

Bacalı Kombi Satış Miktarlarının Tahmininde Yapay Sinir Ağının Kullanılması ve Tedarik Zinciri Yönetimi İçerisindeki Önemi

Using Artificial Neural Network in Estimate of Sales Amounts of Vented Combi and Its Importance in Supply Chain Management

Osman Yakıt¹, Yılmaz Özkan²

Öz

Çalışmanın amacı, PRODTR kodlu "Bacalı Kombi" ürün satışlarını Yapay Sinir Ağı kullanarak tahmin etmek ve bu tahminin tedarik zinciri yönetimi açısından önemini açıklamaktır. Veri seti olarak Türkiye İstatistik Kurumu'nun yayınladığı "Kombi (Bacalı)" isimli ürüne ait değişken değerleri kullanılmıştır. Yıllık veriler için yapay sinir ağı oluşturulmuş ve üretilen tahmin sonuçları gerçekleşen değerlerle karşılaştırılmıştır. Tahmin duyarlılığı hesaplanmış ve tedarik zinciri yönetimi açısından önemi vurgulanmıştır. MATLAB Neural Network Toolbox, Yapay Sinir Ağının eğitilmesi ve tahmin işleminin gerçekleştirilmesi için kullanılmıştır.

Anahtar Kelimeler: Yapay Sinir Ağı, Tedarik Zinciri Yönetimi, Üretim Yönetimi.

Abstract

Purpose of the study is to predict the sales of the "Combi (with chimney)" product coded PRODTR using Artificial Neural Network and to explain the importance of this prediction in terms of supply chain management. As the data set, variable values related to the product named "Combi (with chimney)" has published by the Turkish Statistical Institute were used. An artificial neural network has created for annual data, and the forecast results produced were compared with the actualized values. Forecast sensitivity has calculated and its importance for supply chain management is highlighted. MATLAB Neural Network Toolbox has used for to be trained the Artificial Neural Network and to be performed the prediction process.

Keywords: Artificial Neural Network, Supply Chain Management, Production Management.

Araştırma Makalesi [Research Paper]

JEL Codes: M10, M11, C45

Submitted: 14 / 10 / 2023

Accepted: 23 / 01 / 2024

¹ Öğr. Gör. Dr., Akdeniz Üniversitesi, Antalya, Türkiye, oyakit@akdeniz.edu.tr, Orcid No: <https://orcid.org/0000-0001-8353-9164>

² Prof. Dr., İstanbul Gelişim Üniversitesi, İstanbul, Türkiye, yozkan@gelisim.edu.tr, Orcid No: <https://orcid.org/0000-0002-8831-288X>

Giriş

Geçmişten günümüze kadar geçen zaman içerisinde firmaların geleceği şekillendirebilme isteği her daim var olduğu bilinen bir olgudur. Yapay Sinir Ağları (YSA) ise bu isteğin karşılanması için ortaya çıkan bir kavram olarak ele alınmalıdır. Bu kavram, birbirinden farklı birçok çalışmada değişik şekillerde tanımlanmıştır. Örneğin; Agatonovic-Kustrin ve Beresford (2000: 718), YSA'nın; insan beyninin sayısallaştırılmış modelleri ve bu organın sahip olduğu süreç bilgisinin benzerini oluşturma şeklinde dizayn edilmiş bilgisayar yazılımları olduğunu savunmuştur. Hasegawa vd. (1995: 569); aynı kavramı, beyin fonksiyonunu taklit eden bilgi süreç sistemleri olarak tanımlamıştır. Balkin ve Lin (2000: 2217) ise YSA'nın; zaman serisi tahminini içeren, geniş bir uygulama yelpazesine sahip istatistiksel modelleme araçları olduğunu vurgulamıştır. Bu tanımlamalar ışığında, YSA; insan beyninin işlevsel boyutu baz alınarak geliştirilmiş, tahminleme ve modelleme yapmada kullanılan ve uygulama odaklı olan istatistik temelli araçlar olarak tanımlanabilir.

YSA'nın temel karakteristik yapısının ne şekilde olduğunun bilinmesi ise, YSA tekniğinin daha iyi anlaşılmasına katkı sağlayacaktır. Bu katkının YSA'ya bağlı değerlendirme durumları için önem arz ettiği ifade edilebilir. Bahsedilen katkı noktasında, Özşahin (2013: 770), tipik bir yapay sinir ağının; düğümlerden (nöronlardan) meydana gelen katmanların oluşturduğu bir katman dizisi ve bu diziyeye ait tam bağlantılar şeklinde olduğunu, aynı katmana ait düğümler arasında hiçbir bağlantının bulunmadığını ve bir YSA modelinin genel manada giriş katmanı, gizli katman veya katmanlar ile birlikte çıktı katmanından oluştuğunu vurgulamış ve bu üç katman çeşidinin gerçekleştirdiği faaliyetleri ayrı ayrı belirtmiştir. Buna ek olarak Balls vd. (1996: 272), her yapay sinir ağının üç katman (giriş katmanı, gizli katman ve çıktı katmanı) şeklinde düzenlenmiş, birbirine bağlı ve bir seri biçimindeki düğümlerden oluştuğunu, giriş katmanındaki düğümlerin birer faktör, gizli katmandaki düğümlerin birer özellik sezinleyici, çıktı katmanının kendisinin ise, etkiyi gösterdiğini vurgulamıştır. Ayrıca bu yazarlar (Balls vd., 1996) aynı eserlerindeki aynı sayfada; düğümler arası bağlantıların, çıktı değerlerini üretmek için girdi değerleri tarafından değiştirilen etkin matematiksel ağırlıklar olduğunu ve ağın; eğitim veri setinin içinde yer alan girdilere doğru yanıtlar sunan çıktı değerleri üretene kadar, tekrarlı bir sürecin içindeki düğümlere ait aralıksız olarak değişen ağırlıklar tarafından eğitildiğini savunmuşlardır. Yitian ve Gu (2003: 124) ise, YSA'nın ağırlıklarına karar verme sürecinin eğitim veya öğretim olarak isimlendirildiğini belirterek bu süreci bir matematiksel modele ait kalibrasyona benzetmiştir.

YSA'nın tahmin oluşturma konusunda kullanılmasının nedenleri bu tekniğin sahip olduğu özellikler ile açıklanabilmektedir. Sietsma ve Dow (1991: 67), Yapay Sinir Ağları 'na ait başlıca güçlü yönlerden birinin, ağa daha önce hiç sunulmamış olan yapıları teşhis etme veya doğru sınıflandırma yeteneği olduğunu savunmuştur. Diğer yandan; Basheer ve Hajmeer (2000: 4), YSA'ya dayalı bir hesaplama gerçekleştirmenin temel amacının insan beyninde yer alan bilgi sürecini ve tecrübeyi taklit etme yoluyla YSA'nın öğrenmesine imkân sağlayacak matematiksel algoritmalar geliştirmek olduğunu vurgulamıştır. Bu algoritmaların istenilen düzeyde geliştirilebilmesi ve en iyi algoritma hedefine ulaşılabilmesi için YSA'nın kendine has olan özelliklerinin geliştirici tarafından iyi bilinmesi gerekmektedir. Ayrıca, YSA'nın öğrendiği bilgiler ışığında karara varabilme yeteneğine sahip olması da kendine has ve güçlü olarak nitelendirilebilecek bir diğer özelliğidir.

Türkiye İstatistik Kurumu'nun resmi internet adresinde yayınladığı "Yıllık Sanayi Ürün (PRODCOM) İstatistikleri" ana başlığı altında yer alan 25.21.12.00.01 PRODTR koduna sahip "Kombi (bacalı)" adlı ürün tanımına ait ilgili değişkenlerin MATLAB programında veri seti olarak kullanılması ve elde edilen bilgilerin kıyaslamaya konu edilerek bir sonuca ulaşılması literatüre katkı vermesi bakımından önem kazanmaktadır. Özellikle, ürünle ilgili satış miktarlarının tahmin edilebilmesi, tedarik zinciri bünyesinde bulunan bazı yönetim kademeleri için önemsenen bir konudur. Yöneticilerin gelecekle ilgili kararlarında sektöre ilişkin tahminlere ihtiyaç duyabilecekleri bilinmektedir.

Bu çalışmada, Yapay Sinir Ağları yardımıyla ürünle ilgili satış miktarları tahmin edilmiş, tahmin sonuçları ile gerçekleşmiş değerler karşılaştırılmış, "Yüzdesel Değişim Toplamının Yıllık Ortalaması" nın nasıl hesaplandığı açıklanarak yüzdesel değişim toplamlarına ait ortalamaların Tedarik Zinciri Yönetimi açısından önemi belirtilmiştir. Çalışmanın birinci bölümünde literatür araştırma sonuçları, ikinci bölümünde MATLAB yazılımı ile gerçekleştirilen uygulama, üçüncü bölümünde bulgular, dördüncü bölümünde tedarik zinciri yönetiminde yüzdesel değişim toplamlarına ait ortalamaların önemi ve son bölümünde sonuç ve değerlendirmeler yer almaktadır.

1. Literatür Taraması

Adewole vd. (2013: 606-611), LPG (Sıvılaştırılmış Petrol Gazı) yakıtlı bir girdap brülöründeki LPG'nin yanması ile ortaya çıkan alev sıcaklığını ve kirletici emisyonları tahmin etmek için standart geri yayılım algoritmalarına dayanan bir yapay sinir ağı modeli geliştirmiştir. Barclay vd. (2013: 127-140), deneylerden elde ettiği sonuçları, yapay sinir ağı modelleri oluşturmada kullanmış ve yapay sinir ağlarının hem endüksiyonla ısınmadan sonra hem de kaynak sonrası plağın son bozulmasını tahmin etme yeteneğini kanıtlar nitelikte olduğunu savunmuştur. Simonović vd. (2016: 1355-1365), küçük bir bölgeye ait ısıtma sisteminde üretilen enerjinin ısı tüketiminin 1 ila 7 gün önceden tahmin edilmesi için bir çeşit gelişmiş

yapay sinir ağı modeli sunmuştur. Silveira vd. (2014: 1-9), tavuk karkaslarının son sıcaklığının endüstriyel ölçekte tahminlenmesinde bir yapay sinir ağı kullanmıştır.

