

Basamak Korelasyon, Kohonen ve ANFIS Yapay Sinir Ağ Modellerinin Sınıflandırma Performanslarının Karşılaştırılması: Lojistik Performans Endeksi Üzerine Uygulama

Comparison of Classification Performances of Cascade Correlation, Kohonen and ANFIS Artificial Neural Network Models: Application on Logistic Performance Index

Ömer Faruk RENÇBER¹

Orcid no: 0000-0001-8020-2750

ÖZET

Küreselleşen dünyamızda, uluslararası pazarda sınırların kalkması ile birlikte, ülkelerin sahip oldukları lojistik imkânlar, küresel rekabet ve uluslararası ticaret entegrasyonu açısından büyük önem arz etmektedir. Dünya Bankası, ülkelerin lojistik gelişmişliklerini değerlendirmek ve öneriler sunmak amacıyla iki yılda bir Lojistik Performans Endeksi(LPE) Raporu yayınlamaktadır. Endeks ile ülkeler; gümrük işlemleri, altyapı, uluslararası sevkiyatlar, lojistik hizmetlerin kalitesi, sevkiyatların izlenebilmesi ve zamanında ulaşmasına göre karşılaştırılmaktadır. Çalışma kapsamında şu sorulara cevap aranmaktadır;

İktisadi açıdan; LPE hesaplamasında kullanılan faktörlerin ülkelerin sınıflandırılmasında etki düzeyleri nelerdir ve endeks ile ülkeler ne kadar doğru sınıflandırılmaktadır?

İstatistiki açıdan; sınıflandırma problemlerinde kullanılan BKSA, LVQ ve ANFIS ağ modellerinden hangisi daha başarılı sonuçlar vermektedir ve farkları nelerdir?

Bu amaçlar doğrultusunda; ağ modelleri 2007, 2010, 2012 ve 2014 yılları LPE ile eğitilmiş daha sonra 2016 yılı LPE ile test edilmiştir. Sonuç olarak; lojistik performans ölçümünde lojistik kalitesi, altyapı ve takip faktörlerinin en önemli oldukları bulgusu elde edilmiştir. Bunun yanı sıra, ülkelerin BKSA ile %92.58, Kohonen ile %91.80 ve ANFIS ile %82.81 oranında doğru sınıflandırıldığı görülmüştür. Dolayısıyla, hem pratik uygulanabilirliği hemde doğru sınıflandırma yüksekliği nedeniyle, BKSA'nın diğer modellere göre çok başarılı olduğu sonucuna ulaşılmıştır.

Anahtar Kelimeler: Basamak Korelasyon, Kohonen, ANFIS, Lojistik Performans Endeksi

ABSTRACT

In globalizing world, with the dearth of borders in international market, the logistical possibilities of countries are of great importance in terms of global competition and international trade integration. The World Bank publishes the Logistic Performance Index (LPE) Report for every two years to evaluate countries' logistical developments and to offer suggestions. With the index; countries are compared according to customs, infrastructure, international shipments, logistic quality and competence, tracking and tracing and timeliness. Within the scope of the study, answers to the following questions are sought;

In terms of economic; What are the impact levels of the factors used in the LPE calculation for the classification of countries and how accurately are the countries classified?

In terms of statistics; Which of the BKSA, LVQ and ANFIS network models give better results for classification problems and what are the differences?

In line with these aims; the network models were trained with LPE for 2007, 2010, 2012 and 2014 and then tested with LPE for 2016. As a result; it has achieved that the logistics quality, infrastructure and timeliness factors are the most important factors in logistics performance measurement. In addition, the countries are correct classified as rate of 92.58% with BKSA, 91.80% with Kohonen and 82.81% with ANFIS. So, it has reached that because of both practical applicability and high classification accuracy, BKSA is very successful compared to other models.

Keywords: Cascade Correlation, Kohonen, ANFIS, Logistic Performance Index

1. GİRİŞ

20.yy başlarından bu yana yaşanan teknolojik gelişmeler ile birlikte ticarete sınırların kalması ve rekabetin daha sert hale gelmesi uluslararası ticaretteki başarı parametrelerini büyük oranda değiştirmiştir. Özellikle, küresel düzeyde artan ticaret hacmi ile birlikte üretilen ürünlerin nakliyesi, depolanması, gümrükleme işlemleri gibi faaliyetlerin önemi de gün geçtikçe daha da artmaktadır. Dünya Ticaret Örgütü verilerine göre; dünyada üretilen mal veya hizmetlerin toplam bedeli 1960 yılında 1,5 trilyon civarında iken, 2015 yılında 74,5 trilyon dolar, 2016 yılında ise 75,5 trilyon dolardır. Bu durum, özellikle son 50 yıl içerisinde dünyada üretimin ve ticaret hacminin ne düzeyde arttığına en önemli göstergesi olarak değerlendirilebilir.

Küreselleşmenin her ülkeyi etkilediği söylenebilirken bunun her ülke için aynı düzeyde gelişmeye katkı sağladığı söylenemeyebilir. Uluslararası ticarete ülkeler arasındaki lojistik hizmet kalitesindeki farklılıklar bulunmaktadır. Örneğin, gümrükte yaşanan resmi bürokratik işlemler bazı ülkelerde çok kolay ve hızlı iken başka ülkelerde zor olabilmektedir. Benzer olarak, taşıma olanakları da ülkeden ülkeye göre değişebilmektedir. Günümüzde bu farklılıklar nicel olarak Lojistik Performans Endeksi (LPE) olarak ifade edilen bir endeks ile ölçülmektedir. Endeks, Dünya Bankası tarafından iki yılda bir hesaplanmakta olup ülkelerin uluslararası ticarete lojistik faaliyetler açısından gösterdikleri performans ve gelişmişlikleri incelemektedir. Endeks, lojistikte performansın ve gelişmişliğin belirleyicileri olarak görülebilecek altı temel konuyu esas almaktadır. Bunlar; gümrük işlemleri, lojistik altyapı, uluslararası sevkiyatlar, lojistik hizmetlerin kalitesi ve yetkinliği, sevkiyatların takibi/izlenebilmesi ve sevkiyatların alıcıya zamanında ulaşmasıdır(LPE Raporu, 2016). Şu ana kadar açıklanan 2007, 2010, 2012, 2014

ve 2016 yılları için endeks sıralamasına göre en yüksek lojistik gelişmişliğe ve performansa sahip 10 ülke tablo 1'deki gibidir.

Tablo 1'de görüldüğü üzere, Singapur ve Almanya genellikle en yüksek lojistik performansa sahip ülkelerdir. Bununla birlikte, her ne kadar sıralama değişse de, ülkelerin genellikle yıllara göre yakın sıralarda oldukları görülmektedir. Endeks ile ülkeler 2016 yılına kadar sadece sıralanırken, 2016 yılı raporunda sıralamaya dayalı beşte birlik dilime göre sınıflandırılmıştır. Buna göre ülkeler; lojistik dostu, istikrarlı ve kısmen lojistik performansa sahip ve lojistik dostu olmayan ülkeler olarak sınıflandırılmıştır.

Bu çalışmada, iktisadi ve istatistiki açıdan iki tür amaç bulunmaktadır. İktisadi açıdan; ülkelerin LPE'ne göre ne düzeyde doğru sınıflandırıldığı ve hangi göstergelerin endeks ölçümünde etkili olduğunun saptanması amaçlanmıştır. İstatistiki açıdan ise, basamak korelasyon (BKSA), Kohonen (LVQ) ve Bulanık tabanlı ANFIS sinir ağı modellerinin sınıflandırma performanslarının karşılaştırılması amaçlanmıştır. Bu kapsamda LPE'nin hesaplanmasında kullanılan göstergeler dikkate alınarak üç yöntemle göre ülkeler yeniden sınıflandırılmış ve karşılaştırılmıştır.

2. LOJİSTİK YÖNETİMİ VE LOJİSTİK PERFORMANS ENDEKSİ

Dünyamızda artan teknolojik imkanlar ve bu doğrultuda yaşanan gelişim ve değişimlerin sonucu olarak; dünya pazarında sınırlar kalkmakta ve dünyamız küresel bir köy halini almaktadır(Pupavac, Draskovic, 2017). Bu durum ile bölgesel lojistik ve küresel lojistik faaliyetleri olarak tanımlanan iş ve işlemler, uluslararası ticaret entegrasyonu açısından büyük önem arz etmektedir.

Tablo 1: LPE'ne göre ilk 10 sırada yer alan ülkeler

Sıralama	2007	2010	2012	2014	2016
1	Singapur	Almanya	Singapur	Almanya	Almanya
2	Hollanda	Singapur	Çin	Hollanda	Lüksemburg
3	Almanya	İsveç	Finlandiya	Belçika	İsveç
4	İsveç	Hollanda	Almanya	İngiltere	Hollanda
5	Avusturya	Lüksemburg	Hollanda	Singapur	Singapur
6	Japonya	İsviçre	Danimarka	İsveç	Belçika
7	İsviçre	Japonya	Belçika	Norveç	Avusturya
8	Çin	İngiltere	Japonya	Lüksemburg	İngiltere
9	İngiltere	Belçika	ABD	ABD	Çin
10	Kanada	Norveç	İngiltere	Japonya	ABD

Temel anlamda lojistik kavramının birçok tanımı bulunmaktadır. Tedarik Zinciri Konseyi Yönetim Profesyonelleri'ne göre lojistik; "Müşteri isteklerini karşılamak üzere hammaddenin başlangıç noktasından, ürünün tüketildiği son noktaya kadar olan tedarik zinciri içindeki malzemelerin servis hizmetlerinin ve bilgi akışının etkili ve verimli bir şekilde her iki yöne doğru hareketinin ve depolanmasının, planlanması, uygulanması ve kontrol edilmesi" olarak tanımlanmaktadır(CSCMP, 2018).

