

## **GÜL ÇİÇEĞİ DİKİM ALANLARININ YAPAY SİNİR AĞLARI YÖNTEMİYLE TAHMİNİ**

**Yrd. Doç. Dr. Meltem KARAATLI**

Süleyman Demirel Üniversitesi, İİBF, İşletme Bölümü

**Doç. Dr. Mesut ALBENİ**

Süleyman Demirel Üniversitesi, İİBF, İktisat Bölümü

### **ÖZET**

*Bu çalışmanın amacı gül çiçeği dikim alanlarının yapay sinir ağları yöntemiyle önceden tahmin edilerek gülcülük sektörü ile ilgili tarımsal politikaların belirlenmesine katkı sağlamaktır. Bu çalışmada gül çiçeği dikim alanlarını etkileyen değişkenler; gül çiçeği reel fiyatları, gül çiçeği dikim alanı, meyve veren elma ağacı sayısı, elma reel fiyatları (TL/kg), üzüm reel fiyatları (TL/kg), sabit kukla, eğim kukla ve zaman değişkenleri olarak belirlenmiştir. Çalışmada 1980-2010 yıllarına ait veriler kullanılmıştır. Araştırma yalnızca Isparta ilini kapsamaktadır. Çalışmanın sonucunda 2011 ve 2012 yılına ait Isparta ili gül dikim alanları tahmin edilmiştir.*

**Anahtar Kelimeler:** *Yapay Sinir Ağları, Tahmin, Gül çiçeği*

## **FORECASTING ROSE FLOWER PLANTING AREAS USING ARTIFICIAL NEURAL NETWORKS**

### **ABSTRACT**

*The aim of this study is to forecast the planting areas of rose flower in order to guide the policies of rose sector. The variables used in this study are real prices of rose flower, planting areas of rose flower, the number of apple trees, real apple prices, real grape prices, fixed and slope dummy and time. Study covers the years between 1980 to 2010. Study has performed for the city of Isparta.*

**Keywords:** *Artificial Neural Networks, Forecasting, Rose Flower*

## 1. GİRİŞ

Gül, gülgiller (Rosaceae) familyasının Rosa cinsindedir. Fosil kaynaklı kayıtlara göre, gülün yeryüzündeki varlığı en az 35 milyon yıllık bir geçmişe sahiptir. Gül çiçeğinin insanlık tarihindeki yeri ve önemi ise en az 5000 yıllık bir geçmişe dayanır. Bu zaman içinde gül; aşk, güzellik, savaş, barış ve siyaset alanlarında sembol olarak kullanılmıştır (Gülbirlik, 2011).

Yağ gülünün Türkiye'ye nasıl ve nereden geldiği ve gül tarımının ne zaman başladığı hakkında kesin bilgiler olmamasına rağmen bilimsel adından (Rosa Damascena) menşinin Şam olduğu varsayılmaktadır. Şam'ın ve Bulgaristan'ın Osmanlı İmparatorluğu'nun birer vilayeti olduğu sıralarda yetiştiriciler tarafından Şam'dan alınarak Bulgaristan'ın elverişli ekolojik şartlara haiz Kızanlık Bölgesi'ne götürülüp yetiştirildiği tahmin edilmektedir. Gül, Isparta'ya 1888 yılında Müftüzade İsmail Efendi tarafından Bulgaristan'ın Kızanlık yöresinden getirilmiş ve ilk olarak Gülcü Mahallesine dikilerek yetiştirmeye başlanmıştır. Yağ gülü tarımı Isparta ve çevre halkı tarafından benimsenerek kısa zamanda büyük gelişme göstermiştir. 1912 yılında Ticaret ve Ziraat Nezareti'nin gülcülük hakkındaki kitabı, yörede gül tarımının gelişmesine de büyük katkı sağlamıştır. O tarihlerde 6915 dönüm gül bahçesi tesis edildiği resmi kayıtlarda görülmektedir. 1953 yılında Isparta'da Gülbirlik'in kurulması, 1954 yılında İslamköy, 1976 yılında Yakaören, Kılıç, Güneykent ince gül yağı fabrikaları ile Aliköy konkret fabrikasının ilde üretilen tüm gül çiçeğini modern teknolojiye uygun olarak işletmeye başlaması sonunda gül yağları dünya piyasalarına pazarlanmaya başlanmış, neticede dikim alanları hızlı bir gelişme göstermiştir (Gülbirlik, 2011). Günümüzde Isparta ilinde, Gülbirlik dışında gülyağı üretimi ile uğraşan farklı ölçeklerde on civarında firma da bulunmaktadır.

