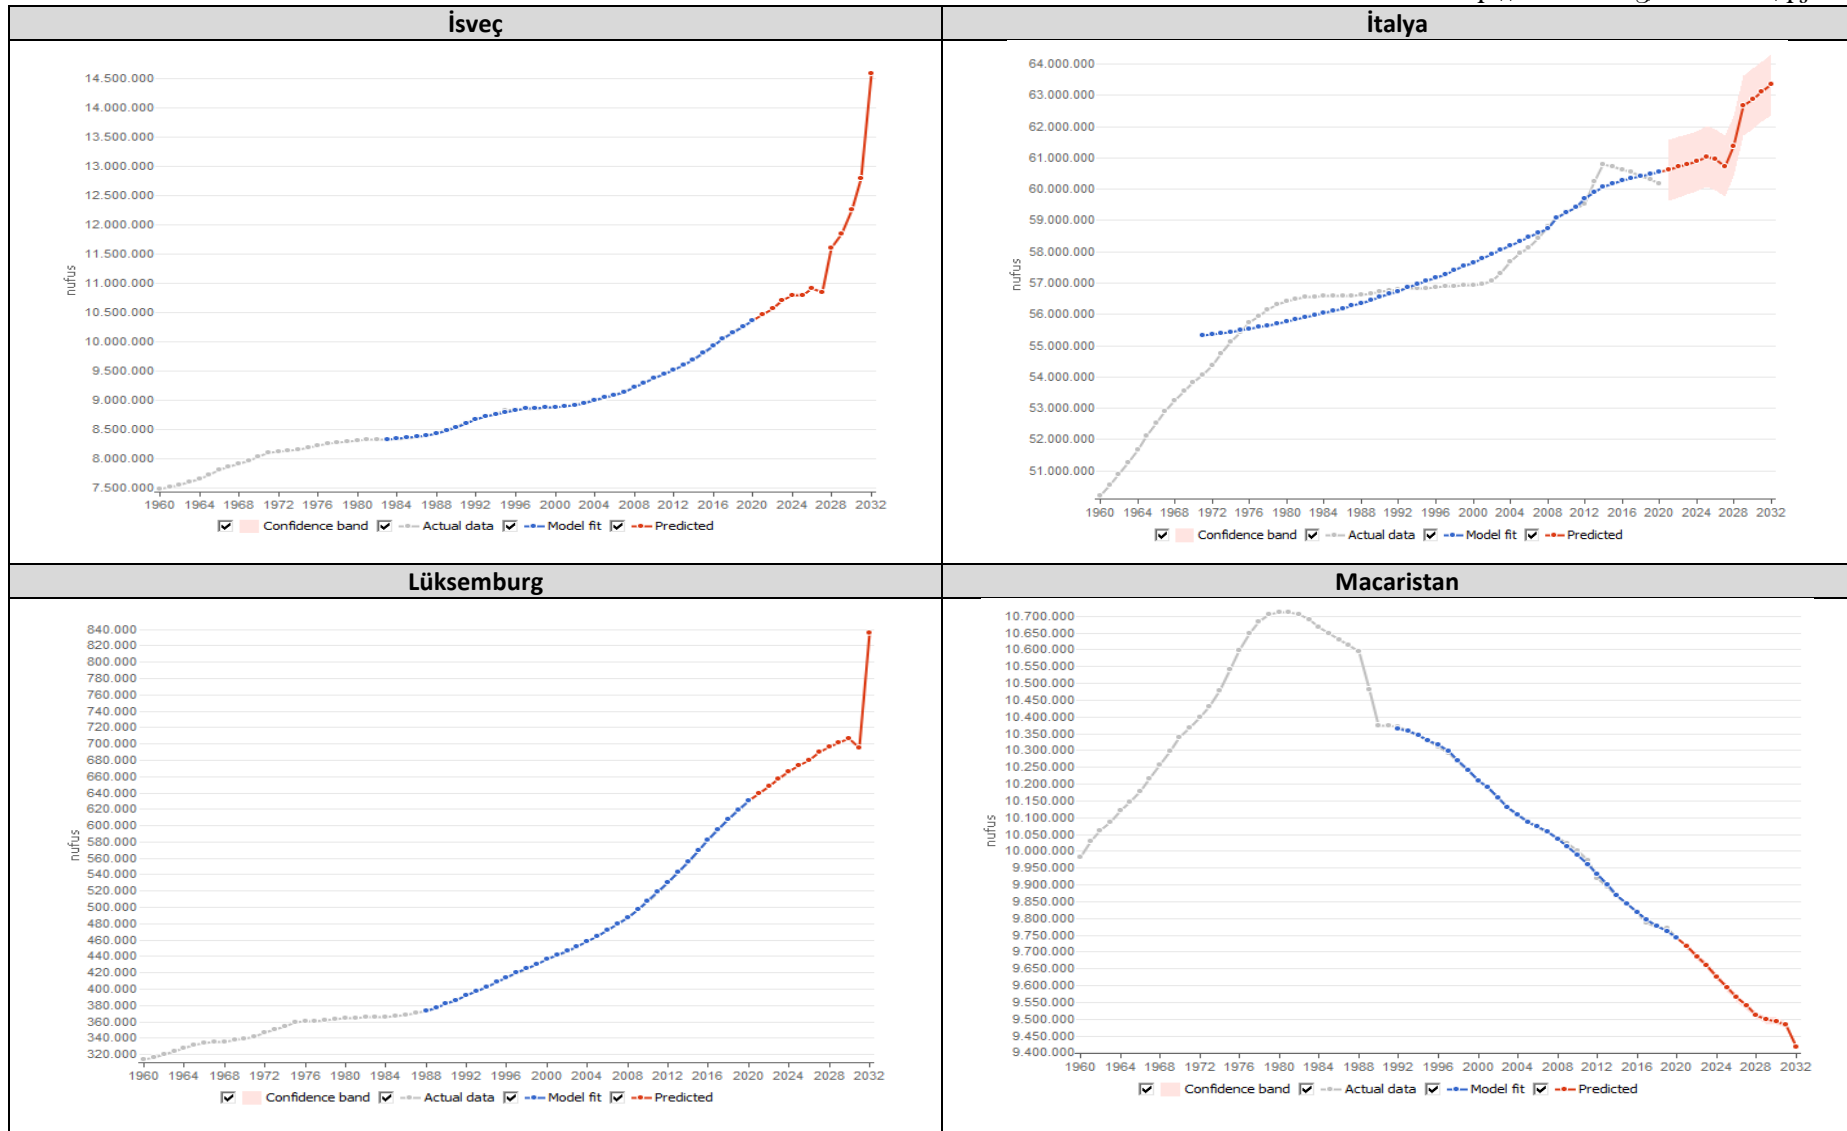

















## 6. SONUÇ

Ülkelerin kalkınma planlarının oluşumunda o ülkenin nüfus yapısı ve büyüklüğü yapının temelini oluşturmaktadır. Çünkü bir ülkenin nüfusu geliri belirlediği gibi o ülkenin ekonomisinde mal ve hizmete olan talep miktarını da belirlemektedir. Yani nüfus yapısı, büyüklüğü ülkenin üretim sisteminin temel girdi faktörüdür. Bu nedenle nüfus ülke ekonomisinde yani kalkınmasında büyük önem taşımaktadır. Bu yüzden ülkenin politika yapıcıları da ülkelerindeki nüfus artışını önceden tahmin etmeyi hedeflemekte ve bu yüzden nüfus projeksiyon yöntemlerini kullanmaktadırlar. Ancak günümüzde özellikle teknolojinin hızla ilerlemesi ve son zamanlarda bilişim çağına olan rağbet, çok fazla verileri kısa sürede doğru ve etkili çözebilen yapay zekâ, makine öğrenmesi, derin öğrenme gibi kavramları açığa çıkarmıştır. Bu nedenle bu çalışmada da 27 AB ülkesinin nüfusu yapay sinir ağı temelli (derin öğrenmenin temelini oluşturan) GMDH Sinir Ağı yöntemi kullanılarak tahmin edilmektedir. Tahmin edilen değerlerin olabildiğince gerçek değerlere yakın olması hedeflenmektedir. GMDH Sinir Ağı da kendi kendini organize eden özelliği, yüksek esnekliği ve zaman tasarrufu sağlaması açısından çeşitli doğrusal olmayan karmaşık sistemlerin tahmini için güçlü bir test yöntemidir.