Lojistik yönetimi; lojistik faaliyetlerinin sahip olduğu zaman, para ve altyapı gibi kaynakların iyileştirilmesi, optimum düzeyde kullanılabilmesi amacıyla ele alınan yönetsel faaliyetlerin bütünü olarak tanımlanabilir. İşletme düzeyinde lojistik yönetiminin temel faaliyetleri; nakliye, depolama, envanter yönetimi, elleçleme, sipariş işleme, ambalajlama, satın alma ve enformasyon yönetimidir(Bayır ve Yılmaz, 2017:73). İşletmelerin uluslararası düzeyde yürüttükleri dış ticarete kendi lojistik kabiliyetleri kadar ülkelerin lojistik gelişmişlikleri de ön plana çıkmaktadır.

İşletme düzeyinde lojistik performansı; "lojistik sektör veya lojistik hizmet üreten firmaların kendi stratejik planları çerçevesinde belirli bir dönem sonunda elde ettikleri hizmet çıktısının veya önceden belirlenmiş kendi lojistik görevlerine yönelik oluşturulan; amaçlara, politikalara, stratejilere, taktiklere, planlara ve hedeflere ne derece ulaşıldığını veya belirlenen standartlara ne derece yaklaştığını kurumsal açıdan ifade etmesi ile ilgili çalışmalar bütünü" olarak tanımlanmaktadır(Demircanlı ve Kundakçı;2015:110). Uluslararası düzeyde lojistik performansı ise ülkenin sahip olduğu bütün lojistik faaliyetlerindeki gelişmişlik düzeyi olarak tanımlanabilir. Bu durumda, lojistik performansın ülkenin iktisadi gelişmişliğini ifade ettiği söylenebilir. Benzer şekilde, yüksek lojistik maliyetleri ve düşük hizmet anlayışı ülkelerin kalkınma politikası karşısında önemli engellerden biri olarak görülmektedir(Dağdeviren, Akay ve Kurt,2004:133).

Lojistik Performans Endeksi, bir başka ifadeyle Lojistik Gelişmişlik Endeksi, Dünya Bankası tarafından ülkelerin rekabet güçlerinin değerlendirilmesi açısından birbirlerini karşılaştırabilmeleri ve uluslararası ticaret anlamında kendi yetkinliklerini görebilmeleri amacıyla geliştirilmiştir. Endeks; 2007, 2010, 2012, 2014 ve 2016 yılları kapsamında iki yılda bir yayınlanmaktadır.

Endeks, ülkelerin denizaşırı ticaret faaliyetlerindeki altı temel konuya odaklanmaktadır. Bunlar; gümrük işlemleri, lojistik altyapı, uluslararası sevkiyatlar,

lojistik hizmetlerin kalitesi ve yetkinliği, sevkiyatların takibi/izlenebilmesi ve sevkiyatların alıcıya zamanında ulaşmasıdır.

Endeksin altyapısını oluşturan veri seti anket yöntemiyle elde edilmektedir. Bu anlamda LPE, dünya genelinde uluslararası ekspres taşımacılar ve lojistik uzmanları ile yapılan kapsamlı bir anket çalışmasının bir sonucudur. Anket, 10-15 sorudan oluşmakta olup, gelir grubuna göre belirlenen örnekleme uygulanmaktadır. Örneğin, 2016 yılında 1000 uluslararası taşımacılık yapan acenteler ile 6000 civarı anket uygulaması yapılmıştır. Anketin birinci kısmında ülkelerin komşu ülkedeki yaşanan sıkıntıları ve kolaylıkları dikkate alarak anketi çok zor/çok kolay niceleme sıfatları ile değerlendirmeleri istenmektedir. Eğer ülke bir ada ise en yakın kara köprü bağlantısı neredeyse onunla alakalı değerlendirme yapılmaktadırlar. Bu şekilde 2016'da, lojistik uzmanları tarafından 7000'den fazla anket uygulaması ile değerlendirme yapılmıştır. 2016 LPE raporuna göre ülkeler, aldıkları puana göre, dört farklı kategoride sınıflanmaktadır. Skorların büyükten küçüğe göre sıralanması ile ülkeler beş gruba ayrılmış olup, ilk dilimde yer alan ülkeler "Lojistik dostu", ikinci dilimde yer alan ülkeler "istikrarlı performans sergileyenler", üçüncü ve dördüncü dilimde yer alan ülkeler "kısmen performans gösteren" ve beşinci dilimde yer alan ülkeler "lojistik dostu olmayan" olarak sınıflandırılmaktadır.

Anketin ikinci kısmında ise ülkelerin kendi lojistik ve uluslararası tedarik zinciri yönetim faaliyetleri hakkında niceliksel bilgiler vermesi istenmektedir. Bu şekilde oluşturulan veri setine temel bileşenler analizi uygulanarak altı faktörden oluşan bir yapı elde edilmektedir. Daha sonra bu faktörlerin ortalaması alınarak o ülkenin LPE değeri bulunmaktadır. Örnek olarak, Türkiye'nin LPE için yıllara göre performans değişimi tablo 2'deki gibidir.

Tablo 2: Türkiye'nin LPE'ne göre performans tablosu

	2007	2010	2012	2014	2016
LPE Sıralama	34	30	27	39	34
LPE Skoru	3,42	3,5	3,51	3,22	3,15

Tablo 2'de görüldüğü üzere, Türkiye'nin açıklanan endekslerde sıralama ve skor açısından büyük oranda bir değişim görülmemektedir. Bu durum, diğer ülkeler için de geçerli olup aynı zamanda anketin objektif ve tutarlı doldurulduğunu da göstermektedir.

3. LİTERATÜR İNCELEMESİ

Literatürde LPE ile ilgili birçok çalışma bulunmaktadır. Bu çalışmaların genellikle ülkelerin lojistik durumlarının yorumlanması ve incelenmesi hakkında olduğu söylenebilir. Çalışmanın bu bölümünde lojistik performans ölçümü ve endeksi ile ilgili daha önce yapılan çalışmaların kısa özetlerine yer verilmiştir.

Kara, Tayfur ve Basık'a göre (2009) bir ülkenin küresel ticarete lojistik üs olabilmesi için coğrafik, fiziki ve kurumsal altyapısının güçlü olması gerekmektedir. LPE kapsamında yapılan değerlendirmede; Türkiye'nin bir lojistik üs olabilmesi için kombine taşımacılık, bilgi teknolojileri, yasal, finansal ve yönetsel kurumsal alanda iyi olması gerekmektedir.

Lau (2011), çalışmasında Çin ve Japonya kapsamında yeşil lojistik performans endeksini hesaplamıştır. Çalışmada üretilen endeks değeri ile şirketlerin ötesinde ülkenin lojistik performansı ölçümünde farklı bir bakış açısı getirmiştir.

Bayraktutan, Tüylüoğlu ve Özbilgin (2012), çalışmalarında LPE sıralamasında Türkiye'nin durumunu yorumlayarak benzer bir değerlendirmeyi Türkiye'de iller düzeyinde yapmışlardır. Özel olarak Kocaeli'nin lojistik performansının incelendiği çalışmada, LPE ölçümüne benzer olarak anket yöntemi uygulamışlardır. Sonuç olarak, Kocaeli'nin lojistik performansı açısından Türkiye'de iyi bir konumda olduğu bulgusuna ulaşmışlardır.

Sofyalıoğlu ve Kartal (2013) çalışmalarında Türkiye ile Avrasya Ekonomik Topluluğu ülkelerini lojistik performans indekslerine göre karşılaştırmışlardır. Yazarlar çalışmalarında Türkiye'nin Asya ve Avrupa kıtalarını bağlaması nedeniyle jeopolitik açıdan çok büyük öneme sahip olduğunu vurgulamışlardır. Bununla birlikte Türkiye'nin rekabet gücü kazanabilmesi için demiryolu, denizyolu, havayolu ve boru hatlarından oluşan lojistik alt yapısına sahip olmasının zorunlu olduğunu ifade etmişlerdir.

Marti, Puertas ve Garcia'ya göre (2014) lojistik ve taşımacılık uluslararası ilişkilerde artan bir öneme sahiptir. 2007-2012 yılları arasında kapsayan çalışmada ülkeler, LPE değerlerine ve uluslararası ticaret hacimleri arasındaki ilişkiyi incelemişlerdir. Çalışmanın sonucunda, LPE'nin ve özellikle bileşenlerinin ticaret akışında artan öneme sahip olduğu bulgusuna ulaşmışlardır.

Bayat ve Özdemir (2016), çalışmalarında lojistik performansın ölçümünde kullanılacak göstergeleri incelemişlerdir. Buna göre çalışmada, LPE kapsamında

ulaşılabilir ve düzenli yayınlanan farklı göstergeler ve veri setleri hakkında bilgi vermişlerdir.