Dünyanın en önemli yağ gülü üreticileri sırasıyla Türkiye ve Bulgaristan'dır. Türkiye'de %62,4 ile en fazla üretim yapan il olan Isparta'yı Afyon, Denizli ve Burdur izlemektedir (Tosun vd.,2011).

**Tablo 1: Gül Çiçeğinin Türkiye ve Bulgaristan'daki Üretim Miktarları (2003-2010)**

Yıllar	Türkiye	Bulgaristan
2003	6.000 ton	5.000 ton (yaklaşık)
2004	6.000 ton	5.000 ton (yaklaşık)
2005	6.500 ton	5.500 ton (yaklaşık)
2006	7.500 ton	6.000 ton (yaklaşık)
2007	6.500 ton	5.000 ton (yaklaşık)
2008	8.400 ton	6.000 ton (yaklaşık)
2009	6.500 ton	5.500 ton (yaklaşık)
2010	5.500 ton	5.000 ton (yaklaşık)

**Kaynak: GÜLBİRLİK,2011**

Türkiye ve Bulgaristan'da yağ gülü üretimi, karşılaştırmalı olarak Tablo 1'de verilmiştir. Tabloda dikkati çeken husus, Bulgaristan'da üretim miktarının yıllar itibariyle (2003-2010) daha istikrarlı bir seyir izlemesine rağmen, Türkiye'de aynı dönemde dalgalı bir seyir izlemesidir. Bunun temel nedeni,

Tablo 2’de görüldüğü gibi ekili alan miktarında yıllar itibariyle görülen değişimlerdir.

**Tablo 2: Son 8 Yıllık Üretim ve Dikim Alanları**

Yıllar	Üretim/Ton	Ekili Alan	Verim/Kg/Hektar
2003	6.000 ton	1200 ha	5000 Kg/ha
2004	6.000 ton	1200 ha	5000 Kg/ha
2005	6.500 ton	1300 ha	5000 Kg/ha
2006	7.500 ton	1500 ha	5000 Kg/ha
2007	6.500 ton	1500 ha	4300 Kg/ha
2008	8.400 ton	1700 ha	5500 Kg/ha
2009	6.500 ton	1700 ha	5000 Kg/ha
2010	5.500 ton	1600 ha	4000 Kg/ha

**Kaynak: GÜLBİRLİK, 2011**

Her sektörde olduğu gibi tarım sektöründe de güvenilir verilerin elde edilerek doğru tahminlerin elde edilmesi ileriki yıllarda geliştirilecek tarım politikaları için büyük önem arz etmektedir. Gül çiçeği reel fiyatlarındaki dalgalanmalar gül çiçeği dikim alanlarının, dolayısıyla gül çiçeği - gül yağı arzının dalgalanmasına neden olmaktadır. Bu nedenle gül çiçeği reel fiyatları, üretimde istikrarı sağlayacak şekilde tespit edilmelidir. Ayrıca gül çiçeği dikim alanlarının tavan ve taban fiyatları, dikim alanları izinleri gibi politikalar yardımıyla plansız gelişmelerin önüne geçilebilir.

Gül çiçeği üretiminin farklı boyutlarını ele alan (üretim-pazarlama-teknik boyut vb.) çok sayıda farklı çalışmalar olmakla birlikte gül dikim alanlarının yapay sınır ağları yöntemi ile tahminine ilişkin literatürde herhangi bir çalışmaya rastlanmamıştır.

## **2. YAPAY SİNİR AĞLARI YÖNTEMİ İLE GÜL ÇİÇEĞİ DİKİM ALANLARININ TAHMİN EDİLMESİ**

Bu çalışmada yapay sinir ağları yöntemi ile Isparta ilinde gül çiçeği dikim alanları tahmin edilmeye çalışılmıştır. Analizlerde TÜİK ve Gülbirlik’ten alınan 1980-2010 yılları arasındaki yıllık veriler kullanılmıştır. 1980 yılı öncesine ilişkin güvenilir verilere ulaşılamadığı için analizlere dahil edilmemiştir. Çalışmada kullanılan değişkenler ve yapay sinir ağları yöntemi ile ilgili genel bilgiler ilerleyen bölümlerde detaylı olarak açıklanmıştır.