Al-Chalabi vd. (2014: 311-322), madencilik sektöründe kullanılan sondaj makinelerinin ekonomik ömrünü tahmin edebilmek amacıyla bir yapay sinir ağı kullanmış ve bu kullanımın ortaya koyduğu sonuçlar üzerinde durmuştur. Ebrahimabadi vd. (2015: 573-583), yapay sinir ağı yaklaşımını kullanarak ortalama kapasiteye sahip tünel açma makinelerinin anlık kesme oranları noktasında kesme performansının araştırılmasını amaçlamış ve Kohonen Kendini Organize Eden Özellik Haritası (KSOFM) 'na ilişkin yapay sinir ağının sistem davranışının ve bilgi almanın anlaşılmasında etkili bir yol olduğu sonucuna varmıştır. Monazami vd. (2012: 21-31), İran'ın güneyindeki petrol sahalarının birinden elde edilmiş sondaj parametrelerinin arasında yer alan Nüfuz Etme Oranı'nın tahmin edilmesi amacıyla yapay sinir ağı kuramlarının bir uygulamasını sunmuştur.

Kuo vd. (2015: 1560-1569), mekanik olarak havalandırılmış hastalarda başarılı ekstübasyonu tahmin etmek için bir yapay sinir ağı modeli hazırlamış ve bu modelin başarılı ekstübasyon tahminlemesine ait doğruluğu geliştirdiğini ifade etmiştir. Przednowek vd. (2017: 175-189), yapay sinir ağlarını kullanarak engel aşmada antrenman yüklerinin planlanmasına ilişkin yeni bir yaklaşım sunmuş, sonuç olarak elde edilen modelin seçilen bir antrenman periyodu boyunca bir antrenöre antrenman yüklerinin planlanmasında yardımcı olacak bir araç olarak kullanılabileceği yargısına varmıştır.

Moghaddam vd. (2016: 89-93), güçlü bir yapay sinir ağı modeli geliştirebilmek amacıyla 28 Ocak 2015'ten 18 Haziran 2015'e kadar geçen süredeki NASDAQ 'ın günlük borsa kurlarını kullanmış ve günlük NASDAQ borsa kurunun tahmin edilmesinde yapay sinir ağının kabiliyetini araştırmıştır. Choudhry vd. (2012: 170-178), mikro yapıli piyasa değişkenlerinin yabancı döviz kurlarının tahminlenmesinde nasıl kullanılabileceğini irdelemiş ve bu bağlamda yapay sinir ağı tahmin kuramını uygulamıştır.

2. Uygulama

2.1. Çalışmanın Amacı

Çalışma iki amaca sahiptir. Bu amaçlardan ilki, "Yıllık Sanayi Ürün (PRODCOM) İstatistikleri" ana başlığı altında yer alan 25.21.12.00.01 PRODTR koduna sahip "Kombi (bacalı)" adlı ürün tanımının "Üretim Değeri", "Satış Değeri" ve "Üretim Miktarı" değişken değerlerini kullanarak, MATLAB programında onbir yıl için yapay sinir ağı ile ayrı ayrı satış miktarlarını tahmin etmek, bu tahmin edilen değerleri mevcut değerler ile kıyaslamaktır. Amaçlardan ikincisi ise, MATLAB'ın tahminleme konusundaki duyarlılığının ortaya konulup bu duyarlılığın Tedarik Zinciri Yönetimi içerisindeki önemi açıklanarak işletme yöneticilerine bu noktada ışık tutmaktır.

2.2. Kapsam ve Sınırlılıklar

TÜİK Sanayi Ürünleri Yıllık Üretim ve Satış İstatistiklerinde yer alan Kombi (bacalı) adlı ürün tanımındaki ilgili "Üretim Miktarı", "Üretim Değeri", "Satış Miktarı", "Satış Değeri" isimli değişkenler, çalışmanın veri setini oluşturmaktadır. Ürünle ilgili "Girişim Sayısı" isimli değişken; TÜİK'in yaptığı tanımdan, bu değişkenin tahmin edilmiş veriyi de kapsamış olabileceği nedeniyle kapsam dışı bırakılmıştır.

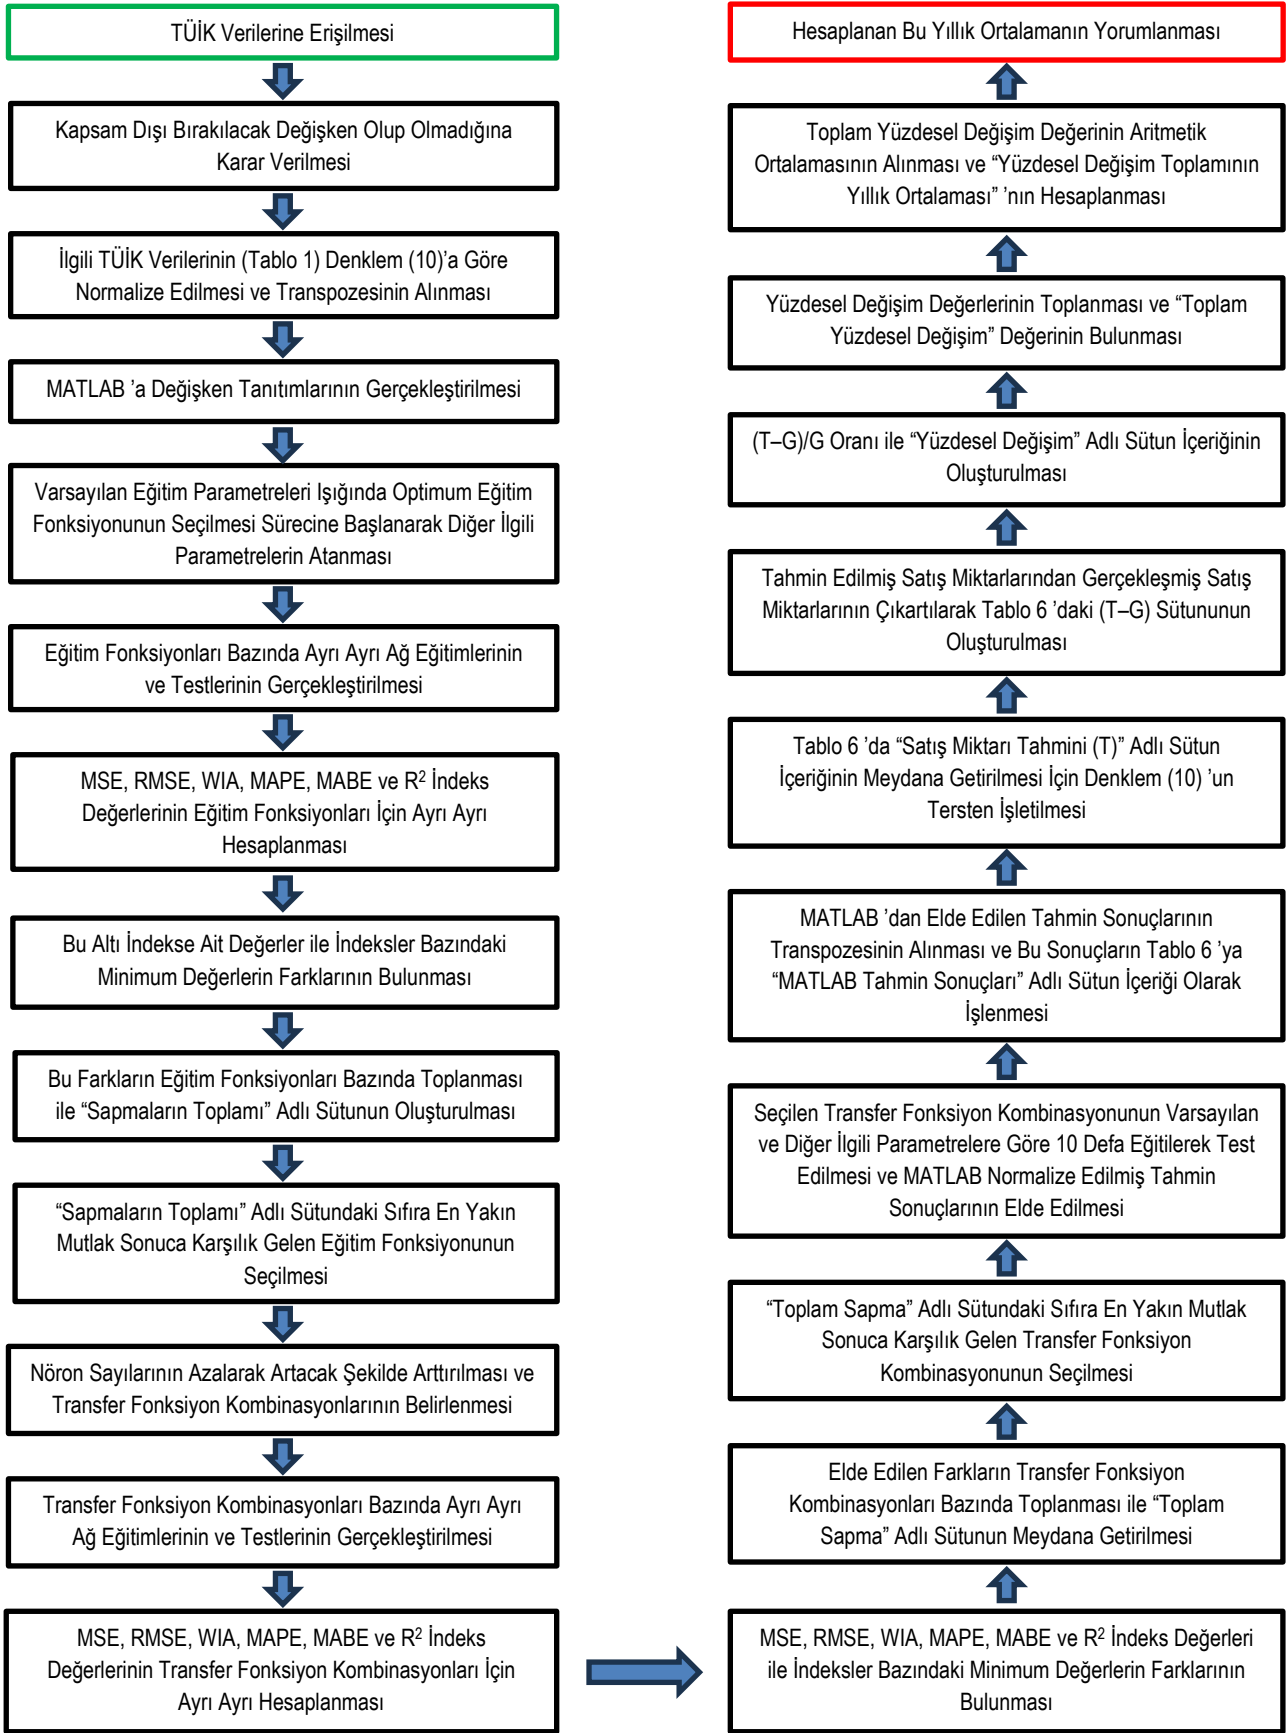
2.3. Yöntem

MATLAB programıyla oluşturulan yapay sinir ağı, tahmin için bir ara işlem olarak düşünülmüştür. Bu sinir ağının oluşturulması sırasında seçilen ileri beslemeli geri yayılım (Feed-forward backprop) ağ tipi, tahminlemede sıklıkla kullanılan bir ağ tipi olma özelliğine sahiptir. Bununla birlikte söz konusu ağ tipi, bu makale çalışmasındaki ilgili sinir ağlarının ağ tipi noktasında çalışma mantığını barındırmaktadır. İleri beslemeli geri yayılım ağ tipi için Devi vd. (2016) ile Khan vd. (2016) 'nin görüşleri ise şu şekildedir:

Geri yayılım ağı, ileri beslemeli bir ağıdır. Ağ tipinin adı olarak bilinen bu yapı, aynı zamanda çok katmanlı yapay sinir ağlarının eğitilmesinde kullanılan sistematik bir metot ve tahmin görevinde kullanılan en popüler paradigmadır (Devi vd., 2016: 418). Geri yayılım; her öğrenme olayından sonraki her bağlantı ile eşdeğer ağırlıkların ayarlanmasından sonra istenen çıktılar üreten ileri beslemeli sinir ağlarında, çok önemli öğrenme algoritmalarından biridir (Khan vd., 2016: 2716).

RMSE (Root Mean Square Error: Ortalama Karesel Hatanın Karekökü), MSE (Mean Square Error: Ortalama Karesel Hata), MAPE (Mean Absolute Percentage Error: Ortalama Mutlak Yüzdellik Hata), MABE (Mean Absolute Bias Error: Ortalama Mutlak Sapma Hatası), WIA (Willmott Uyum İndeksi) ve R² (Coefficient of Determination: Belirlilik Katsayısı) değerlerinin ise hangi formüller ile hesaplandığı bilinmelidir.

Bu formüllerden bahsetmeden önce, çalışmaya ait ilgili akış diyagramının aşağıdaki şekilde belirtilmesi yerinde olacaktır:



Şekil 1. Çalışmayla İlgili Akış Diyagramı

Willmott ve Matsuura (2005: 80), model tahminlerini P_i ($i = 1, 2, \dots, n$), güvenilir ve çift yönlü eşleştirmeli gözlemleri O_i ($i = 1, 2, \dots, n$) olarak göstermiş, bireysel model tahmin hatalarının genellikle $e_i = P_i - O_i$ şeklinde tanımlandığını belirterek RMSE formülünü şu şekilde ifade etmişlerdir:

$$\text{RMSE} = \left[n^{-1} \sum_{i=1}^n |e_i|^2 \right]^{1/2} \quad (1)$$

Fox (1981: 607), çalışmasında RMSE 'yi, MSE 'nin karekökü olarak RMS adıyla ifade etmiştir. Willmott ve Matsuura (2005) 'nın (1) numaralı RMSE formülünün karesi alınırca, MSE aşağıdaki formülle gösterilebilir:

$$\text{MSE} = [\text{RMSE}]^2 = \left[\left[n^{-1} \sum_{i=1}^n |e_i|^2 \right]^{1/2} \right]^2 = n^{-1} \sum_{i=1}^n |e_i|^2 \quad (2)$$

Shen vd. (2015: 246) MAPE'yi (3) numaralı formülle hesaplamışlardır. Formülde; y_i gerçek gözlem değerlerini, y'_i tahmin değerlerini, T ise tahmin sayısını göstermektedir:

$$\text{MAPE} = \frac{1}{T} \sum_{i=1}^T \left| \frac{y_i - y'_i}{y_i} \right| \times 100 \quad (3)$$

Willmott vd. (2012: 2088-2089); Willmott ve Wicks (1980: 59-73) ile Willmott (1981: 184-194)'un çalışmalarında, Willmott Uyum İndeksi'nin orijinal haline bir denklem (4) tanımlaması olarak yer verdiklerini savunmuş, bu indeksi göstermede Willmott ve Wicks (1980)'in " ρ " yerine " d " 'yi kullandığını ifade etmiştir. Bununla birlikte; Willmott vd. (2012: 2088-2089), Denklem (4)'deki değişkenlerin anlamlarının neler olduğunu vurgulayarak, ilgili orijinal indekse ait formülün Denklem (5)'teki hale gelmiş olduğunu ve Denklem (5) 'in sadeleştirilen, genellikle bu sadeleştirilmiş şekliyle yazılan halinin Denklem (6) 'da yer aldığı biçimde olduğunu belirtmiştir ($d = \text{WIA}$):

$$\rho = 1 - \delta/\mu \quad (4)$$

$$d = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (5)$$

$$d = 1 - \frac{\sum_{i=1}^n [(P_i - \bar{O}) - (O_i - \bar{O})]^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (6)$$

Denklem (4) içindeki " ρ "; Willmott Uyum İndeksi'nin orijinal halini, " δ "; ortalama hatanın boyutsal bir ölçüsünü veya ortalama hata boyutunu, " μ "; karşılaştırmaya ait bir kuralı ve bununla birlikte, Denklem (5) ve Denklem (6) içindeki " P_i "; model tahminlerini ($i = 1,2,\dots,n$), " O_i "; güvenilir ve çift yönlü eşleştirmeli gözlemleri ($i = 1,2,\dots,n$), " \bar{O} ", gözlemlere ait aritmetik ortalamayı ifade etmektedir (Willmott vd., 2012: 2088-2089). Mohammadi vd. (2015: 224), MABE 'nin Denklem (7) 'de yer aldığı şekilde tanımlandığını belirtmiş ve bu denklemdeki $X_{i,pred}$ ve $X_{i,meas}$ 'in sırasıyla i 'inci tahmini ve i 'inci gözlemlenen değerler olduğunu savunmuştur:

$$\text{MABE} = \frac{1}{n} \sum_{i=1}^n |X_{i,pred} - X_{i,meas}| \quad (7)$$

Quej vd. (2016: 452); çalışmalarında R^2 değerini, Denklem (8) 'deki biçimde tanımlamış ve bu denklemdeki n 'in; karşılaştırma sayısını, H_m 'in; ölçülen güneş radyasyonunu, $H_{m,avg}$ 'nin; ölçülen güneş radyasyon değerlerinin aritmetik ortalamasını, H_c 'nin; tahmini güneş radyasyonunu ve $H_{c,avg}$ 'nin; tahmini güneş radyasyon değerlerinin aritmetik ortalamasını gösterdiğini vurgulamıştır:

$$R^2 = \frac{[\sum_{i=1}^n (H_c - H_{c,avg})(H_m - H_{m,avg})]^2}{\sum_{i=1}^n (H_c - H_{c,avg})^2 \sum_{i=1}^n (H_m - H_{m,avg})^2} \quad (8)$$

Diğer yandan, N: Karşılaştırma sayısını, D_t: Tahmin değerini, D_{t,ao}: Tahmin değerlerinin aritmetik ortalamasını, D_g: Gerçekleşmiş değeri, D_{t,ao}: Gerçekleşmiş değerlerin aritmetik ortalamasını göstermek üzere; Denklem (8) 'deki Quej vd. (2016) 'ne ait formülü genel anlamda aşağıdaki şekilde ifade etmek mümkündür:

$$R^2 = \frac{[\sum_{i=1}^N (D_t - D_{t,ao})(D_g - D_{g,ao})]^2}{\sum_{i=1}^N (D_t - D_{t,ao})^2 \sum_{i=1}^N (D_g - D_{g,ao})^2} \quad (9)$$

2.4. “Kombi (bacalı)” Adlı Ürün ile İlgili Değişkenlerin Tahmin için Kullanılması

PRODTR 25.21.12.00.01 kodlu kombi (bacalı) ürünü ile ilgili tahmine ilişkin değişkenler; Üretim Miktarı, Üretim Değeri, Satış Miktarı ve Satış Değeri olup, Tablo 1'de gösterilmiştir:

Tablo 1. Bacalı Kombi Tahmin Değişkenleri (2005-2015)

Yıllar	Üretim Miktarı (Adet)	Üretim Değeri (TL)	Satış Miktarı (Adet)	Satış Değeri (TL)
2005	345247	267482002	357232	277432128
2006	401628	322251317	417497	335527652
2007	355549	268894841	363046	273798070
2008	363202	293751835	369554	298764556
2009	410920	316016483	423053	325543896
2010	521787	381668170	532205	388427304
2011	727981	586397063	724439	584343715
2012	791489	678766827	775878	665349500
2013	708888	657010486	714716	661550031
2014	724431	730971510	717323	728936428
2015	723527	774933464	743910	810904616

Kaynak: TÜİK, 2018 (<https://data.tuik.gov.tr/Kategori/GetKategori?p=sanayi-114&dil=1> Erişim Tarihi: 25.07.2018)

Tablo 1'deki ilgili değişkenlerle tahmin yapabilmek için ilgili değerler, Jiang vd. (2010: 3)'nin kullandıkları formül (10) ile normalize edilmiştir. Formülde; x orijinal, x' ise normalize edilmiş girdi değerini göstermektedir. Ayrıca, Jiang vd. (2010: 3), girdi vektörlerine ait değer aralığının [0, 1] olacağını belirtmiştir.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (10)$$

MATLAB programında değişkenleri tanımlamak için normalize edilen değişkenlerin transpozesi alındıktan sonra Neural Network Toolbox adlı bileşene Satış Miktarı “Hedef”, diğer değişkenler “Girdi” olarak tanımlanmış ve virgülden sonra on beş basamak alınmıştır. Optimum eğitim fonksiyonunun seçilebilmesi için, ağ tipi (Feed-forward backprob), adaptasyon öğrenme fonksiyonu (LEARNGDM), performans fonksiyonu (MSE), katman sayısı (2), nöron sayısı (10), gizli katman (Layer 1) için transfer fonksiyonu (TANSIG), çıktı katmanı (Layer 2) için transfer fonksiyonu (TANSIG) sabit tutulmuştur. Ayrıca, eğitim fonksiyonları bazında MATLAB tarafından ayrı ayrı varsayılan olarak tanımlanmış olan eğitim parametrelerinde herhangi bir değişiklik gerçekleştirilmemiştir. Sadece eğitim fonksiyonları olan; TRAINBFG, TRAINBR, TRAINCGB, TRAINCGF, TRAINCGP, TRAINGD, TRAINGDM, TRAINGDA, TRAINGDX, TRAINLM, TRAINOSS, TRAINR, TRAINRP, TRAINSCG değiştirilmiştir. Eğitim fonksiyonlarını MSE, RMSE, WIA, MAPE, MABE ve R² değerlerine göre karşılaştırabilmek için Tablo 2 oluşturulmuştur:

Tablo 2. Eğitim Fonksiyonlarına Ait Değerler

Eğitim Fonksiyonu	Eğitim Süresi (Saniye)	Ağ Eğitimi İterasyon Sayısı	MSE	RMSE	WIA	MAPE	MABE	R ²
TRAINBFG	1	24	0,02109	0,14524	0,97131	7,09667	0,08550	0,92528
TRAINBR	3	214	0,00168	0,04097	0,99727	3,14363	0,03512	0,99268
TRAINCGB	0 ila 1 arası	16	0,00355	0,05956	0,99475	3,39564	0,04976	0,98151
TRAINCGF	0 ila 1 arası	38	0,02045	0,14300	0,96865	7,85813	0,10432	0,92913
TRAINCGP	0 ila 1 arası	15	0,00478	0,06914	0,99302	4,48326	0,05924	0,97883
TRAINGD	1	368	0,00734	0,08567	0,98722	5,67608	0,06663	0,96303
TRAINGDM	1	359	0,00751	0,08668	0,98694	5,72373	0,06744	0,96159
TRAINGDA	0 ila 1 arası	66	0,00737	0,08583	0,98720	5,68761	0,06684	0,96257
TRAINGDY	0 ila 1 arası	69	0,01152	0,10734	0,98005	6,62795	0,07824	0,94219
TRAINLM	0 ila 1 arası	13	0,00569	0,07542	0,99214	3,09476	0,04937	0,99004
TRAINOSS	0 ila 1 arası	10	0,02328	0,15259	0,96894	8,17236	0,10413	0,91787
TRAINR	2	29	0,00541	0,07352	0,99094	5,06614	0,05960	0,97004
TRAINRP	0 ila 1 arası	14	0,01258	0,11216	0,97762	8,19173	0,08714	0,96537
TRAINSOG	0 ila 1 arası	11	0,00581	0,07625	0,99022	5,00553	0,05974	0,96810


MATLAB ile bulunan sonuçlar, ağın bir kere eğitilmesinin ve akabinde tüm girdi değerleri için test edilmesinin bir sonucu olarak elde edilmiş olan normalize edilmiş tahmin değerleridir. MSE, RMSE, WIA, MABE ve R² değerleri, gerçekleşen değerlerin normalize edilmiş halleri ve MATLAB uygulaması sonucu elde edilmiş normalize tahmini değerler kullanılarak hesaplanmıştır. MAPE hesaplanırken; anılan normalize edilmiş tahmin sonuçlarının (10) numaralı formülün tersten işletilerek normalize edilmemiş tahmin sonuçlarına çevrilmiş değerleri ve gerçekleşen değerlerin normalize edilmemiş halleri kullanılmıştır. Bunun nedeni, MAPE 'nin formülünde payda kısmında x_i 'nin yer alması ve bu nedenle Formül (10) kullanılarak elde edilen normalize edilmiş satış miktarı sütunundaki bir değer mutlaka 0 (sıfır) çıkmasıdır. MSE, RMSE, MAPE ve MABE değerlerinden minimum değerlerin, WIA ve R² değerlerinden maksimum değerlerin çıkartılmasıyla bulunan sapma değerleri Tablo 3'te gösterilmiştir. Sonraki adımda, hesaplanan değerler her satır için toplanarak "Sapmaların Toplamı" bulunmuştur:

Tablo 3. Sapmalara Ait Toplam Değerler

Eğitim Fonksiyonu	MSE – MSE _{min}	RMSE – RMSE _{min}	WIA – WIA _{maks}	MAPE – MAPE _{min}	MABE – MABE _{min}	R ² – R ² _{maks}	Sapmaların Toplamı
TRAINBFG	0,01941	0,10427	-0,02596	4,00191	0,05038	-0,06740	4,08261
TRAINBR	0	0	0	0,04887	0	0	0,04887
TRAINCGB	0,00187	0,01859	-0,00252	0,30088	0,01464	-0,01117	0,32229
TRAINCGF	0,01877	0,10203	-0,02862	4,76337	0,06920	-0,06355	4,86120
TRAINCGP	0,00310	0,02817	-0,00425	1,38850	0,02412	-0,01385	1,42579
TRAINGD	0,00566	0,04470	-0,01005	2,58132	0,03151	-0,02965	2,62349
TRAINGDM	0,00583	0,04571	-0,01033	2,62897	0,03232	-0,03109	2,67141
TRAINGDA	0,00569	0,04486	-0,01007	2,59285	0,03172	-0,03011	2,63494
TRAINGDY	0,00984	0,06637	-0,01722	3,53319	0,04312	-0,05049	3,58481
TRAINLM	0,00401	0,03445	-0,00513	0	0,01425	-0,00264	0,04494
TRAINOSS	0,02160	0,11162	-0,02833	5,07760	0,06901	-0,07481	5,17669
TRAINR	0,00373	0,03255	-0,00633	1,97138	0,02448	-0,02264	2,00317
TRAINRP	0,01090	0,07119	-0,01965	5,09697	0,05202	-0,02731	5,18412
TRAINSOG	0,00413	0,03528	-0,00705	1,91077	0,02462	-0,02458	1,94317

Tablo 3'teki sapmaların en düşük toplam değeri "0,04494" olarak hesaplanmış, bu değere ilişkin bir hücre için sapma değerinin ise sıfır çıktığı görülmüştür. MAPE – MAPE_{min} sütunu ile TRAINLM satırının kesiştiği hücrede sapma değeri sıfırdır. TRAINLM, eğitim fonksiyonları içinde en düşük MAPE değerine sahip fonksiyondur.

“Sapmaların Toplamı” sütunundaki değerler mutlak olarak alınmış ve sıfıra yakın olma durumları incelenmiştir. Bu inceleme, ağ eğitimin tamamlandığı süre ve iterasyon sayısı bir bütün olarak değerlendirildiğinde; optimum sonucu veren eğitim fonksiyonunun, “TRAINLM” olduğu sonucuna ulaşılmış, veri setine en uygun eğitim fonksiyonu olarak “TRAINLM” seçilmiştir. Ayrıca, Tablo 2. 'de yer alan ve TRAINLM eğitim fonksiyonuna ait MSE, RMSE, WIA, MAPE, MABE ve R² değerlerinin hesaplanmasında kullanılan tahmin değerlerinin elde edilmesi noktasında ağın eğitilmesiyle ilişkili MATLAB ekran görüntüsü Şekil 2. 'de verilmiştir.



Şekil 2. TRAINLM Eğitim Fonksiyonuna Ait Ağ Eğitimi İçin MATLAB Ekran Görüntüsü

Eğitim fonksiyonu belirlendikten sonra; gizli katman ve çıktı katmanı için, en uygun transfer fonksiyon kombinasyonu ve nöron sayısının belirlenmesi gerekmektedir. Bunun için, nöron sayıları birden on altıya kadar sırasıyla 5,4,3,2 ve 1 (6–1=5, 10–6=4, 13–10=3, 15–13=2 ve 16–15=1) artış oranları dâhilinde -azalarak artacak şekilde- artırılmış ve transfer fonksiyon kombinasyonları oluşturulmuştur (Bakınız: Tablo 4). Bununla birlikte; transfer fonksiyon kombinasyonları ve bu kombinasyonlara ait gizli katman nöron sayıları bazında MATLAB 'da elde edilen normalize tahmin değerleri, Tablo 4'teki MSE, RMSE, WIA, MAPE, MABE ve R² değerlerini elde etmek için kullanılmıştır. Eğitim fonksiyonu “TRAINLM” iken, gizli ve çıktı katmanı için en uygun transfer fonksiyon kombinasyonu ve nöron sayısı ise Tablo 5'te gösterilmiştir.

Tablo 4. Transfer Fonksiyon Kombinasyonları ve İlgili Nöron Sayılarına Ait Değerler*

Sıra No	EF	GKTF	ÇKTF	GKNS	MSE	RMSE	WIA	MAPE	MABE	R ²
1	TRAINLM	TANSIG	LOGSIG	1	0,08917	0,29861	0,76765	23,28239	0,22335	0,92290
2	TRAINLM	TANSIG	TANSIG	1	0,01059	0,10288	0,98291	4,20647	0,05584	0,93887
3	TRAINLM	TANSIG	PURELIN	1	0,00106	0,03250	0,99831	1,01672	0,01604	0,99552
4	TRAINLM	LOGSIG	LOGSIG	1	0,09053	0,30088	0,75109	23,92182	0,23458	0,92330
5	TRAINLM	LOGSIG	TANSIG	1	0,00565	0,07516	0,99059	3,83446	0,04912	0,96978
6	TRAINLM	LOGSIG	PURELIN	1	0,00430	0,06556	0,99385	4,00299	0,05159	0,98236
7	TRAINLM	PURELIN	LOGSIG	1	0,09278	0,30460	0,81184	24,74140	0,24752	0,92192
8	TRAINLM	PURELIN	TANSIG	1	0,00113	0,03362	0,99823	2,66312	0,03061	0,99316
9	TRAINLM	PURELIN	PURELIN	1	0,00003	0,00514	0,99996	0,32061	0,00413	0,99985
10	TRAINLM	TANSIG	LOGSIG	6	0,08743	0,29569	0,79582	22,76141	0,21345	0,92900
11	TRAINLM	TANSIG	TANSIG	6	0,00088	0,02960	0,99864	1,88579	0,02004	0,99501
12	TRAINLM	TANSIG	PURELIN	6	0,00706	0,08402	0,98806	3,54175	0,05473	0,98135
13	TRAINLM	LOGSIG	LOGSIG	6	0,08727	0,29542	0,78963	22,46576	0,20835	0,92684
14	TRAINLM	LOGSIG	TANSIG	6	0,00191	0,04376	0,99682	3,33329	0,03967	0,99381
15	TRAINLM	LOGSIG	PURELIN	6	0,00173	0,04160	0,99718	2,81496	0,03561	0,99373