Pupavac ve Draskovic (2017), çalışmalarında bazı Avrupa ülkeleri için LPE ile bileşenlerini karşılaştırmışlardır. Bu bağlamda endeks değeri ile bileşenlerin güçlü ve anlamlı ilişkiye sahip oldukları, aynı zamanda bileşenlerden lojistik altyapının LPE'de en önemli etkiye sahip olduğu sonucuna ulaşmışlardır.

Wang ve Yang (2017), çalışmalarında ülkelerin lojistik performans ölçümlerini incelemişlerdir. Yazarlara göre, lojistik performans ölçümünde aynı zamanda ülkelerin ulusal stratejilerinin de dikkate alınması gerektiği savunulmaktadır. Yılmaz ve Yılmaz (2017) çalışmalarında AB ülkelerinin lojistik performanslarını, LPE kapsamında, Analitik Hiyerarşi Proses ve VIKOR yöntemleri ile hesaplamışlardır. 2016 yılı ve 20 Avrupa ülkesini kapsayan çalışmada LPE'ye alternatif bir ağırlıklandırma ve hesaplama önerisi geliştirmişlerdir.


Jhavar ve Garg (2018)'e göre lojistik performansındaki iyileşme; doğrudan yabancı yatırım ve uzun süreli ekonomik büyüme açısından oldukça önemlidir. Buna göre, lojistik performansı yüksek olan ülkelerde doğrudan yabancı yatırım daha kolay gelmekte ve ülkenin geliri de buna bağlı olarak artmaktadır.

4. YÖNTEM

Çalışmada, istatistiki açıdan; Basamak Korelasyon, Kohonen ve ANFIS yapay sinir ağ modellerinin sınıflandırma performanslarının incelenmesi amaçlanmaktadır. Bu nedenle; bu bölümde, yapay sinir ağı yöntemi ve ağ modelleri teorik olarak anlatılmıştır.

4. 1. Yapay Sinir Ağı

Yapay sinir ağı, biyolojik sinir ağının matematiksel olarak benzetimine dayanan yapay zekâ yöntemlerinden bir tanesidir. Buna göre yapay sinir hücresi; bir olayı verilere dayanarak danışmanlı veya danışmansız öğrenerek daha sonra hiç görmediği benzer örnekler hakkında tahminde bulunan bir sisteme sahiptir. Bununla birlikte YSA; örüntü tanıma, sınıflandırma, modelleme, optimizasyon ve tahmin gibi amaçlar için kullanılmaktadır. YSA'nın yapısı çoklu girdiden bir çıktı üretmeye dayanmaktadır. Örnek olarak, yapay sinir ağı modeli şekil 1'deki gibidir (Şen, 2004).



Şekil 1: Yapay Sinir Ağı Modeli

Bir yapay sinir ağı beş temel bileşenden oluşmaktadır. Bunlar; girdi, ağırlık, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktıdır (Şen, 2004). Girdi, YSA'nın öğrenilmesinin istendiği veri setidir. Ağırlıklar, girdilerin çıktılara eşleşmesinin yapıldığı en önemli eğitim aracıdır. Buna göre ağırlıklar değiştirilerek girdiler çıktılar ile eşleştirilir. Bu kısımda ağırlıkların nasıl belirleneceği ve nasıl değiştireceği öğrenme algoritmaları ile yapılmaktadır. Bu öğrenme algoritmalarından bazıları; geri yayılım, delta bar delta, geliştirilmiş delta bar, yönlendirilmiş rassal tarama, LVQ, olasılıklı YSA, Hopfield, Boltzman Makinası, ART, SOM, ANFIS ve Basamak korelasyon sinir ağıdır. Bunların her biri farklı algoritmalara dayanarak farklı amaçlar doğrultusunda ağırlık değişimini öğrenmesini sağlamaktadır.

Toplama fonksiyonunda girdiler ağırlıklar ile çarpılıp toplanmaktadır. Aktivasyon fonksiyonu, toplama fonksiyonu neticesinde elde edilen değer bir fonksiyondan geçirilerek çıktıya yönlendirildiği aşamadır. Eğer aktivasyon fonksiyonu sonucu eşik değer altındaysa değer çıktıya dönüştürülmez aksi durumda çıktı üretilir. Burada kullanılan fonksiyonlar; doğrusal, adım, eşik, sigmoid, hiperbolik ve Gaussian tipi fonksiyonlardır. Ağırlık değişimini öğrenme aşaması olan çıktı ise, transfer fonksiyonunun neticesi olarak elde edilen değer yapay sinir ağına çıktı değeri olup başka bir sinire girdi veya dış ortama çıktı olarak gönderilebilir.

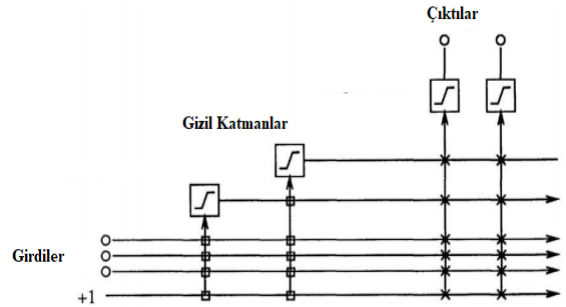
Literatürde YSA yönteminin sınıflandırma amacıyla uygulandığı birçok çalışma bulunmaktadır. Örneğin, pazar segment (Fish, Barnes ve Aiken, 1995), finansal başarı (Zhang vd. 1999), sağlık durumları (Ottenbacher vd. 2001), gen (Chandra ve Babu, 2014), eğitim başarısı (Toprak, 2017) sınıflandırmaları bu çalışmalardan bazılarıdır.

4.1.1. Basamak Korelasyon Sinir Ağı

Basamak korelasyon sinir ağı, ileri beslemeli danişman eğitim sürecine sahip kendini organize edebilen bir ağ modelidir. İlk defa 1990 yılında Fahlman ve

LeBiere tarafından geri yayımlı öğrenme mantığına alternatif olarak geliştirilmiştir (Şengöz ve Özdemir, 2017:127). Geri yayılım algoritmasına sahip bir sinir ağına eğitim, girdiden çıktıya doğru olmaktadır. Aynı zamanda tahmini çıktı ile gerçek çıktı arasındaki hata çıktıdan girdiye doğru geri yayılmaktadır (Michie, Spiegelhalter ve Taylor, 1992:97).

Bir yapay sinir ağına eğitimi, girdilere verilen ağırlıkların değişimi ile mümkün olmaktadır. Buna göre bu ağırlıkların nasıl belirlendiği ve eğitime göre nasıl güncellendiği önemli bir konudur. Klasik bir yapay sinir ağına ağırlıklar rastgele belirlenir ve eğitim süresince güncellenerek devam eder. Daha sonra eğer ağırlıklarda anlamlı bir değişiklik olmuyorsa ağına eğitimi sonlandırılır. BKSA'da ise eğitim önce küçük bir ağı başlar ardından teker teker gizli düğüm sayısı artırılarak çok katmanlı ağı yapısı elde edilir. Her gizli katman eklenmesinde önceki eğitim ağırlıkları dondurulur ve bu şekilde önceki ağına eğitim hatası bir sonraki ağına eğitimini etkilemez (Fahlman ve Lieberman, 1992:528). Örnek bir BKSA yapısı Şekil 2'deki gibidir.



Şekil 2: Basamak Korelasyon Sinir Ağı Modeli

Şekil 2'de görüldüğü üzere ağda üç girdi ve iki çıktı bulunmaktadır. Buna göre ağına eğitiminde başlangıçta bir gizli katman kullanılmış ancak daha sonra ikiye çıkarılmıştır. Bu özelliğinden dolayı BKSA'na katmanlı sinir ağı da denilmektedir. Şekil 2'de kutu olarak görünen kısımlarda ağırlık değişimini dondurulmuştur. Bunun nedenle ağına eğitim sürecinde her iterasyon neticesinde oluşan hata daha önceki eğitimi etkilemez. Bu yönüyle geri yayımlı sinir ağı algoritmasından farklılık içermektedir. Yıldız (*) olarak görünen yerlerde ise ağına eğitimi devam etmektedir. Girdiler ile aynı yönde bulunan (+1) ise ağına eğitim durumuna göre yeni bir gizli katman eklenip eklenmeyeceğinin belirlenmesinde kullanılmaktadır. Bu kısım eğitim süresince bu şekilde devam etmektedir.

BKSA'da eğitim; ağıdaki çıktı ile artık hata arasındaki korelasyonun maksimize edilmesi mantığına

dayanmaktadır. Eğitim sürecinde nöronlardan oluşan bir aday havuzu oluşturur daha sonra bu havuzdan aşağıda belirtilen denkleme göre korelasyonun maksimum olduğu nöron belirlenir.


$$s = \sum_0^p \left| \sum_p (V_p - \bar{V}) \cdot (E_{p,0} - \bar{E}_0) \right| \quad (1)$$

Denklem (1)'de V gizli katmandaki çıktıyı, E ise çıktıların artık hatasını ifade etmektedir. Denklem ile hesaplanan korelasyon değerinin maksimum olduğu noktada eğitim sonlandırılır. Bu noktanın tespitinde ise gradyan düşüş optimizasyon tekniği kullanılmaktadır. Bu şekilde ağı eğitimi devam etmekte ve istenilen düzeye ulaşıldığında da sonlandırılmaktadır.