Çalışmada bağımlı değişken olarak belirlenen gül çiçeği dikim alanlarını etkilediği düşünülen bağımsız değişkenler Albeni’nin de (Albeni, 1996:64- çalışmasında kullandığı şekilde; ağırlıklı iki yıl gecikmeli gül çiçeği reel fiyatları, bir yıl gecikmeli gül çiçeği dikim alanı, meyve veren elma ağacı sayısı, bir yıl gecikmeli elma reel fiyatları (TL/kg), bir yıl gecikmeli üzüm reel fiyatları (TL/kg), zaman, sabit kukla, olarak belirlenmiştir. Albeni, çalışmasında 1995 yılı öncesi aynı verileri kullanarak regresyon analizleri yardımıyla 1996 ve 1997 yılları gül çiçeği dikim alanlarının tahminini yapmıştır.

Gül çiçeđi dikim alanlarını en fazla etkilediđi düşünölen deđişken, gül çiçeđi fiyatı/kg'dir. Gül çiçeđinin fiyatı genellikle Gülbirlik tarafından belirlenmekte ve özel sektör de bu fiyata göre üreticilere ödemede bulunmaktadır. Enflasyonist ortamda gül çiçeđinin nominal fiyatlarındaki artışlar üreticiler için aldatici olduğundan dolayı üreticiler, önceki dönemlerde gerçekleşen gül çiçeđi fiyatlarını üretim planlarını belirlemede kullanırken, fiyatlar genel düzeyindeki hareketleri de dikkate aldıklarından araştırmada gül çiçeđi reel fiyatları kullanılmıştır.

Gül çiçeđi reel fiyatları hesaplanırken TÜİK'ten alınmış Tarım Sektörü Gayri-Safi Milli Hasıla Deflatörlerinden yararlanılmıştır. 1987 yılı baz yıl olarak kabul edilmiştir. Gülçiçeđi reel fiyatlarının hesaplanmasında aşağıdaki formöl (1) kullanılmıştır.

$$\text{Gülçiçeđi Reel Fiyatı / kg} = \frac{\text{Gülçiçeđi Nominal fiyatı / kg}}{\text{Tarım Sektörü GSMH Deflatörü}} * 100 \quad (1)$$

Tarım sektöründe üreticiler, stoklama imkanı olmayan/bir sonraki yıl piyasaya sürölemeyen tarımsal ürünler için üretim planlarını belirlerken, genellikle bir yıl önce piyasada gerçekleşen fiyatlarını dikkate alırlar. Gül çiçeđi üretiminde ise konunun uzmanları, gül çiçeđinin ağaççık formundaki yapısı ve dikiminden ötürü en az iki yıl sonra ürün vermeye başlayacağı için, bu sürenin bir yıldan fazla olduğunu vurgulamışlardır. Gül çiçeđinin söküml kararı kolaylıkla verilememektedir. Bu yüzden gül çiçeđi reel fiyatlarının modellerde kullanılabilmesi için birkaç yılın fiyatlarını temsil edebilecek fiyatlar "Hareketli Ortalamalar Yöntemi" kullanılarak hesaplanmıştır. Örnek olarak aşağıdaki formöl (2) verilebilir.

$$F_{2000} = \frac{F_{1998} + F_{1999}}{2} \quad (2)$$

Araştırmada ikinci bağımsız deđişken olarak gül çiçeđi dikim alanlarının gecikmeli deđerleri kullanılmıştır. Çünkü üreticiler, üretim kararlarını belirlemede bir önceki yıl gül çiçeđi üretimi yaptıkları arazi miktarını da dikkate almaktadır.

Çalışmada kullanılan üçüncü bağımsız deđişken ise Isparta il sınırları içinde yıllık ürün veren elma ağacı sayısıdır. Çünkü gül çiçeđi ürünü ve elma, Isparta ilinde birer ikame ürün niteliğindedir.

Çalışmada kullanılan dördüncü deđişken ise zaman deđişkenidir. Zamana bađlı olarak gül çiçeđi dikim alanlarının ne yönde ve ne kadar deđişeceđi belirlenmeye çalışılmıştır.

Araştırmada gül çiçeđi üretiminin yapıldığı arazilerde üretimi yapılabilecek alternatif tarımsal ürünlerin reel fiyatları da bağımsız deđişken olarak düşünölmüştür. Isparta ilinde gül çiçeđi üretimi ile birlikte en çok üretilen iki tarımsal ürün, elma ve üzümdür. Bu nedenle elma ve üzüm reel fiyatlarının da bir yıl gecikmeli reel deđerleri açıklayıcı deđişken olarak araştırmaya dahil edilmiştir. Reel deđerlerin hesaplanmasında, gül çiçeđi reel fiyatlarında olduğu gibi, tarım sektörü GSMH deflatörleri kullanılmıştır.