Bu nedenle bu çalışmada, 27 Avrupa Birliği (AB) ülkelerinin (Almanya, Avusturya, Belçika, Bulgaristan, Çek Cumhuriyeti, Danimarka, Estonya, Finlandiya, Fransa, Kıbrıs, Hırvatistan, Hollanda, İrlanda, İspanya, İsveç, İtalya, Letonya, Litvanya, Lüksemburg, Macaristan, Malta, Polonya, Portekiz, Romanya, Slovenya, Slovak Cumhuriyeti, Yunanistan) yıllık nüfus tahmini için Veri İşleme Grup Yöntemi tipi Sinir Ağı yaklaşımı kullanılmıştır. Veri seti Dünya Veri Bankasından elde edilmiş olup 1960 - 2020 yıllarına ait veriler kullanılarak analiz yapılmıştır. Elde edilen test performansları, genel olarak ortalama yüzde karekök hataları (RMSPE) için %10 altındayken ve belirleme katsayıları ( $R^2$ ) için 0.90 üzeri hatta genel olarak 0.99 civarındadır. Ayrıca elde edilen tahmin değerleri ile gerçek değerler arasında meydana gelen sapmanın oransal ölçümü için uygulanan hata analizine göre ortalama mutlak yüzde hatası MAPE değerleri ise %10'nun altında çıkmıştır. Bütün bu değerler kapsamında modelin çok iyi ve doğru tahmin ettiği sonucuna varılmıştır. Ayrıca yine yapılan analiz Dünya Bankası Veri tabanında bulunan 2021 - 2032 tahmin değerleri ile karşılaştırılmıştır. Elde edilen bulgular ve karşılaştırma sonuçlarına göre GMDH tipi Sinir Ağı'nın 27 AB ülkelerinin yıllık nüfus tahmini için çok iyi bir yaklaşım olduğu geçmiş yıllardaki gerçek değerlerle neredeyse birebir sonuç elde ettiği bu nedenle gelecek yıllar için elde edilen tahminlerinde tutarlı ve gerçeğe çok yakın olduğu sonucuna varılmıştır.