Literatüre göre BKSA yönteminin bir çok alanda uygulandığı görülmektedir. Örneğin; BKSA'nın, hisse senedi getiri tahmini (Velusamy ve Amalraj, 2017), ürün kalite başarısı sınıflandırma (Spoerre, 1997), troit hastalığının teşhisi (Şenol ve Yıldırım, 2009), (Sharma ve Mukharjee, 2013), ses sınıflandırma (Ankışhan ve Yılmaz, 2013) konularında uygulandığı görülmektedir.

4.1.2. Kohonen Ağı (LVQ: Linear Vector Quantization)

LVQ ağı ilk defa, 1984 yılında Kohonen tarafından geliştirilen denetimli ağ yapısına sahip bir yapay sinir ağı modelidir. Buna göre, nöronlar bir vektör olarak görülmekte olup temel amaç; girdi vektörlerinin hangi çıktı vektörü ile eşleşebileceğinin bulunmasıdır. Ağı eğitiminde girdiler çıktıya dönüştürülürken çıktı sayısı kadar ağırlık rastgele olarak belirlenir. Ardından "kazan her şeyi alır" stratejisine göre en yüksek ağırlığa sahip çıktı için 1, diğerleri için 0 değeri verilir. Buna göre, her bir karar birimi bu mantığa göre eşleştirilir ve böylece girdiler çıktıya dönüştürülmüş olur. LVQ ağı genellikle sınıflama için kullanılan bir ağ modeli olup yapısı şekil 3'deki gibidir.

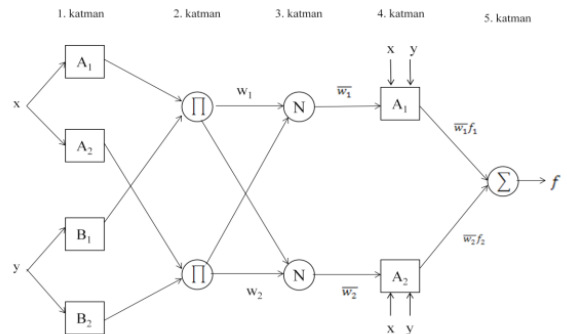


Şekil 3: LVQ ağı yapısı

Şekil 3'e göre örnek ağ modelinde üç girdi ve N tane çıktı vardır. Çıktı vektör setine aynı zamanda referans vektör de denilmektedir. Girdiler ve çıktılar bir vektör olarak sisteme girilmektedir. Örneğin, üç girdili bir karar birimi için girdi vektörü $[x_1, x_2, x_3]$ ve iki sınıflı bir çıktı için vektör $[0, 1]$ veya $[1, 0]$ şeklinde olmaktadır. Burada 1 değerini alan referans vektör girdi vektörünün sınıfını ifade etmektedir. Ağı eğitiminde öncelikle girdiler referans vektörleri ile eğitilir, ardından Öklid ölçüm yöntemine göre girdi ile referans vektör çıktıları arasındaki yakınlık hesaplanır. Ardından çıktıya en yakın referans vektörünün doğru olup olmadığı kontrol edilir. Eğer doğru ise referans vektörünün girdi vektöre yakınlığı, yanlış ise uzaklığı sağlanır. Bu işlemlerin devamında sonuç olarak, girdi vektörüne en yakın referans vektörü belirlenir ve kazanan vektöre 1, diğerlerine ise 0 değeri verilir. Bu da karar biriminin hangi sınıfta olduğunu göstermektedir. Literatüre göre LVQ tipi sinir ağı; parmak izi tanıma (Bernand vd, 2001), başarı tahmininde (Crowdhury ve Wang, 1996), yemekhane günlük talep tahmini (Kılıç, 2015), konuşmacının sesine dayanarak cinsiyet tahmini (Yücesoy ve Nabiyev, 2016) gibi konularda kullanıldığı görülmektedir.

4.1.3. ANFIS (Adaptive Neuro Fuzzy Inference System) Yöntemi

ANFIS yöntemi, ilk olarak 1993 yılında Jang tarafından ortaya atılmış olup yöntem, bulanık mantık ile yapay sinir ağının entegre edilmesi düşüncesine dayanmaktadır. Buna göre bir yapay sinir ağına eğitim, bulanık mantık (eğer ise) yöntemine göre yapılmaktadır. Bulanık mantık ise 1965 yılında Zadeh tarafından klasik mantığa alternatif olarak geliştirilmiştir. Klasik mantıkta karar biriminin üyelik derecesi ya 0 veya 1'dir. Ancak bulanık mantıkta dilsel ifadeler kullanılmış olup üyelik derecesi 0 ile 1 arasında değişmektedir. ANFIS yönteminde kullanılan sinir ağının yapısı şekil 4'deki gibidir.



Şekil 4: ANFIS ağı yapısı

Şekil 4'e göre ANFIS yapısında x ve y olmak üzere iki adet girdi ve bir adet çıktı (f) bulunmaktadır. Birinci katman modeldeki girdi değişkenlerini göstermekte olup veri setinin sisteme tanımlandığı yerdir. Buradaki A_i ve B_j , bulanık mantıktaki dilsel değişkenleri ifade etmek için kullanılır. Bu aşamadan sonra daha önce tercih edilen bulanık mantık üyelik fonksiyonu ile girdi değişkenleri çarpılır ve ardından bu değerler üçüncü adımda normalleştirilir. Normalleştirme işlemi her girdi için elde edilen değer toplam değere oranlanarak yapılmaktadır. Dördüncü katmanda ise Takagi Sugeno tipi bulanık mantık işlemi uygulanır ve ardından toplam çıktı değer elde edilir (Do ve Chen, 2013).

ANFIS yönteminde klasik YSA tekniklerinden farklı olarak, çıktı bir vektör olarak değil de sayı olarak verilmektedir. Yöntemin uygulamasında hangi bulanık kuralın kullanılacağı veya kaç tane üyelik fonksiyonu tanımlanacağı genellikle deneme yanılma yoluyla tespit edilmektedir. Bununla birlikte klasik YSA bir kara kutu olarak değerlendirilirken, ANFIS'te her girdinin ağı nasıl etkilediği, diğer bir ifadeyle, girdilerin çıktı üzerindeki etki düzeyleri bulunabilmektedir. Yöntemin uygulamasında ise genellikle MATLAB gibi kodlamaya dayanan matematiksel yazılımlar kullanılmaktadır. ANFIS yöntemi literatürde farklı konularda sınıflandırma amacıyla kullanılmaktadır. Örneğin, finansal başarı tahmininde (Chen, 2013), (Akbulut ve Rençber,2016), ülkelerin sınıflandırılmasında (Shekarian ve Ghohizadeh, 2013), (Rençber,2017), tohum sınıflandırma (Şengöz ve Özdemir,2017) kullanıldığı görülmektedir.

5. UYGULAMA

5. 1. Çalışmanın Amacı ve Kapsamı

Çalışmada, iktisadi ve istatistiki olarak iki tür amaç bulunmaktadır. İktisadi açıdan; ülkelerin lojistik performanslarını gösteren endekse göre sınıflandırılmasında etkili olan değişkenlerin belirlenmesi; istatistiki açıdan ise BKSA, LVQ ve ANFIS yapay sinir ağ modellerinin sınıflandırma performanslarının karşılaştırılması amaçlanmaktadır. Çalışmada, LPE hesaplamasında kullanılan göstergeler dikkate alınarak, BKSA, LVQ ve ANFIS ağ modellerine göre sınıflandırmalar yapılmıştır. Buna göre çalışmada kullanılan ve sinir ağlarına girdi ve çıktı olarak tanıtılan değişkenler tablo 3'deki gibidir.

Tablo 3: Çalışmada Kullanılan Göstergeler

Değişken Türü	Gösterge Adı
Çıktı	Ülkelerin sınıfları
Girdiler	Gümrük
	Altyapı
	Uluslararası Sevkiyat
	Hizmet Kalitesi
	Takip ve İzleme
	Zamanlama

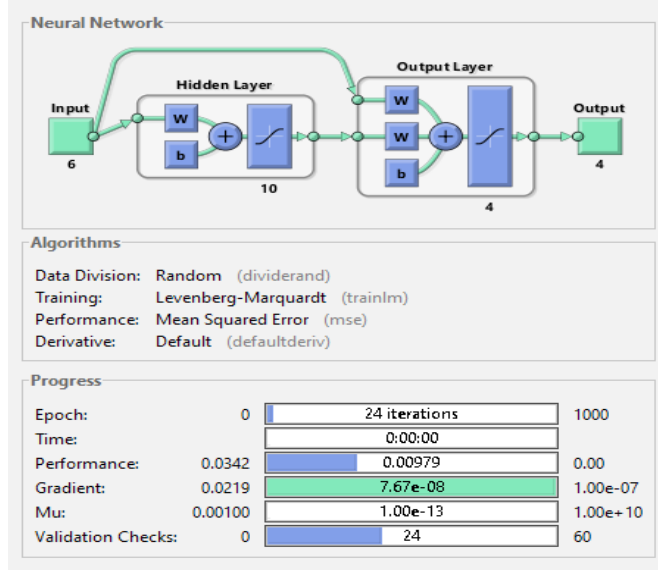
Her üç model uygulamasında da altı girdi ve bir çıktı değişkeni bulunmaktadır. Girdiler, aynı zamanda Dünya Bankası tarafından ülkelerin lojistik performanslarının belirlenmesinde kullanılmaktadır. Ülkelerin ait oldukları sınıflar ise ağıncı çıktısını oluşturmaktadır. Resmi endeks raporlarında 2016 yılına kadar ülkelere ait bir sıralama verilmiş ve 2016 yılı raporunda ülkeler beş sınıfa ayrılmıştır. Buna göre öncelikle ülkeler, skorlarına göre büyükten küçüğe sıralanmaktadır. Daha sonra 160 ülkeden ilk 32'si "Lojistik dostu", ikinci 32'si "istikrarlı performans sergileyenler", üçüncü ve dördüncü dilimde yer alan 64 ülke "kısmen performans gösteren" ve beşinci dilimde yer alan 32 ülke ise "lojistik dostu olmayan" şeklinde sınıflandırılmıştır. Çalışmada, tüm yıllar için esas alınan sınıflandırma işlemleri bu metoda göre yapılmıştır. Bununla birlikte üçüncü ve dördüncü dilimdeki ülkeler aynı sınıfta yer aldığından dolayı ülkeler, toplamda dört sınıfta incelenmiştir.