16	TRAINLM	PURELIN	LOGSIG	6	0,08919	0,29865	0,77820	23,65667	0,22887	0,89767
17	TRAINLM	PURELIN	TANSIG	6	0,00395	0,06284	0,99353	4,41051	0,05351	0,98135
18	TRAINLM	PURELIN	PURELIN	6	0,00007	0,00850	0,99989	0,50820	0,00696	0,99966
19	TRAINLM	TANSIG	LOGSIG	10	0,08851	0,29751	0,79999	23,20146	0,22090	0,92298
20	TRAINLM	TANSIG	TANSIG	10	0,00569	0,07542	0,99214	3,09476	0,04937	0,99004
21	TRAINLM	TANSIG	PURELIN	10	0,00811	0,09007	0,98654	1,61854	0,02948	0,95531
22	TRAINLM	LOGSIG	LOGSIG	10	0,08906	0,29844	0,77279	23,39315	0,22510	0,91667
23	TRAINLM	LOGSIG	TANSIG	10	0,00193	0,04388	0,99713	1,51076	0,02406	0,99102
24	TRAINLM	LOGSIG	PURELIN	10	0,00609	0,07807	0,98952	4,41768	0,05414	0,96915
25	TRAINLM	PURELIN	LOGSIG	10	0,09790	0,31289	0,75250	24,50232	0,24427	0,72285
26	TRAINLM	PURELIN	TANSIG	10	0,00224	0,04735	0,99641	3,20326	0,03876	0,98694
27	TRAINLM	PURELIN	PURELIN	10	0,00003	0,00549	0,99995	0,33079	0,00445	0,99982
28	TRAINLM	TANSIG	LOGSIG	13	0,08768	0,29611	0,78440	22,64874	0,21135	0,90478
29	TRAINLM	TANSIG	TANSIG	13	0,00179	0,04232	0,99735	1,81075	0,02540	0,99286
30	TRAINLM	TANSIG	PURELIN	13	0,01340	0,11576	0,97887	2,89305	0,04983	0,92054
31	TRAINLM	LOGSIG	LOGSIG	13	0,08721	0,29531	0,79334	22,38329	0,20683	0,92534
32	TRAINLM	LOGSIG	TANSIG	13	0,00160	0,03996	0,99762	1,89741	0,02564	0,99338
33	TRAINLM	LOGSIG	PURELIN	13	0,00353	0,05943	0,99461	2,15682	0,03300	0,97899
34	TRAINLM	PURELIN	LOGSIG	13	0,09162	0,30269	0,79791	24,49531	0,24334	0,87325
35	TRAINLM	PURELIN	TANSIG	13	0,00152	0,03898	0,99754	2,83750	0,03095	0,99233
36	TRAINLM	PURELIN	PURELIN	13	0,00003	0,00535	0,99996	0,27535	0,00370	0,99985
37	TRAINLM	TANSIG	LOGSIG	15	0,09072	0,30120	0,74654	24,32334	0,24094	0,90396
38	TRAINLM	TANSIG	TANSIG	15	0,00285	0,05338	0,99555	3,68995	0,04816	0,98313
39	TRAINLM	TANSIG	PURELIN	15	0,00065	0,02544	0,99902	1,60433	0,01679	0,99651
40	TRAINLM	LOGSIG	LOGSIG	15	0,08888	0,29814	0,76467	23,60315	0,22831	0,91305
41	TRAINLM	LOGSIG	TANSIG	15	0,01248	0,11173	0,98223	5,02952	0,07021	0,95473
42	TRAINLM	LOGSIG	PURELIN	15	0,00047	0,02165	0,99929	1,18782	0,01271	0,99750
43	TRAINLM	PURELIN	LOGSIG	15	0,09249	0,30412	0,81163	24,67492	0,24638	0,92255
44	TRAINLM	PURELIN	TANSIG	15	0,00976	0,09881	0,98729	6,03790	0,07981	0,97831
45	TRAINLM	PURELIN	PURELIN	15	0,00004	0,00606	0,99994	0,27789	0,00399	0,99978
46	TRAINLM	TANSIG	LOGSIG	16	0,08726	0,29540	0,78977	22,53068	0,20947	0,92484
47	TRAINLM	TANSIG	TANSIG	16	0,04250	0,20617	0,92578	10,66694	0,12921	0,77319
48	TRAINLM	TANSIG	PURELIN	16	0,00026	0,01626	0,99959	0,69516	0,00918	0,99857
49	TRAINLM	LOGSIG	LOGSIG	16	0,08765	0,29606	0,78376	22,66270	0,21192	0,91952
50	TRAINLM	LOGSIG	TANSIG	16	0,01949	0,13961	0,97162	6,58396	0,07924	0,92461
51	TRAINLM	LOGSIG	PURELIN	16	0,05904	0,24299	0,87985	19,39757	0,19576	0,90188
52	TRAINLM	PURELIN	LOGSIG	16	0,08763	0,29603	0,78990	22,86898	0,21528	0,91434
53	TRAINLM	PURELIN	TANSIG	16	0,00150	0,03873	0,99773	2,74441	0,03306	0,99158
54	TRAINLM	PURELIN	PURELIN	16	0,00003	0,00508	0,99996	0,31359	0,00412	0,99985

* EF (Eğitim Fonksiyonu), GKTF (Gizli Katman Transfer Fonksiyonu), ÇKTF (Çıktı Katmanı Transfer Fonksiyonu), GKNS (Gizli Katman Nöron Sayısı)

Tablo 5. Transfer Fonksiyon Kombinasyonlarına İlişkin Sapmaların Toplamı**

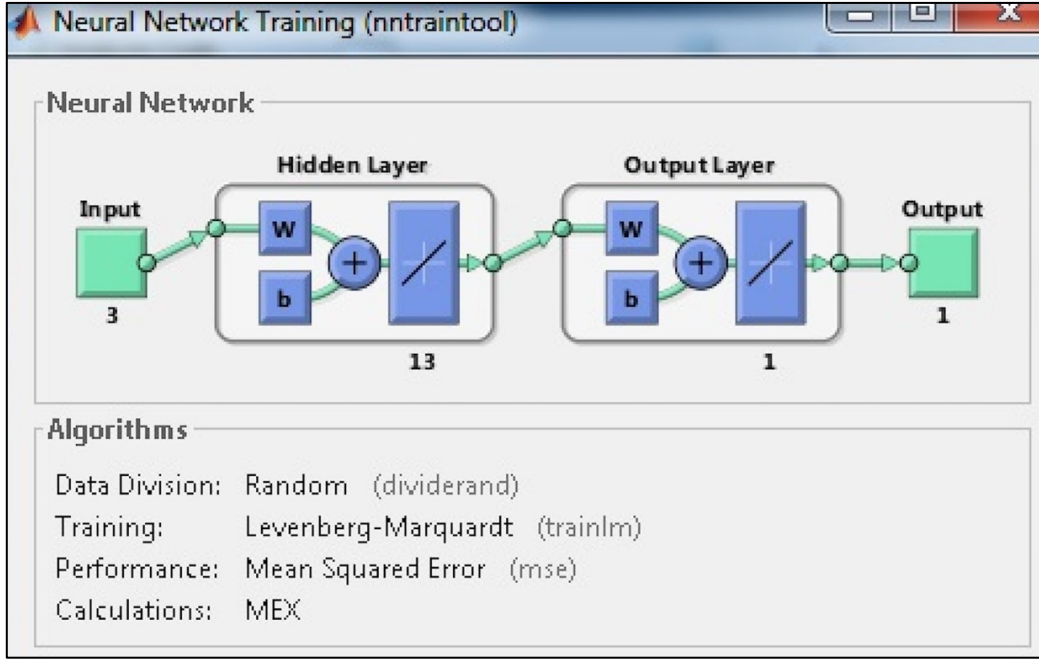
Sıra No	GKTF	ÇKTF	GKNS	MSE – MSE _{min}	RMSE – RMSE _{min}	WIA – WIA _{maks}	MAPE – MAPE _{min}	MABE – MABE _{min}	R ² – R ² _{maks}	Toplam Sapma
1	TANSIG	LOGSIG	1	0,08914	0,29353	-0,23231	23,00704	0,21965	-0,07695	23,30010
2	TANSIG	TANSIG	1	0,01056	0,09780	-0,01705	3,93112	0,05214	-0,06098	4,01359
3	TANSIG	PURELIN	1	0,00103	0,02742	-0,00165	0,74137	0,01234	-0,00433	0,77618
4	LOGSIG	LOGSIG	1	0,09050	0,29580	-0,24887	23,64647	0,23088	-0,07655	23,93823
5	LOGSIG	TANSIG	1	0,00562	0,07008	-0,00937	3,55911	0,04542	-0,03007	3,64079
6	LOGSIG	PURELIN	1	0,00427	0,06048	-0,00611	3,72764	0,04789	-0,01749	3,81668
7	PURELIN	LOGSIG	1	0,09275	0,29952	-0,18812	24,46605	0,24382	-0,07793	24,83609
8	PURELIN	TANSIG	1	0,00110	0,02854	-0,00173	2,38777	0,02691	-0,00669	2,43590
9	PURELIN	PURELIN	1	0,00000	0,00006	0,00000	0,04526	0,00043	0,00000	0,04575
10	TANSIG	LOGSIG	6	0,08740	0,29061	-0,20414	22,48606	0,20975	-0,07085	22,79883
11	TANSIG	TANSIG	6	0,00085	0,02452	-0,00132	1,61044	0,01634	-0,00484	1,64599
12	TANSIG	PURELIN	6	0,00703	0,07894	-0,01190	3,26640	0,05103	-0,01850	3,37300
13	LOGSIG	LOGSIG	6	0,08724	0,29034	-0,21033	22,19041	0,20465	-0,07301	22,48930
14	LOGSIG	TANSIG	6	0,00188	0,03868	-0,00314	3,05794	0,03597	-0,00604	3,12529
15	LOGSIG	PURELIN	6	0,00170	0,03652	-0,00278	2,53961	0,03191	-0,00612	2,60084