Buradan hareketle, nüfus tahmini üzerine GMDH-Sinir Ağı yöntemi bu çalışmada uygulanmış olup, analizden elde edilen sonuçlar doğrultusunda, nüfus tahmini yapabilmek için GMDH tipi Sinir Ağı yaklaşımının uygun ve başarılı bir yöntem olduğu kanaatine varılarak, yöntem önerilmektedir.

**Kaynakça**

- Adeyinka, D. A., & Muhajarine, N. (2020). Time series prediction of under-five mortality rates for Nigeria: comparative analysis of artificial neural networks, Holt-Winters exponential smoothing and autoregressive integrated moving average models. *BMC medical research methodology*, 20(1), 1-11.
- Ahmad, A. S., Hassan, M. Y., Abdullah, M. P., Rahman, H. A., Hussin, F., Abdullah, H., & Saidur, R. (2014). A review on applications of ANN and SVM for building electrical energy consumption forecasting. *Renewable and Sustainable Energy Reviews*, 33, 102-109.
- Ahmadi, M. H., Ahmadi, M. A., Mehrpooya, M., & Rosen, M. A. (2015). Using GMDH neural networks to model the power and torque of a stirling engine. *Sustainability*, 7(2), 2243-2255.
- Akkaya, A. V. (2021). GMDH-type neural network-based monthly electricity demand forecasting of Turkey. *International Advanced Researches and Engineering Journal*, 5(1), 53-60.
- Anastasakis, L., & Mort, N. (2001). The development of self-organization techniques in modelling: a review of the group method of data handling (GMDH). *RESEARCH REPORT-UNIVERSITY OF SHEFFIELD DEPARTMENT OF AUTOMATIC CONTROL AND SYSTEMS ENGINEERING*.
- Chen, F., & Xu, J. (2006). Factor analysis for well-off construction based on GMDH. *World Journal of Modeling and Simulation*, 2(4), 213-221.
- Çelik., U. (2019) Veri İşleme Grup Yöntemi Türünde Sinir Ağları Algoritması İle Bitcom Fiyat Tahmini. II. International Conference on Emprical Economics and Social Science (ICEESS' 19). *Scientific Committee*, 1322-1330.
- Fallahi, S., Shaverdi, M., & Bashiri, V. (2014). Applying GMDH-type neural network and genetic algorithm for stock price prediction of Iranian cement sector. *Soft-Computing in Capital Market: Research and Methods of Computational Finance for Measuring Risk of Financial Instruments*, 147.
- Farlow, S. J. (1981). The GMDH algorithm of Ivakhnenko. *The American Statistician*, 35(4), 210-215.
- Furuoka, F. (2009). Population growth and economic development: New empirical evidence from Thailand. *Economics Bulletin*, 29(1), 1-14.
- Gerland, P., Raftery, A., Ševčíková, H., Li, N., Gu, D., Spoorenberg, T., Alkema, L., Fosdick, B., Chunn, J., Lalic, N., Bay, G., Buettner, T., Heilig, G., & Wilmoth, J. (2014). World population stabilization unlikely this century. *Science*, 346, 234–237.
- Geweke, J., & Whiteman, C. (2006). Bayesian forecasting. In *Handbook of economic forecasting* (Vol. 1, pp. 3–80). Boston: Elsevier.
- Ghazanfari, N., Gholami, S., Emad, A., & Shekarchi, M. (2017). Evaluation of GMDH and MLP networks for prediction of compressive strength and workability of concrete. *Bulletin de la Société Royale des Sciences de Liège*, 86, 855-868.
- Graziani, R. (2020). Stochastic Population Forecasting: A Bayesian Approach Based on Evaluation by Experts. *Developments in Demographic Forecasting*, 49, 21.