Analize başlamadan önce eğitim ve test için veri setlerinin belirlenmesi gerekmektedir. Literatürde genellikle veri setinin %70'i eğitim, %30'u ise test amaçlı kullanılmaktadır. Çalışmada, %70-%30 oranına dikkat edilerek, eğitim-test ayrımının yıl düzeyinde yapılması uygun görülmüştür. Buradaki temel düşünce; yapay sinir ağının, geçmişe bakarak geleceği tahmin etmesinin istenmesi ve lojistik performans endeksini etkileyen faktörlerin incelenmesinin amaçlanmasıdır. Bu doğrultuda, bütün yapay sinir ağ modelleri için 2007, 2010, 2012 ve 2014 yılları LPE ve bileşenleri eğitim; 2016 yılı LPE ve bileşenleri test amaçlı kullanılmıştır. Buna göre, 2007'de 150, 2010'da 155, 2012'de 155 ve 2014'de endeks hesaplaması yapılan 160 ülke olmak üzere toplamda 620 (%70) karar birimi (ülke) eğitim; 2016 yılı kapsamındaki 160 (%30) ülke de test olarak değerlendirilmiştir.

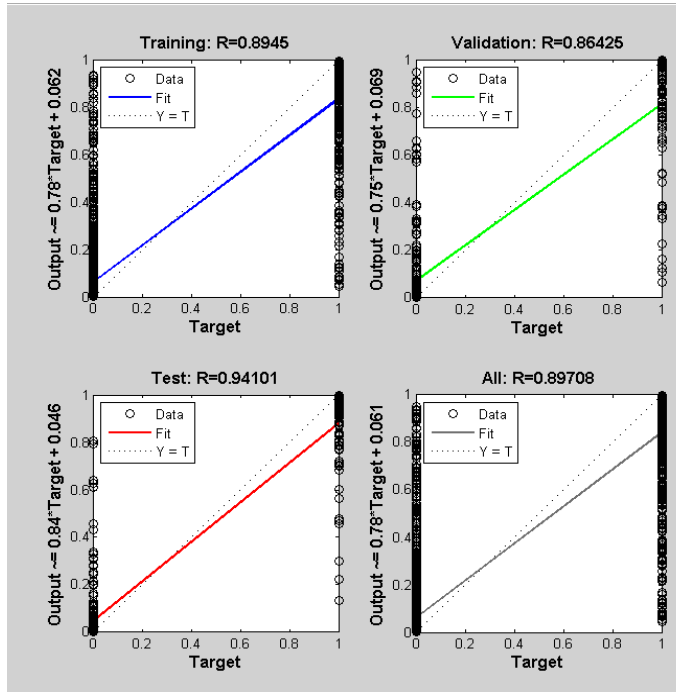
5. 2. Basamak Korelasyon Yapay Sinir Ağı Uygulaması

BKSA modelinin uygulaması MATLAB programı ile yapılmıştır. Ağda altı girdi, dört çıktı ve bir gizli katman

bulunmaktadır. Gizli katmandaki düğüm sayısı için farklı seçenekler denenmiş ve en iyi performans 10 düğüm ile elde edilmiştir. Oluşturulan ağın yapısı ve uygulama paneli şekil 5'deki gibidir.



Şekil 5: Basamak Korelasyon Sinir Ağı Eğitim Ekran Görüntüsü



Şekil 6: Basamak Korelasyon Eğitim Düzeyleri

Şekle göre ağ, Levenberg-Marquardt (trainlm) fonksiyonu ile eğitilmiş ve performansı, en küçük hata kareler ortalaması ile ölçülmüştür. Ağın eğitimi minimum gradyan değerine ulaşılması nedeniyle 24

iterasyonda tamamlanmıştır. Bu süreç ise neredeyse bir saniye içerisinde tamamlanmıştır. Eğitimin performansını gösteren regresyon doğrusu şekil 6'daki gibidir.

Ağın eğitim sürecinde veri seti; eğitim, doğrulama ve test etme amaçlı rastgele olarak üç gruba bölünmüştür. Buna göre elde edilen R^2 düzeyleri eğitim için $(0,8948^2)$ %80; doğrulama amaçlı kullanılan veri setinde $(0,86425^2)$ %75; test edilen veri setinde ise %89 ve veri setinin tamamı dikkate alındığında eğitimin R^2 düzeyinin $(0,89708^2)$ %80 olduğu görülmektedir. Bu değer, klasik regresyon analizine göre yeterli olarak kabul edilmektedir.

Ağın eğitiminin ardından, 2016 yılı lojistik performans endeksi değerleri ile ağın sınıflandırma performansı test edilmiştir. Buna göre elde edilen doğru sınıflandırma tablosu, tablo 4'deki gibidir. Buradaki ortalama değer; sütunlar için yapılan tahmine göre o sınıftaki karar biriminin 160 ülke içindeki yüzdelik payını, satırlar için ise aritmetik ortalama ile hesaplanan doğru sınıflandırma oranını ifade etmektedir.

Tablo 4: Basamak Korelasyon Sinir Ağı Doğru Sınıflandırma Tablosu


Doğru Sınıflandırma Tablosu					
Gerçek Sınıf	Tahmin Edilen Sınıf				Doğruluk Yüzdesi
	1	2	3	4	
1	30	2			93.75%
2		27	5		84.38%
3			63	1	98.44%
4			2	30	93.75%
Ortalama	18.75%	18.13%	43.75%	19.38%	92.58%

Tablo 4'e göre lojistik dostu olan ülkelerden iki tanesi (Çin ve Çek Cum.) istikrarlı; istikrarlı ülkelerden beş tanesi (Kıbrıs, Romanya, Tanzanya, Ruanda ve Endonezya) kısmen performanslı; kısmen performanslı olan ülkelerden bir tanesi (Solomon Adaları) lojistik dostu olmayan; lojistik dostu olmayan ülkelerden iki tanesi (Bolivya ve Suriye) kısmen performanslı olarak tahmin edilmiştir. Toplamda 10 ülke hatalı sınıflandırılmış olup, genel anlamda ülkelerin BKSA ile ortalama %92,58 oranda doğru sınıflandırıldığı ve eğitim sürecinin bir saniye gibi çok kısa zamanda tamamlandığı bulgularına ulaşılmıştır.

5.3. LVQ Model Sinir Ağı Uygulaması

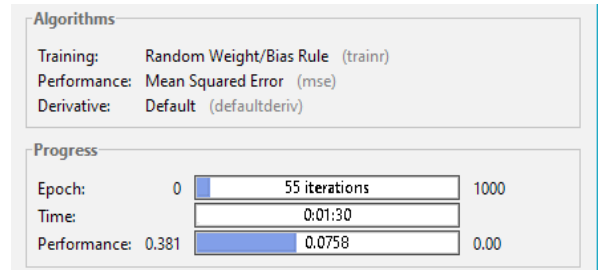
LVQ ağı, ileri beslemeli ve geri yayımlı bir sinir ağ modelidir. Buna göre, girdiler ağa sunulur ve ardından çıktı tahmin edilir, hatalar tekrar girdiye gösterilir ve ağırlıklar değiştirilerek eğitim devam eder. Uygulamada öğrenme oranı 0,01 alınmış olup transfer fonksiyonu Learnlv1 (LVQ1) kullanılmıştır. Diğer YSA tekniklerinde

olduğu gibi 2007, 2010, 2012 ve 2014 yılları LPE ve bileşenleri eğitim, 2016 LPE ve bileşenleri test olarak kullanılmıştır. LVQ modeli sinir ağı uygulamasında çalışmanın modeli şekil 7'deki gibidir.



Şekil 7: LVQ Model Ağ Yapısı

Şekil 7'ye göre ağ yapısında altı girdi, dört çıktı ve bir gizli katman bulunmaktadır. Farklı denemeler ile gizli katmanda ise 10 nöron alınmasının uygun olduğu görülmüştür. Ağın eğitiminin yapıldığı arayüzün ekran görüntüsü şekil 8'deki gibidir.



Şekil 8: LVQ model ağ eğitimi ekran görüntüsü

Şekil 8'e göre ağın eğitim performansının sabitlenmesi nedeniyle eğitim, 55 iterasyonda tamamlanmıştır. Bu aşamaya kadar geçen süre 1,5 dakika civarındadır. Ağın eğitim performansını gösteren ekran görüntüsü şekil 9'daki gibidir.