16	PURELIN	LOGSIG	6	0,08916	0,29357	-0,22176	23,38132	0,22517	-0,10218	23,66528
17	PURELIN	TANSIG	6	0,00392	0,05776	-0,00643	4,13516	0,04981	-0,01850	4,22172
18	PURELIN	PURELIN	6	0,00004	0,00342	-0,00007	0,23285	0,00326	-0,00019	0,23931
19	TANSIG	LOGSIG	10	0,08848	0,29243	-0,19997	22,92611	0,21720	-0,07687	23,24738
20	TANSIG	TANSIG	10	0,00566	0,07034	-0,00782	2,81941	0,04567	-0,00981	2,92345
21	TANSIG	PURELIN	10	0,00808	0,08499	-0,01342	1,34319	0,02578	-0,04454	1,40408
22	LOGSIG	LOGSIG	10	0,08903	0,29336	-0,22717	23,11780	0,22140	-0,08318	23,41124
23	LOGSIG	TANSIG	10	0,00190	0,03880	-0,00283	1,23541	0,02036	-0,00883	1,28481
24	LOGSIG	PURELIN	10	0,00606	0,07299	-0,01044	4,14233	0,05044	-0,03070	4,23068
25	PURELIN	LOGSIG	10	0,09787	0,30781	-0,24746	24,22697	0,24057	-0,27700	24,34876
26	PURELIN	TANSIG	10	0,00221	0,04227	-0,00355	2,92791	0,03506	-0,01291	2,99099
27	PURELIN	PURELIN	10	0,00000	0,00041	-0,00001	0,05544	0,00075	-0,00003	0,05656
28	TANSIG	LOGSIG	13	0,08765	0,29103	-0,21556	22,37339	0,20765	-0,09507	22,64909
29	TANSIG	TANSIG	13	0,00176	0,03724	-0,00261	1,53540	0,02170	-0,00699	1,58650
30	TANSIG	PURELIN	13	0,01337	0,11068	-0,02109	2,61770	0,04613	-0,07931	2,68748
31	LOGSIG	LOGSIG	13	0,08718	0,29023	-0,20662	22,10794	0,20313	-0,07451	22,40735
32	LOGSIG	TANSIG	13	0,00157	0,03488	-0,00234	1,62206	0,02194	-0,00647	1,67164
33	LOGSIG	PURELIN	13	0,00350	0,05435	-0,00535	1,88147	0,02930	-0,02086	1,94241
34	PURELIN	LOGSIG	13	0,09159	0,29761	-0,20205	24,21996	0,23964	-0,12660	24,52015
35	PURELIN	TANSIG	13	0,00149	0,03390	-0,00242	2,56215	0,02725	-0,00752	2,61485
36	PURELIN	PURELIN	13	0,00000	0,00027	0,00000	0,00000	0,00000	0,00000	0,00027
37	TANSIG	LOGSIG	15	0,09069	0,29612	-0,25342	24,04799	0,23724	-0,09589	24,32273
38	TANSIG	TANSIG	15	0,00282	0,04830	-0,00441	3,41460	0,04446	-0,01672	3,48905
39	TANSIG	PURELIN	15	0,00062	0,02036	-0,00094	1,32898	0,01309	-0,00334	1,35877
40	LOGSIG	LOGSIG	15	0,08885	0,29306	-0,23529	23,32780	0,22461	-0,08680	23,61223
41	LOGSIG	TANSIG	15	0,01245	0,10665	-0,01773	4,75417	0,06651	-0,04512	4,87693
42	LOGSIG	PURELIN	15	0,00044	0,01657	-0,00067	0,91247	0,00901	-0,00235	0,93547
43	PURELIN	LOGSIG	15	0,09246	0,29904	-0,18833	24,39957	0,24268	-0,07730	24,76812
44	PURELIN	TANSIG	15	0,00973	0,09373	-0,01267	5,76255	0,07611	-0,02154	5,90791
45	PURELIN	PURELIN	15	0,00001	0,00098	-0,00002	0,00254	0,00029	-0,00007	0,00373
46	TANSIG	LOGSIG	16	0,08723	0,29032	-0,21019	22,25533	0,20577	-0,07501	22,55345
47	TANSIG	TANSIG	16	0,04247	0,20109	-0,07418	10,39159	0,12551	-0,22666	10,45982
48	TANSIG	PURELIN	16	0,00023	0,01118	-0,00037	0,41981	0,00548	-0,00128	0,43505
49	LOGSIG	LOGSIG	16	0,08762	0,29098	-0,21620	22,38735	0,20822	-0,08033	22,67764
50	LOGSIG	TANSIG	16	0,01946	0,13453	-0,02834	6,30861	0,07554	-0,07524	6,43456
51	LOGSIG	PURELIN	16	0,05901	0,23791	-0,12011	19,12222	0,19206	-0,09797	19,39312
52	PURELIN	LOGSIG	16	0,08760	0,29095	-0,21006	22,59363	0,21158	-0,08551	22,88819
53	PURELIN	TANSIG	16	0,00147	0,03365	-0,00223	2,46906	0,02936	-0,00827	2,52304
54	PURELIN	PURELIN	16	0,00000	0,00000	0,00000	0,03824	0,00042	0,00000	0,03866

** GKTF (Gizli Katman Transfer Fonksiyonu), ÇKTF (Çıktı Katmanı Transfer Fonksiyonu), GKNS (Gizli Katman Nöron Sayısı)

54 kombinasyonun her biri için ağı; ayrı ayrı eğitilmiş, sonra tüm girdi değerleri için ayrı ayrı test edilmiştir. Elde edilen bu değerler "normalize edilmiş" tahmin değerleridir. Tablo 4 'te yer alan en düşük MSE, RMSE, MAPE, MABE ve en yüksek WIA ve R² değerleri ile aynı tablodaki MSE, RMSE, WIA, MAPE, MABE ve R² değerleri arasındaki sapmaların sütun bazında ve hücre bazında hesaplanması, bu sapmaların satır bazında toplamalarının hesaplanabilmesi için önemlidir. Hesaplanan sapmalar ve bu sapmaların satır bazında toplamaları Tablo 5 'te görülmektedir.

Tablo 5 'teki sapmalara ait toplam değerlerin satır bazında mutlak değerleri düşünüldüğünde 36. sıradaki kombinasyonun en uygun olduğu bulunmuştur. Bu kombinasyonda; eğitim fonksiyonu "TRAINLM" iken, gizli katman nöron sayısı 13, gizli katman transfer fonksiyonu PURELIN, çıktı katmanı transfer fonksiyonu PURELIN şeklindedir. Ayrıca, Tablo 4 'te yer alan 36. sıradaki kombinasyona ait MSE, RMSE, WIA, MAPE, MABE ve R² değerlerinin hesaplanmasında kullanılan tahmin değerlerinin elde edilmesi noktasında ağı eğitilmesiyle ilişkili MATLAB ekran görüntüsü Şekil 3. 'te verilmiştir.



Şekil 3. Seçilen Kombinasyonun Ağ Eğitimine İlişkin MATLAB Ekran Görüntüsü

36. sıradaki kombinasyon ve nöron sayısı atanmış olan ağ; ağ tipi (Feed-forward backprob), adaptasyon öğrenme fonksiyonu (LEARNGDM), performans fonksiyonu (MSE) ve varsayılan eğitim parametreleriyle on defa eğitilmiş, bu eğitimlerin ilk üçünde, birinci eğitim sonucunda bulunan tahmin değerlerine, diğer yedisinde ise dördüncü eğitim sonucunda bulunan tahmin değerlerine ulaşılmıştır. Ağ, 10. eğitiminden sonra girdi değerleri için test edilmiş ve virgülden sonra 15 basamaklı olarak elde edilen tahmin değerlerinin virgülden sonraki ilk sekiz hanesi herhangi bir yuvarlama işlemi yapılmadan Tablo 6 'da "MATLAB Tahmin Sonuçları" sütun başlığı altında verilmiştir. Ayrıca; bu sütun başlığına ait içeriğe ek olarak Normalize Edilmiş Satış Miktarı, Normalize Edilmiş Üretim Değeri, Normalize Edilmiş Üretim Miktarı, Normalize Edilmiş Satış Değeri, Satış Miktarı Tahmini (T), (T-G), Yüzdesele Değişim adlı sütunların içerikleri ve Toplam Yüzdesele Değişim değeri de virgülden sonra 15 basamaklı olarak değerlendirmeye alınmıştır. Sütun başlıklarına ait içeriklerin ve Yüzdesele Değişim Toplamının Yıllık Ortalaması adlı değerlerin virgülden sonraki ilk 8 basamağı Tablo 6 'da yuvarlamadan gösterilmiştir.


Hesaplanan tahmin değerleri, normalize edilmiş değerlerdir. Tahmin değerleri ile gerçekleşen değerleri karşılaştırabilmek için, normalize edilmiş şekilde elde edilmiş olan tahmin değerlerinin normalize edilmemiş haline çevrilmesi gerekmektedir. Bu, bir dizi işlem sonucunda gerçekleştirilir.

Çalışmada, ilk olarak MATLAB'dan elde edilen tahmin sonuçlarının transpozese alınmış ve bahsedilen biçimde "MATLAB Tahmin Sonuçları" adlı sütun içeriği olarak gösterilmiştir. Daha sonra, Satış Miktarı Tahmini (T) adlı sütunun içeriği oluşturulurken Denklem (10) tersten işletilmiştir. Satış Miktarı (Adet) (G) sütunundaki adetler ise yıllara göre gerçekleşmiş satış miktarlarıdır. (T-G) adlı sütun, MATLAB yardımıyla elde edilen tahmin değerlerinden, gerçekleşen değerlerin farklarını göstermektedir. "Yüzdesele Değişim" adlı sütun değerleri ise $(T-G)/G$ oranı ile hesaplanmış, sonra yüzdesele değişim değerleri toplanarak "Toplam Yüzdesele Değişim" değeri bulunmuştur. Son işlem olarak, toplam yüzdesele değişim değerinin aritmetik ortalaması alınarak "Yüzdesele Değişim Toplamının Yıllık Ortalaması" hesaplanmıştır (Bakınız: Tablo 6).


Ayrıca, Tablo 6 'da gösterilmiş olan; "Yıllar", "Satış Miktarı (Adet) (G)" ve "Satış Miktarı Tahmini (T)" sütunlarında yer alan değerler kullanılarak Grafik 1, "Yıllar" ve "Yüzdesele Değişim" değerleri ile Grafik 2 düzenlenmiştir.