Ivakhnenko, A. G. (1968). The group method of data of handling; a rival of the method of stochastic approximation. *Soviet Automatic Control*, 13, 43-55.

Ivakhnenko, A. G., & Ivakhnenko, G. A. (1995). The review of problems solvable by algorithms of the group method of data handling (GMDH). *Pattern recognition and image analysis c/c of raspoznavaniye obrazov i analiz izobrazhenii*, 5, 527-535.

Jia, X., Di, Y., Feng, J., Yang, Q., Dai, H., & Lee, J. (2018). Adaptive virtual metrology for semiconductor chemical mechanical planarization process using GMDH-type polynomial neural networks. *Journal of Process Control*, 62, 44-54.

Jiang, W., Wang, Y., Li, D., Zhang, M., Ai, H., & Lv, H. (2021). The Establishment and Analysis of Population Growth Forecasting Model Based on Big Data. *Design Engineering*, 447-467.

Lewis, C. D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*. Butterworth-Heinemann.

Li, R. Y. M., Fong, S., & Chong, K. W. S. (2017). Forecasting the REITs and stock indices: group method of data handling neural network approach. *Pacific Rim Property Research Journal*, 23(2), 123-160.

Lutz, W., & Scherbov, S. (1998). An expert-based framework for probabilistic national population projections: The example of Austria. *European Journal of Population*, 14, 1-17.

Mazzuco, S., & Keilman, N. (2020). *Developments in demographic forecasting* (p. 258). Springer Nature.

Metin, S., (2021). Kripto Para Fiyatlarının Regresyon Analizi Yöntemleri İle Tahmini: Bitcoin, Ethereum ve Ripple, 2. Uluslararası Sosyal Bilimler Ve İnovasyon Kongresi 24-25 Mayıs 2021, ANKARA, 591-606.

Moradi, H., Joka, I., & Forouzantabar, A. (2015). Modelling and forecasting gold price using GMDH neural network. *Indian Journal of Fundamental and Applied Life Sciences*, 5(1), 30-41.

National Research Council – NRC. (2000). Beyond six billion: Forecasting the World's population. Panel on population projections. In J. Bongaarts & R. Bulatao (Eds.), *Committee on population, commission on behavioral and social sciences and education*. Washington, DC: National Academy Press.

Onwubolu, G. C. (Ed.). (2014). *Gmdh-methodology And Implementation In C (With Cd-rom)*. World Scientific.

Öztürk, M., Paksoy, T., & Öztürk, Ö. G. M. (2018). Genetik Algoritmalar (GA) İle Nüfus Artış Tahmini. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 11(1), 40-51.

Rezaei, M. H., Sadeghzadeh, M., Alhuyi Nazari, M., Ahmadi, M. H., & Astarai, F. R. (2018). Applying GMDH artificial neural network in modeling CO2 emissions in four nordic countries. *International Journal of Low-Carbon Technologies*, 13(3), 266-271.

R. Shankar, Master's Thesis, University of Delaware, 1972.

Selçuk, İ. A. (2014). Şehir Planlamada Nüfus Kavramı ve Tahmininde Kullanılan Matematiksel Yöntemler. *Artium*, 2(2).

Shen, J., & Spence, N. (1997). Modelling regional population growth in China. *Mathematical Population Studies*, 6(3), 241-274.

Smith, S. K. (1987). Tests of forecast accuracy and bias for county population projections. *Journal of the American Statistical Association*, 82(400), 991-1003.

Tayman, J., & Swanson, D. A. (1999). On the validity of MAPE as a measure of population forecast accuracy. *Population Research and Policy Review*, 18(4), 299-322.

Törnquist, L. (1949). Om de synpunkter, som bestämt valet av de primära prognos-antaganda. *Beräkningar rörande Finlands befolkning, dess reproduktion och framtida utveckling. Statistiska Meddelanden*, 38, 69-75.

United Nations Economic Commission for Europe – UNECE. (2018). Recommendations on communicating population projections (Report no. ECE/CES/STAT/2018/1). Geneva: United Nations

Wang, C. Y., & Lee, S. J. (2021). Regional Population Forecast and Analysis Based on Machine Learning Strategy. *Entropy*, 23(6), 656.

Wei, H., Jiang, Y., & Zhang, Y. (2015). A review of two population growth models and an analysis of factors affecting the Chinese population growth. *Asian J. Econom. Model*, 3(1), 8-20.

Zhang, W. (2008). A forecast analysis on world population and urbanization process. *Environment, Development and Sustainability*, 10(6), 717-730.

Zhang, M., He, C., & Liatsis, P. (2012). A D-GMDH model for time series forecasting. *Expert Systems with Applications*, 39(5), 5711-5716.

<https://databank.worldbank.org/source/health-nutrition-and-population-statistics>, Erişim Tarihi: 21/06/2021.