All Confusion Matrix					
Output Class	Target Class				
	1	2	3	4	
1	125 20.2%	1 0.2%	1 0.2%	0 0.0%	98.4% 1.6%
2	22 3.5%	141 22.7%	6 1.0%	0 0.0%	83.4% 16.6%
3	0 0.0%	11 1.8%	140 22.6%	40 6.5%	73.3% 26.7%
4	0 0.0%	3 0.5%	9 1.5%	121 19.5%	91.0% 9.0%
	85.0% 15.0%	90.4% 9.6%	89.7% 10.3%	75.2% 24.8%	85.0% 15.0%

Şekil 9: LVQ Model Ağın Eğitim Performansı Ekran Görüntüsü

Ağ, BKSA'na benzer olarak toplam 620 ülke ile eğitilmiştir. Şekil 9'a göre LVQ sinir ağının eğitimi ile ülkeler %85 oranında doğru sınıflandırılmıştır. Eğitimde en yüksek başarı %98,4 ile lojistik dostu; en düşük başarı ise kısmen lojistik dostu ülkelerde elde edilmiştir. Bunun ardından eğitilen ağı test edebilmek amacıyla 2016 yılı lojistik performans endeksi verileri ağı girilmiştir. Buna göre, elde edilen doğru sınıflandırma tablosu, tablo 5'deki gibidir. Buradaki ortalama değeri, sütunlar için yapılan tahmine göre o sınıftaki biriminin bütün ülkeler içindeki yüzdelik payını, satırlar için ise aritmetik ortalama ile hesaplanan doğru sınıflandırma oranını ifade etmektedir.

Tablo 5: LVQ Model Sinir Ağı Doğru Sınıflandırma Tablosu

Gözlenen Sınıf	Sınıflandırma				Doğruluk Yüzdesi
	Tahmin Edilen Sınıf				
	1	2	3	4	
1	30	2			93.75%
2		32			100.00%
3	2	6	53	3	82.81%
4			3	29	90.63%
Ortalama	26.88%	25.63%	28.13%	19.38%	91.80%

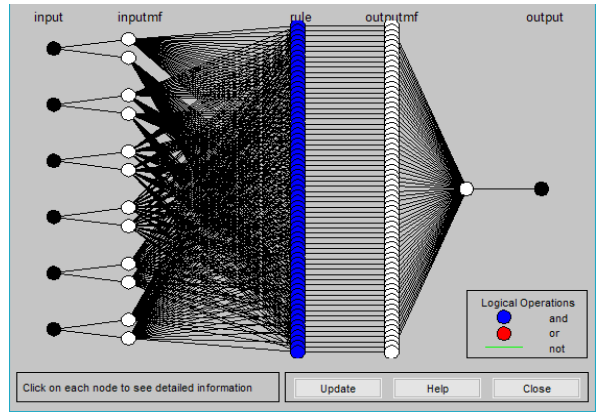
Tablo 5'e göre istikrarlı ülkeler tamamen doğru sınıflandırılmış olup diğer sınıflar için; lojistik dostu iki ülke (Macaristan ve Malezya) istikrarlı; kısmen performanslı ülkelerden iki tanesi (Lübnan ve Bosna) lojistik dostu, altı tanesi (Uruguay, Arjantin, Jordan, Pakistan, Peru ve Brunei Darusselam) istikrarlı, üç tanesi (Bahamalar, Burkina Faso ve Namibya) ise lojistik dostu olmayan ülkeler olarak tahmin edilmiştir. Bununla birlikte lojistik dostu olmayan üç ülkenin (Gine, Gürcistan ve Küba) kısmen performansa sahip sınıfında olabileceği bulgularına ulaşılmıştır. Toplamda 16 ülke hatalı sınıflandırılmış olup, genel olarak, ülkelerin LVQ model sinir ağı ile ortalama %91,80 oranda doğru sınıflandırıldığı sonucuna ulaşılmıştır.

5. 4. ANFIS Modelinin Uygulanması

ANFIS yöntemi, bulanık mantık ile yapay sinir ağının beraber uygulandığı bir yöntemdir. Buna göre, klasik yapay sinir ağına ek olarak, girdiler çıktıya dönüştürülürken bulanıklaştırma ve durulaştırma sürecinden geçmektedir. Bu aşamada, her girdi için bulanık mantık

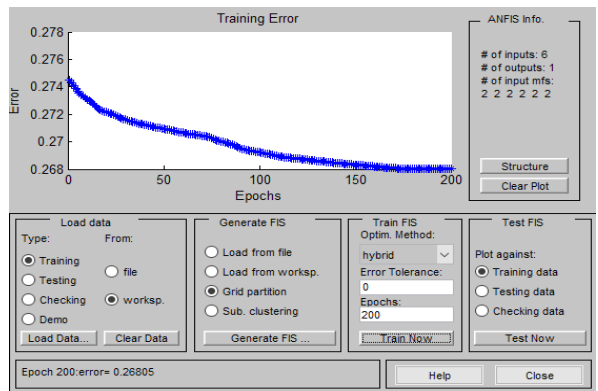
üyelik fonksiyonu ve kullanılacak fonksiyon sayısı belirlenmelidir. Bu kısım genellikle deneme yanılma yolu ile bulunmaktadır. Ağın yapısı oluşturulduktan sonra eğitim ve test aşamasına geçilmektedir.

Çalışmada, öncelikle her girdi için ikişer üyelik fonksiyonu tanımlanmış ve 50 iterasyon ile fonksiyonların tamamı denenmiştir. Buna göre en düşük hata (0,24673) yamuk tipi üyelik fonksiyonu ile edilmiştir. Dolayısıyla, ANFIS uygulamasının yamuk tipi üyelik fonksiyonu ile yapılmasının gerektiği sonucuna ulaşılmıştır. ANFIS yöntemine göre yapılan uygulamanın model yapısı şekil 10'daki gibidir.



Şekil 10: ANFIS Model Yapısı

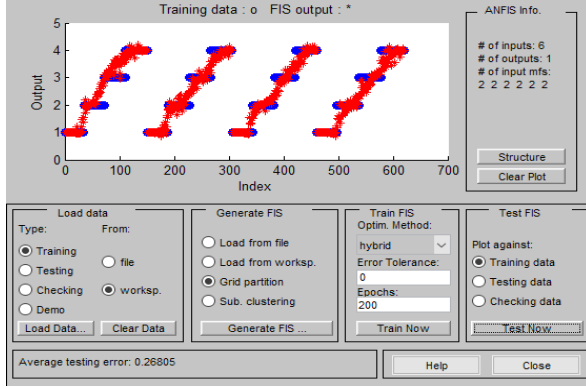
Şekil 10'a göre modelde altı girdi ve her girdi için ikişer adet üyelik fonksiyonu ve bir çıktı bulunmaktadır. Bu şekilde tasarlanan ağın eğitimine ait ekran görüntüsü şekil 11'deki gibi olmaktadır.



Şekil 11: ANFIS Eğitimi Ekran Görüntüsü

Şekil 11'e göre, ağın eğitimi hibrit öğrenme tekniğine göre yapılmış ve 200 iterasyon ile tamamlanmıştır. Bununla birlikte ağın eğitim hatası 160 iterasyonda

sabitlemiş ve hata oranı 0,27 civarı bulunmuştur. Eğitim verisi test edildiğinde elde edilen ekran görüntüsü şekil 12'deki gibi olmaktadır.



Şekil 12: Eğitim Verisinin Test Edildiği Ekran Görüntüsü


Şekil 12'ye göre 620 ülkeden genellikle lojistik dostu olan ve olmayan ülkelerin daha doğru sınıflandırıldığı görülmektedir. Diğer taraftan, 2016 yılı LPE test amacıyla ağa tanıtıldığında elde edilen doğru sınıflandırma tablosu tablo 6'daki gibidir. Buradaki ortalama değeri, sütunlar için o sınıftaki karar biriminin tahmin sonucu bütün ülkeler içindeki yüzdelik payını, satırlar için ise aritmetik ortalama ile hesaplanan doğru sınıflandırma oranını ifade etmektedir.

Tablo 6: ANFIS Uygulaması Doğru Sınıflandırma Tablosu

Gözlenen Sınıf	Sınıflandırma				Doğruluk Yüzdesi
	Tahmin Edilen Sınıf				
	1	2	3	4	
1	31	1			96.88%
2	5	20	7		62.50%
3			32		100.00%
4			9	23	71.88%
Ortalama	22.50%	13.13%	30.00%	14.38%	82.81%

Tablo 6'ya göre lojistik dostu ülkelerden 1 tanesi (Macaristan) istikrarlı; istikrarlı ülkelerden beş tanesi (İzlanda, Kenya, Litvanya, Bahreyn ve Kıbrıs) lojistik dostu, yedi tanesi (Panama, Bulgaristan, Kamboçya, Ekvator, Cezayir, Sırbistan ve Kazakistan) kısmen performanslı; lojistik dostu olmayan ülkelerden dokuz tanesi (Özbekistan, Jamaika, Belarus, Venezuela,

Nepal, Kongo, Etiyopya, Gine-Bissau ve Gine) kısmen performanslı olarak tahmin edilmiştir. Toplamda 22 ülke hatalı sınıflandırılmış olup, genel olarak ülkelerin ANFIS yöntemi ile ortalama %82.81 oranında doğru sınıflandırıldığı sonucuna ulaşılmıştır. Bununla birlikte, diğer ağ modellerinde hesaplanamamasına rağmen, hangi girdinin çıktığı en çok etkilediği sorusuna ANFIS yöntemi ile cevap bulunabilmektedir. Bu ise girdilerin eğitim sürecindeki hata oranları ile belirlenmekte olup, elde edilen sonuç şekil 13'deki gibidir.