Tablo 6. MATLAB Tahmin Değerlerine İlişkin “Yüzdesel Değişim Toplamının Yıllık Ortalaması”

Yıllar	Satış Miktarı (Adet) (G)	Üretim Değeri (TL)	Üretim Miktarı (Adet)	Satış Değeri (TL)	Normalize Edilmiş Satış Miktarı	Normalize Edilmiş Üretim Değeri	Normalize Edilmiş Üretim Miktarı	Normalize Edilmiş Satış Değeri	MATLAB Tahmin Sonuçları	Satış Miktarı Tahmini (T)	(T-G)	Yüzdesel Değişim
2005	357232	267482002	345247	277432128	0,000000000	0,000000000	0,000000000	0,00676599	0,00727769	357766,90128683	534,90128683	0,00149734
2006	417497	322251317	401628	335527652	0,14395216	0,10793015	0,12634624	0,11492986	0,14267963	416964,25743599	-52,74256400	-0,00127603
2007	363046	268894841	355549	273798070	0,01388762	0,00278418	0,02308612	0,00000000	0,01388463	363036,37443900	-9,67566099	-0,00002651
2008	369554	293751835	363202	298764556	0,02943298	0,05176816	0,04023601	0,04648330	0,03035211	369938,78975143	384,78975142	0,00104122
2009	423053	316016483	410920	325543896	0,15722352	0,09564359	0,14716902	0,09634182	0,15684130	422892,98459097	-160,01540902	-0,00037823
2010	532205	381668170	521787	388427304	0,41794977	0,22501889	0,39561493	0,21341991	0,41604105	531405,92230773	-799,07769226	-0,00150144
2011	724439	586397063	721981	584343715	0,87713008	0,62846416	0,85768260	0,57818257	0,88016127	725707,99599654	1268,99599654	0,00175169
2012	775878	678766827	797489	665349500	1,00000000	0,81049096	1,00000000	0,72900141	0,99833533	775781,09461979	-696,90538020	-0,00089821
2013	714716	657010486	708888	661550031	0,85390520	0,76761722	0,81488540	0,72192745	0,84214546	709792,83096864	-4923,16903135	-0,00688828
2014	717323	730971510	724431	728936428	0,86013242	0,91336717	0,84972727	0,84738833	0,85611524	715641,22139521	-1681,77860478	-0,00234452
2015	743910	774933464	723527	810904616	0,92363954	1,00000000	0,84770747	1,00000000	0,94441112	752605,93909120	8695,93909119	0,01168950
Toplam										Yüzdesel Değişim	0,00266651	
Yüzdesel Değişim Toplamının Yıllık Ortalaması										0,00242441		



Grafik 1. Gerçekleşmiş ve Tahmini Satış Miktarları



Grafik 2. Yıllara Göre Yüzdesele Değişim Değerleri

3. Bulgular

Tahminlerin gerçekleşen değerlerden yüzdesel olarak ne kadar saptığını gösteren ortalama sapma miktarı, “Yüzdesel Değişim Toplamının Yıllık Ortalaması” olarak hesaplanmış, 0,000242410314950 bulunmuş ve virgülden sonraki ilk sekiz basamağı yuvarlamadan 0,00024241 şeklinde gösterilmiştir (Tablo 6). Sapma miktarının bu derece küçük çıkması, yapay sinir ağlarıyla gerçeğe çok daha yakın tahminlerin yapılabileceğine işaret etmektedir. Tahmin duyarlılığı belirlenirken, “Yüzdesel Değişim Toplamının Yıllık Ortalaması” genel bir endeks gibi, gösterge olarak kullanılabilir.

“Yüzdesel Değişim Toplamının Yıllık Ortalaması” veri setinin büyüklüğüne, yapısına, varsayılan parametrelerin kullanılıp kullanılmadığına ve eğitim sayısına bağlı olarak değişiklik gösterebilecek bir yapıya sahip olduğu görülmüştür. Tedarik zinciri paydaşları; yıllık satış miktarı hedeflerini, hesapladıkları tahmin sonuçlarıyla karşılaştırma imkânı bulabileceklerdir.

4. Tedarik Zinciri Yönetiminde Yüzdesel Değişim Toplamlarına Ait Ortalamaların Önemi

“Yüzdesel Değişim Toplamının Yıllık Ortalaması”; “Üretim Miktarı”, “Üretim Değeri” ve “Satış Değeri” değişkenlerinden etkilenen “Satış Miktarı” değişken değerlerinin ne düzeyde tahmin edilebildiğinin bir göstergesidir. Burada, tedarik zincirinin genel manadaki tedarikçi, üretici, toptancı, perakendeci, müşteri ve servis sağlayıcı biçimindeki paydaşları düşünüldüğünde; bu paydaşlardan ikisi olan üretici ve müşteri arasında mamul noktasında aşamalı bir ilişkinin var olduğu ve bu ilişki noktasında gerçekleşen satış işlemlerinin tedarikçi dâhil tüm tedarik zinciri paydaşlarını etkilediği ifade edilebilmektedir.

Tedarikçi tarafından belirlenmiş yıllık satış hedefleri ile MATLAB kullanılarak tahmin edilmiş yıllık satış miktarlarının uyumluluk derecesi, tedarikçilerin tedarikçilerine verilecek olan sipariş miktarlarını etkileyecektir. Müşterinin tedarikçisi olan perakendecinin, perakendecinin tedarikçisi olan toptancının, toptancının tedarikçisi olan üreticinin ayrı ayrı belirlenmiş oldukları yıllık satış hedefleri ile paydaşlar bazında tahmin edilmiş yıllık satış miktarlarının uyumluluk dereceleri de benzer biçimde sipariş miktarlarını etkileyecektir. Diğer bir ifadeyle; perakendeci ve müşteri, toptancı ve perakendeci, üretici ve toptancı arasında sırasıyla müşterinin perakendeciye vereceği, perakendecinin toptancıya vereceği, toptancının üreticiye vereceği sipariş miktarları uyumluluk derecelerinden etkilenecektir.

Bahsedilen uyumluluk derecelerinin belirlenebilmesi için yıllık bazdaki satış miktarlarının tahmin edilmiş olması gerekmektedir. Satış miktarlarının tahmin edilmesi ile; tedarik zinciri bünyesindeki ilgili paydaşlar satış miktarı hedeflerini, tahmin sonuçlarıyla yıllık bazda kıyaslayabileceklerdir. Yöneticiler, bu noktada oluşan mesleki tecrübe ışığında ve ilerleyen yıllar için sayısal sonuçlar doğrultusunda daha doğru ve sağlıklı tahminlerde bulunabileceklerdir.

Ayrıca, firma yöneticileri tahmin değerleri dışında gerçekleştirmiş oldukları satış hedefleri için de “Yüzdesel Değişim Toplamının Yıllık Ortalaması” ’nı hesaplayabilecek ve bu ortalamayı tahmin değerleri için hesaplanmış olan ortalama ile kıyaslamak suretiyle mesleki gelişim sağlayabileceklerdir. Dolayısıyla; tedarik zincirindeki yöneticiler için anılan ve artan mesleki tecrübe zamanla tedarik zinciri içerisinde yer alan paydaşlar arasındaki süreçlerin daha sağlıklı bir şekilde işlemesine ve yöneticilerin daha doğru tahminler ile gerçeğe daha yakın yaklaşımlar içerisinde bulunmalarına neden olacaktır. Bu faydalar neticesinde; tedarik zinciri içerisindeki üretim eskiye göre daha sağlıklı planlanabilecek, tüm tedarik zinciri boyunca stoklama ve depolama maliyetlerinin düşürülebilmesi durumu oluşacaktır. Stoklama ve depolama maliyetlerinin tüm tedarik zinciri boyunca düşmesi ile birlikte; lojistik konusu daha dinamik hale gelecek ve oluşan dinamizm tedarik zincirinin gelişimine katkı sağlayacaktır. Yöneticilerin; bu katkının, lojistik konusunda gerçekleştirilecek operasyonel işlemlerin artması ile birlikte tedarik zincirinde oluşabilecek problemlerin ve bu problemlere ait çözümlerin bir potada eritilmesi neticesinde gün yüzüne çıkabilecek nitelikte olduğunun bilincinde olmaları önem taşımaktadır.

Netice itibarıyla, literatüre yeni bir katkı sunmayı amaçlayan “Yüzdesel Değişim Toplamının Yıllık Ortalaması” adlı gösterge değeri, duyarlılık karşılaştırmalarında kullanılabilir nitelikte olan bir endekstir. Bu endeks sayesinde tedarik zincirinin optimizasyonu söz konusu olmaktadır. Bu durum ise, tedarik zinciri yöneticilerinin gereksiz problemlerle ilgilenmeleri yerine yönetime ilişkin gerekli konulara odaklanması için optimizasyon ile oluşan zaman tasarrufunu kullanabilmeleri anlamına gelmektedir.

Sonuç ve Değerlendirme

MATLAB programı ile elde edilmiş olan tahmin değerleri, gerçekleşen değerlerden küçük olarak nitelendirilebilecek farklılığa sahiptir. 2005, 2008, 2011 ve 2015 yılları için tahmin değerleri; gerçekleşen değerlerden daha fazla çıkmış, 2006, 2007, 2009, 2010, 2012, 2013 ve 2014 yılları için tahmin değerleri ise gerçekleşen değerlerden daha az çıkmıştır. Bunun, MATLAB’ın varsayılan parametrelerinin kullanılmasının ve eğitim sayısının 10 olarak alınmasının bir sonucu olduğu söylenebilir. Ağın daha fazla eğitilmesi ve varsayılan eğitim parametrelerinin değiştirilmesi durumunda duyarlılığı artırmak mümkün olabilir.

Tablo 6'da görüldüğü gibi; 0,000242410314950 olarak bulunmuş olan yüzdesel değişim toplamının yıllık ortalaması yuvarlamadan virgülden sonraki ilk sekiz basamağı ile (0,00024241) gösterilmiştir. Bu, tahminlerin gerçekleşen değerlerden yüzdesel olarak ne kadar saptığını gösteren ortalama sapma miktarıdır. Başka bir deyişle; hesaplanan tahmin değerleri yıllık olarak 0,0002 gibi çok küçük bir sapma göstermektedir. Sapma miktarının bu derece küçük çıkması, MATLAB yardımıyla gerçeğe çok yakın tahminlerin yapılabildiğini gösteren önemli bir bulgudur.

Yıllık istatistik veriler, birbirinden farklı sektörlerde faaliyet gösteren birçok firmada önemli bir değerlendirme aracı olarak kullanılmaktadır. Çalışma konusu yöntem, bu yıllık verileri daha kullanışlı hale getirmektedir. Bu şekilde, yüzdesel değişim toplamlarının yıllık ortalamasının hesaplanarak tahmin duyarlılığının genel bir gösterge olarak belirlenmesi mümkün olabilecektir. MATLAB programının bu noktada değerlendirme aracı olarak kullanılmasının sağlayacağı faydanın rekabetin yoğun olduğu pazar koşullarında yöneticiler açısından önemli olacağı ve bu fayda ile geleceğe yönelik tahminlerin daha küçük sapmalarla yapılabileceği açık olup, bu düzlemde çalışma konusu yöntemin farklı alanlarda da ayrı ayrı kullanılması önerilmektedir.