Şekil 13: Girdilere ait eğitim hata oranları

Şekil 13'e göre eğitim hatası en düşük girdi çıktıda en büyük öneme sahip olmaktadır. Buna göre, lojistik kalitesi ve bileşenler faktörü, ülkelerin LPE sınıflarının belirlenmesinde en önemli etkiye sahiptir. Bunun yanı sıra altyapı, takip ve izlenebilirlik diğer önemli değişkenlerdir. En az önemli olan faktör ise lojistik faaliyetlerdeki zamanlılıktır.

6. SONUÇ

Çalışmada, iktisadi açıdan ülkelerin LPE sınıflandırılmasında etkili olan faktörlerin belirlenmesi; istatistiki açıdan ise BKSA, LVQ ve ANFIS tipi sinir ağlarının sınıflandırma performanslarının karşılaştırılması amaçlanmıştır.

Bir ülkenin lojistik faaliyetlerindeki gelişmişlik düzeyleri, aynı zamanda o ülkenin ticari entegrasyon gücünü de göstermektedir. Bu açıdan, her bir ülke için lojistik faaliyetlerinin değerlendirilmesi ve başka ülkeler ile kıyaslanması oldukça önemlidir. Bu sayede ülkeler, hem kendi durumlarını görebilmekte hem de gelecek politikalarını geliştirebilmektedirler. Dünya Bankası tarafından iki yılda bir süreyle yayınlanan Lojistik Performans Endeksi, ülkeleri birbiriyle; gümrük işlemleri, altyapı, uluslararası sevkiyatlar, lojistik hizmetlerin kalitesi, sevkiyatların izlenebilmesi ve za-

manında ulaşmasına göre karşılaştırmaktadır. Endeks, iktisadi açıdan oldukça büyük önem arz etmektedir.

Yöntemler açısından çalışmanın önemi değerlendirilecek olursa; YSA uygulamalarındaki temel amaç, girdileri çıktılar ile en iyi düzeyde eşleştirecek bir yapıyı oluşturmaktır. Bunun için farklı öğrenme algoritmaları, transfer veya aktivasyon fonksiyonları kullanılmaktadır. BKSA, LVQ ve ANFIS tipi sinir ağları öğrenme algoritmaları ve genel çalışma prensipleri açısından farklılık göstermekte olup birbirlerine karşı üstünlük ve zayıflıkları da bulunmaktadır. Örneğin, BKSA ağ yapısını eğitilen veri seti ile kendisi üretmekte ve hataları geri çağırılmamaktadır yani geri yayımlı değildir. LVQ ağı genellikle sınıflandırma problemlerinde kullanılmakta olup kazanan her şeyi alır prensibi ile çalışmaktadır ve geri yayılım öğrenme algoritmasına sahiptir. ANFIS ise bulanık mantık ile YSA'nın birleşiminden meydana gel-

miştir. Uygulamada dilsel ifadeler kullanılmakta olup hibrit öğrenme algoritmasına sahiptir. Bu farklılıkların, karar birimi sınıflandırma işlemlerinde başarıyı ve uygulanabilirliği nasıl etkilediğinin belirlenmesi, yöntem bilimi açısından oldukça önemlidir.

Çalışmada, LPE ve bileşenlerine ait veri seti kullanılarak ülkeler sınıflandırılmıştır. Buna göre, bütün yapay sinir ağ modelleri için 2007, 2010, 2012 ve 2014 yılları LPE ve bileşenleri eğitim; 2016 yılı LPE ve bileşenleri test amaçlı kullanılmıştır. Ülkeler, 2016 LPE raporundaki gibi, sıralamalarına göre beş gruba ayrılmış olup ülkeler sırasıyla; lojistik dostu, istikrarlı, kısmen performanslı, kısmen performanslı ve lojistik dostu olmayan şeklinde sınıflandırılmıştır.

Her üç yöntemde yanlış sınıflandırılan ülkelerin gerçek ve tahmini sınıflarına göre elde edilen sonuçlar tablo 7'deki gibidir.

Tablo 7: Uygulama Sonucunda Yanlış Sınıflandırılan Ülkeler Tahmini ve Gerçek Sınıfları

BKSA			LVQ			ANFIS		
	T	G		T	G		T	G
Tayvan, Çin	1	2	Macaristan	2	1	Macaristan	2	1
Çek Cumhuriyeti	1	2	Malezya	2	1	İzlanda	1	2
Kıbrıs	2	3	Uruguay	2	3	Kenya	1	2
Romanya	2	3	Arjantin	2	3	Letonya	1	2
Tanzanya	2	3	Ürdün	2	3	Bahreyn	1	2
Ruanda	2	3	Pakistan	2	3	Kıbrıs	1	2
Endonezya	2	3	Peru	2	3	Panama	3	2
Solomon Adaları	4	3	Brunei Darusselam	2	3	Bulgaristan	3	2
Bolivya	3	4	Bahamalar	4	3	Kamboçya	3	2
Suriye	3	4	Namibya	4	3	Ekvator	3	2
			Burkina Faso	4	3	Cezayir	3	2
			Lübnan	1	3	Sırbistan	3	2
			Bosna Hersek	1	3	Kazakistan	3	2
			Gine	3	4	Özbekistan	3	4
			Gürcistan	3	4	Jamaika	3	4
			Küba	3	4	Belarus	3	4
						Venezuela	3	4
						Nepal	3	4
						Kongo Cumhuriyeti	3	4
						Etiyopya	3	4
						Gine-Bissau	3	4
						Gine	3	4
T: Tahmini Sınıf			G: Gerçek Sınıf					
1: Lojistik Dostu			2: İstikrarlı		3: Kısmen Performanslı		4: Lojistik Dostu Olmayan	

Tablo 7'ye dikkat edilirse, her üç yöntemin çoğunlukla farklı sonuçlar tahmin ettiği görülmektedir. Kıbrıs ve Macaristan haricindeki ülkeler, sadece bir yöntem ile yanlış sınıflandırılmıştır. Bu durumun ağ modellerindeki öğrenme algoritma farklılıklarından kaynaklandığı düşünülebilir. Genel sınıflandırma başarıları dikkate alındığında elde edilen sonuç tablo 8'deki gibi olmaktadır.

Tablo 8: Yöntemlerin Doğru Sınıflandırma Oranları

Yöntem	Yanlış Sınıflandırılan Ülke Sayısı	Doğru Sınıflandırma Oranı
BKSA	10	% 92,58
LVQ	16	% 91,80
ANFIS	22	%82,81

Tablo 8'de görüldüğü üzere, BKSA ile %92.58, LVQ ile %91.80, ANFIS ile %82.81 oranında doğru sınıflandırma başarısı elde edilmiştir. BKSA'nın diğer model ağlara göre daha başarılı olmasındaki neden, modeli kendisinin oluşturması ve hatayı geri yaymamasıdır. LVQ ağı, "karar birimi bir sınıfa aittir veya değildir" prensibine göre çalışmakta ve geri yayılım öğrenme algoritmasına göre eğitilmektedir. Eğer karar biriminin bir sınıfa ait olduğu tahmin ediliyorsa bu durumda diğer sınıflara üyelik ihtimalinin olmadığı düşünülmektedir. ANFIS yönteminde ise veriler bulanıklaştırma ve durulaştırma işlemlerinden geçmektedir. Buna göre sınıflandırma; karar biriminin her bir sınıfa göre

hesaplanan aidiyet oranı ile belirlenmektedir. Daha sonra bu değerlerin en yüksek oranı hangi sınıfta ise karar biriminin o sınıfa ait olduğu şekilde yorumlanır.

Yöntemlerin sağladıkları çıktılara bakıldığında; BKSA ve LVQ modellerinde YSA'nın "kara kutu" yapısı korunmaktadır. Ancak, ANFIS yöntemi ile girdi çıktı arasındaki ilişki ve etki düzeyleri ölçülebilmektedir. Buna göre, lojistik performans sınıflandırılmasında lojistik kalite ve bileşenleri, altyapı, izlenilebilirliğin en önemli; zamanlılığın ise en az öneme sahip olduğu bulgusuna ulaşılmıştır. Bununla birlikte, yöntemlerde ağı eğitim sürelerine dikkat edildiğinde; sinir ağı BKSA ile 1 saniyede, LVQ ile 1.5 dakikada, ANFIS ile yaklaşık 2.5 dakika süreyle eğitim tamamlanmıştır. Bu açıdan BKSA'nın diğer yöntemlere göre, çok daha hızlı ve daha başarılı sonuçlar ürettiği görülmüştür.

Genel olarak, elde edilen bulgulara göre; yapay sinir ağı ile sınıflandırma problemi uygulamalarında kurulacak modelin yapısının oldukça büyük öneme sahip olduğu görülmüştür. Bunun yanı sıra, üyelik seçimlerinde klasik mantığın bulanık mantıktan daha iyi sonuç verdiği bulgusuna ulaşılmıştır. Elde edilen bulgular, literatürde benzer çalışmalar ile desteklenmektedir (Blonda, Pasquariello ve Smid, 1993), (Shariati ve Haghghi, 2010), (Borselli vd., 2011), (Şengöz ve Özdemir, 2017). İleriki zamanlarda yapılabilecek çalışmalarda sınıflandırma problemlerinde Elman, Nefclass, FuNet gibi farklı sinir ağ modelleri kullanılarak karşılaştırılabilir.

KAYNAKLAR

Akbulut, R. ve Rençber, Ö. F. (2015), Veri Zarflama ve Lojistik Regresyon Analizi ile Çimento İşletmelerinde Finansal Performansa Dayalı Etkinliklerinin Değerlendirilmesi. Alanya İşletme Fakültesi Dergisi, 123-135.

Ankışhan, H. ve Yılmaz, D., 2013, Comparison of SVM and ANFIS for Snore Related Sounds Classification by Using the Largest Lyapunov Exponent and Entropy, Computational and Mathematical Methods in Medicine

Bayat, T., ve Özdemir, Ş. (2016) Yeni Bir Lojistik Performans Endeksi Oluşturmak İçin Gerekli Olan Kriterlerin Belirlenmesi Üzerine Araştırma

Bayraktutan, Y., Tüylüoğlu, Ş., ve Özbilgin, M. (2012). Lojistik Sektöründe Yoğunlaşma Analizi ve Lojistik Gelişmişlik Endeksi: Kocaeli Örneği. Journal of Alanya Faculty of Business 4(3).

Bernard, S., BoujeMaa, N., Vitale, D., and Bricot, C. (2001). Fingerprint Classification Using Kohonen Topologic Map. In Image Processing, 2001. Proceedings. 2001 International Conference on (Vol. 3, pp. 230-233). IEEE.

Blonda, P., Pasquariello, G., and Smid, J. (1993, October). Comparison of Backpropagation, Cascade-Correlation And Kohonen Algorithms For Cloud Retrieval. In Neural Networks, 1993. IJCNN'93-Nagoya. Proceedings of 1993 International Joint Conference on (Vol. 2, pp. 1231-1234). IEEE.

Borselli, A., Colla, V., Vannucci, M., Sant'Anna, P. C. S. S., Valdera, P. S. A., and Piaggio, V. R. (2011). Surface Defects Classification in Steel Products: A Comparison Between Different Artificial Intelligence-Based Approaches. In 11th IASTED International Conference on Artificial Intelligence and Applications AIA (pp. 129-134).

Chandra, B. and Babu, K. (2014), Classification Of Gene Expression Data Using Spiking Wavelet Radial Basis Neural Network. Expert Systems with Applications, 1326-1330.

Chen, M.-Y. (2013), A Hybrid ANFIS Model for Business Failure Prediction Utilizing Particle Swarm Optimization And Subtractive Clustering. Information Sciences, 220, 180-195. doi:10.1016/j.ins.2011.09.013

- Chowdhury, B. H., and Wang, K. (1996, February). Fault classification using Kohonen feature mapping. In *Intelligent Systems Applications to Power Systems, 1996. Proceedings, ISAP'96., International Conference on* (pp. 194-198). IEEE.
- Dağdeviren, M., Akay, D. ve Kurt, M. (2004). İş Değerlendirme Sürecinde Analitik Hiyerarşi Prosesi ve Uygulaması. *Gazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 19(2), 131-138.
- Demircanlı, B. ve Kundakçı, N. (2015). Futbolcu Transferinin AHP ve VIKOR Yöntemlerine Dayalı Bütünleşik Yaklaşım ile Değerlendirilmesi. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 30(2), 105-129.
- Fahlman, S. E. and Lebiere, C. (1990). The cascade-correlation learning architecture. In *Advances in neural information processing systems* (pp. 524-532).
- Fish, K., Barnes, J. and Aiken, M. (1995), *Artificial Neural Networks: A New Methodology for Industrial Market Segmentation*. *Industrial Marketing Management*, 431-439.
- Jhavar A. and Garg S. K. (2018), *Modelling of Critical Factors for Improving Logistics Performance of India Using Interpretive Structural Modelling*, *International Journal of Applied Management Sciences and Engineering (IJAMSE)* 5(1)
- Kara, M., Tayfur, L., ve Basık, H. (2009). Küresel Ticarete Lojistik Üslerin Önemi ve Türkiye, Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 6(11).
- Kılıç, G. (2015). *Yapay Sinir Ağları İle Yemekhane Günlük Talep Tahmini* (Doctoral dissertation, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü).
- Lau H. K. (2011). Benchmarking green logistics performance with a composite index. *Benchmarking: An International Journal*, 18(6), 873-896.
- Lehtokangas M., (2000) Modified cascade correlation learning for classification, *IEEE Transactions on Neural Network*, 1(3) 795-798
- Lojistik Performans Endeksi Raporu (2016), <https://lpi.worldbank.org/> (E. T. 20.10.2017)
- Martí, L., Puertas, R., and García, L. (2014). The importance of the Logistics Performance Index in international trade. *Applied economics*, 46(24), 2982-2992. ISO 690
- Michie, D., Spiegelhalter, D. J., and Taylor, C. C. (1994). *Machine learning, neural and statistical classification*, Cambridge, U.K.
- Ottenbacher, K., Smith, P., Ilig, Linn, R., Fiedler, R. and Granger, C. (2001), Comparison of Logistic Regression And Neural Networks To Predict Rehospitalization in Patients With Stroke. *Journal of Clinical Epidemiology*, 1159-1165.
- Pupavac, D., and Draskovic, M. (2017). Analysis of Logistic Performance In Southeast European Countries. *Business Logistics in Modern Management*, 17, 569-579.
- Rençber Ö. F. (2017) Bulanık ve Yalın Yapay Sinir Ağları ile Çoklu Lojistik Regresyon Yöntemlerinin Sınıflandırma Performanslarının Karşılaştırılması: Ülkelerin Gelişmişlik Düzeylerinin Sınıflandırılması Üzerine Bir Uygulama, Aksaray Üniversitesi, SBE Yayınlanmamış Doktora Tezi, Aksaray
- Shariati, S., and Haghighi, M. M. (2010). Comparison of ANFIS Neural Network with Several other ANNs and Support Vector Machine for Diagnosing Hepatitis and Thyroid Diseases. In *Computer Information Systems and Industrial Management Applications (CISIM), 2010 International Conference on* (pp. 596-599). IEEE.
- Sharma, M. and Mukharjee, S., 2013, Brain Tumor Segmentation Using Genetic Algorithm and Artificial Neural Network Fuzzy Inference System (ANFIS), *Advances in Computing and Information*, Springer - Verlag Berlin Heidelberg, s. 329-339
- Shekarian, E. and Gholizadeh, A. A. (2013), Application of Adaptive Network Based Fuzzy Inference System Method in Economic Welfare. *Knowledge-Based Systems*, 39, 151-158. doi:10.1016/j.knosys.2012.10.013
- Sofyalıoğlu, A. ve Kartal, A. (2013). Türkiye ve Avrasya Ekonomik Topluluğu Ülkelerinin Lojistik Performans İndekslerinin Karşılaştırılması ve Bazı Çıkarımlar A Comparison and some Suggestions for Turkey's and Eurasian Economic Community Countries' Logistic Performance Index Scores. In *International Conference on Eurasian Economies* (pp. 524-531).
- Spoerre, J. K. (1997). Application of the Cascade Correlation Algorithm (CCA) to Bearing Fault Classification Problems. *Computers in industry*, 32(3), 295-304.
- Şen, Z. (2004). *Yapay Sinir Ağları İlkeleri*. Su Vakfı.
- Şengöz, N. ve Özdemir, G. (2017). Sınıflandırma Problemlerinin Karşılaştırılmasında ANFIS ve Basamak Korelasyon Sinir Ağının Kullanımı. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 21(1), 125-130.
- Şenol, C. ve Yildirim T., (2009), Thyroid and Breast Cancer Disease Diagnosis using Fuzzy Neural Networks, 6th International Conference on Electrical and Electronics Engineering (ELECO'2009)
- Toprak, E. (2017), Yapay Sinir Ağı, Karar Ağaçları ve Ayırma Analizi Yöntemleri ile PISA 2012 Matematik Başarılarının Sınıflandırılma Performanslarının Karşılaştırılması.
- Velusamy, K., and Amalraj, R. (2017, February). Performance of the cascade correlation neural network for predicting the stock price. In *Electrical, Computer and Communication Technologies (ICECCT), 2017 Second International Conference on* (pp. 1-6). IEEE.
- Wang, A. H., and Yang, S. X. (2017). Research on the Impact of the "Belt and Road" International Logistic Performance on China's Export. *Journal of South China University of Technology (Social Science Edition)*, 1, 002.
- Yılmaz, T. ve Yılmaz Z., (2017) Assesment of Logistic Performance Indexes of EU Countries by AHP and VIKOR Methods, *Middle East Journal of Education*, 3(2) ss.73-92
- Yücesoy, E., ve Nabiyev, V. V. (2016). Konuşmacı Yaş ve Cinsiyetinin Gkm Süper vektörlerine Dayalı Bir Dvm Sınıflandırıcısı İle Belirlenmesi. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 31(3).

Zhang, G., Hu, M., Patuwo, E. and Indro, D. (1999), Artificial Neural Networks in Bankruptcy Prediction: General Framework And Cross-Validation Analysis. European Journal of Operational Research, 16-32.