Çıkar Çatışması Bildirimi

Yazarlar arasında herhangi bir çıkar çatışması yoktur. Bununla birlikte, çalışmanın sonuçlarını ya da çalışmaya ilişkin yorumları etkileyecek herhangi bir çıkar çatışması da yoktur.

Kaynakça

- Adewole, B. Z., Abidakun, O. A. ve Asere, A. A. (2013). Artificial neural network prediction of exhaust emissions and flame temperature in LPG (liquefied petroleum gas) fueled low swirl burner. *Energy*, Vol. 61, 606-611.
- Agatonovic-Kustrin, S. ve Beresford, R. (2000). Basic concepts of Artificial Neural Network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*, 22(5), 717-727.
- Al-Chalabi, H., Ahmadzadeh, F., Lundberg, J. ve Ghodrati, B. (2014). Economic lifetime prediction of a mining drilling machine using an Artificial Neural Network. *International Journal of Mining, Reclamation and Environment*, 28(5), 311-322.
- Balkin, S. D. ve Lin, D. K. J. (2000). A neural network approach to response surface methodology. *Communications in Statistics - Theory and Methods*, 29(9ve10), 2215-2227.
- Balls, G. R., Palmer-Brown, D. ve Sanders, G. E. (1996). Investigating microclimatic influences on ozone injury in clover (*trifolium subterraneum*) using Artificial Neural Networks. *New Phytologist*, 132(2), 271-280.
- Barclay, C. J., Campbell, S. W., Galloway, A. M. ve McPherson, N. A. (2013). Artificial neural network prediction of weld distortion rectification using a travelling induction coil. *The International Journal of Advanced Manufacturing Technology*, 68(1-4), 127-140.
- Basheer, I. A. ve Hajmeer, M. (2000). Artificial Neural Networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3-31.
- Choudhry, T., McGroarty, F., Peng, K. ve Wang, S. (2012). High-frequency exchange-rate prediction with an Artificial Neural Network. *International Journal of Intelligent Systems in Accounting and Finance Management*, 19(3), 170-178.
- Devi, S. R., Arulmozhivarman, P., Venkatesh, C. ve Agarwal, P. (2016). Performance comparison of Artificial Neural Network models for daily rainfall prediction. *International Journal of Automation and Computing*, 13(5), 417-427.
- Ebrahimabadi, A., Azimipour, M. ve Bahreini, A. (2015). Prediction of roadheaders' performance using Artificial Neural Network approaches (MLP and KOSFM). *Journal of Rock Mechanics and Geotechnical Engineering*, 7(5), 573-583.
- Fox, D. G. (1981). Judging air quality model performance: a summary of the AMS workshop on dispersion model performance, woods hole, mass., 8-11 september 1980. *Bulletin of the American Meteorological Society*, 62(5), 599-609.
- Hasegawa, K., Deushi, T., Yaegashi, O., Miyashita, Y. ve Sasaki, S. (1995). Artificial Neural Network studies in quantitative structure-activity relationships of antifungal azoxy compounds. *European Journal of Medicinal Chemistry*, 30(7-8), 569-574.

- Jiang J., Zhang J., Yang G., Zhang D. ve Zhang L. (2010). Application of back propagation neural network in the classification of high resolution remote sensing image: take remote sensing image of Beijing for instance. *2010 18th International Conference on Geoinformatics*, Beijing, China, 1-6.
- Khan, M. A., Khan, S., Shams, B. ve Lloret, J. (2016). Distributed flood attack detection mechanism using Artificial Neural Network in wireless mesh networks. *Security and Communication Networks*, 9(15), 2715-2729.
- Kuo, H.-J., Chiu, H.-W., Lee, C.-N., Chen, T.-T., Chang, C.-C. ve Bien, M.-Y. (2015). Improvement in the prediction of ventilator weaning outcomes by an Artificial Neural Network in a medical ICU. *Respiratory Care*, 60(11), 1560-1569.
- Moghaddam, A. H., Moghaddam, M. H. ve Esfandyari, M. (2016). Stock market index prediction using Artificial Neural Network. *Journal of Economics, Finance and Administrative Science*, 21(41), 89-93.
- Mohammadi, K., Shamshirband, S., Motamedi, S., Petković, D., Hashim, R. ve Gocic, M. (2015). Extreme learning machine based prediction of daily dew point temperature. *Computers and Electronics in Agriculture*, Vol. 117, 214-225.
- Monazami, M., Hashemi, A. ve Shahbazian, M. (2012). Drilling rate of penetration prediction using Artificial Neural Network: a case study of one of Iranian southern oil fields. *Oil and Gas Business*, No 6, 21-31.
- Özşahin, Ş. (2013). Optimization of process parameters in oriented strand board manufacturing with Artificial Neural Network analysis. *European Journal of Wood and Wood Products*, 71(6), 769-777.
- Przednowek, K., Iskra, J., Wiktorowicz, K., Krzeszowski, T. ve Maszczyk, A. (2017). Planning training loads for the 400 m hurdles in three-month mesocycles using Artificial Neural Networks. *Journal of Human Kinetics*, 60(1), 175-189.
- Quej, V. H., Almorox, J., Ibrakhimov, M. ve Saito, L. (2016). Empirical models for estimating daily global solar radiation in Yucatán Peninsula, Mexico. *Energy Conversion and Management*, Vol. 110, 448-456.
- Shen, F., Chao, J. ve Zhao, J. (2015). Forecasting exchange rate using deep belief networks and conjugate gradient method. *Neurocomputing*, Vol. 167, 243-253.
- Sietsma J. ve Dow, R. J. F. (1991). Creating Artificial Neural Networks that generalize. *Neural Networks*, 4(1), 67-79.
- Silveira, C. L., Belledeli, B. D., Soares, M. B. A., Treichel, H. ve Mazutti, M. A. (2014). Use of Artificial Neural Network for industrial prediction of final temperature of chicken carcasses. *Journal of Food Process Engineering*, 37(1), 1-9.
- Simonović M. B., Nikolić V. D., Petrović E. P. ve Ćirić I. T. (2016). Heat load prediction of small district heating system using Artificial Neural Networks. *Thermal Science*, 20(Suppl. 5), 1355-1365.
- TÜİK, (2018). TÜİK İstatistik Veri Portalı. Erişim Tarihi: 25 Temmuz 2018, <https://data.tuik.gov.tr/Kategori/GetKategori?p=sanayi-114&dil=1>
- Willmott, C. J. (1981). On the validation of models. *Physical Geography*, 2(2), 184-194.
- Willmott, C. J., Robeson, S. M. ve Matsuura, K. (2012). A refined index of model performance. *International Journal of Climatology*, 32(13), 2088-2094.
- Willmott, C. J. ve Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82.
- Willmott, C. J. ve Wicks, D. E. (1980). An empirical method for the spatial interpolation of monthly precipitation within California. *Physical Geography*, 1(1), 59-73.
- Yitian, L., ve Gu, R. R. (2003). Modeling flow and sediment transport in a river system using an Artificial Neural Network. *Environmental Management*, 31(1), 122-134.

Extended Abstract

Aim and Scope

In the study, forecast of the sales amounts of "Vented Combi" was made using the Artificial Neural Network method. By comparing the predicted results with the realized results; A new index have called "Annual Average of Percental Change Total", which is not available in the literature, has been created. This index has a structure that can be easily used not only for forecasting the sales of combi, but also for similar studies. Variables named "Production Amount", "Production Value", "Sales Amount", "Sales Value" related to the product in TÜİK Annual Production and Sales Statistics of Industrial Products (2005-2015 period) were used as data set to calculate the index.

Methods

The Artificial Neural Network have considered as an intermediate operation in the prediction to be made. In the neural network created using the MATLAB program, the Feed-forward Backprop network type was preferred. This has the characteristic of being a type of network that is often used when forecasting. Multiple Linear Regression Analysis was not preferred for prediction because it does not have the learning feature of the Artificial Neural Network and there are many constraints to be met. For the forecast, variables named "Production Value", "Sales Value" and "Production Amount" were used as input variables. In the MATLAB program, the sales amounts were forecasted separately for eleven years with the Artificial Neural Network, and a new index was obtained by comparing these results with the realized results. The forecast sensitivities of different data sets will can be calculated with calculating this index named "Annual Average of Percental Change Total", which can be expressed as a new method. It was thought that a contribution to the literature can be made by generalizing the R^2 formula in Equation (8) that Quej et al. (2016: 452) used in their studies as Equation (9).

Findings

In the study, the index value named "Annual Average of Percental Change Total", which is the average deviation amount showing how much the predictions deviate as a percental from the realized values, have calculated as 0.000242410314950. In different data sets, this index value will be able to vary depending on the size and structure of the data set, whether MATLAB's default parameters are used, and how many training numbers are considered. In addition, together with the forecast values for the years 2005, 2008, 2011 and 2015 have been output higher than realized values the forecast values for the years 2006, 2007, 2009, 2010, 2012, 2013 and 2014 have been output less than the realized values. It can be stated that the difference here is related to how many training numbers are considered which is found within the cases that are effective in the variability of the relevant index value and whether the default parameters of MATLAB are used situations. The generalisable structure of the new index and the mentioned variabilities will be more useful from the point of supply chain stakeholders who frequently use data analysis and forecasting methods.

Conclusion

The annual average of the calculated percental change sum is 0.000242410314950 (In Table 6, the first eight digits of this value after the decimal point are stated without rounding.), the average deviation amount showing how much the forecasts deviate from the realized values. In other words; forecast values can be calculated with a very small deviation of 0.0002 per year. The fact that the deviation amount is so small will give the opportunity to minimize the amount of error in the forecasts. This shows that the forecast results made with the Artificial Neural Network are closer to the truth and will can give more realistic forecast results compared to other forecasting methods. The developed index calculation method makes the annual data in the study more useful and It can give supply chain stakeholders the opportunity to be more accurate in forecasting. In addition, forecast sensitivities related different data sets can be calculated with the help of the index we call "Annual Average of Percental Change Total". The R^2 formula in Equation (8) has generalized as Equation (9) and this operation was thought to contribute to the existing literature.