Etkisi tümüyle ölçülemeyen değişkenleri temsil etmesi için sabit kukla değişkeni kullanılmıştır. Gül çiçeği reel fiyatlarının düştüğü yıllar için kukla değişken değeri (0), yükseldiği dönemler için ise (1) değeri alınmıştır. Ayrıca gül çiçeği reel fiyatları birden fazla faktör tarafından etkilenmektedir. Ekonomik göstergelerde iyileşmeler olduğu dönemlerde (enflasyonun düşme trendine girdiği, sektörel gelirlerin arttığı) bazı değişkenler tarafından temsil edilemeyen etkiler bulunmaktadır. Bu nedenle sabit kukla değişken değerleri (D2) ağırlıklı iki yıl gecikmeli gül çiçeği reel fiyatları (F2) ile çarpılarak yeni bir değişken ( $D2F2=D2 \cdot F2$ ) elde edilmiştir. Dolayısıyla sabit kukla değişkeni olan D2, denklemin yalnızca sabit terimini değiştirirken, yeni elde edilen değişken ( $D2F2$ );  $D=1$  olduğu dönemler için bağımsız değişkenin diğer katsayılarını da etkilemektedir.

Analizlerde kullanılan değişkenler, sembolleri ile birlikte aşağıdaki şekilde gösterilmiştir:

- Y = Gül çiçeği dikim alanı (Da)
- F2 = Ağırlıklı iki yıl gecikmeli gül çiçeği reel fiyatları
- Y1 = Bir yıl gecikmeli gül çiçeği dikim alanları
- EA = Meyve veren elma ağacı sayısı
- Z = Zaman değişkeni
- EF = Bir yıl gecikmeli elma reel fiyatları (TL/kg)
- ÜF = Bir yıl gecikmeli üzüm reel fiyatları (TL/kg)
- D2 = Sabit kukla değişkeni
- D2F2 = Eğim kukla değişkeni

**Tablo 3 : Analizlerde Kullanılan Veriler**

YILLAR	Y	F2	Y1	EA	ÜF	D2	D2F2
1980	20120	209	20000	1301970	165,8042976	0	0
1981	20250	157,2	20120	1372000	151,1615222	0	0
1982	20150	300,9594801	20250	1521295	132,277912	1	300,9594801
1983	20850	315,008269	20150	1613811	168,0314088	1	315,008269
1984	24130	342,1020481	20850	1680192	119,8810129	1	342,1020481
1985	25260	400,9605542	24130	1729000	132,3052496	1	400,9605542
1986	33600	628,5959566	25260	1836200	138,4199192	1	628,5959566
1987	43990	1082,02643	33600	2120130	168,2281238	1	1082,02643
1988	45578	1164,933296	43990	2153150	137,25	1	1164,933296
1989	65757	821,8525169	45578	2295250	179,9155569	0	0
1990	65000	524,259174	65757	2271850	107,9795514	0	0
1991	56750	357,1930664	65000	2211740	113,7680108	0	0
1992	47000	282,7364656	56750	2238640	218,2462389	0	0
1993	26700	235,2664193	47000	2301420	162,0924233	0	0
1994	26376	194,8918456	26700	2359350	122,771359	0	0
1995	11260	267,6027999	26376	2397210	208,3276115	1	267,6027999
1996	10580	426,3989631	11260	2362850	212,8741156	1	426,3989631
1997	18640	504,2042661	10580	2476286	77,33443892	1	504,2042661
1998	17720	472,6117292	18640	2562180	87,94130614	0	0
1999	18310	352,3421704	17720	2584172	86,57819716	0	0
2000	15870	299,6690968	18310	2624830	120,3578954	0	0
2001	15910	321,354175	15870	2673810	125,7562995	1	321,354175
2002	15635	471,2866924	15910	2673810	170,2718348	1	471,2866924
2003	15835	659,6441592	15635	2895167	148,2492364	1	659,6441592

2004	15905	716,7046984	15835	2914283	184,4050759	1	716,7046984
2005	18935	715,0970456	15905	3094177	187,1627006	0	0
2006	19025	699,7944975	18935	2993775	215,3825476	0	0
2007	19057	559,386962	19025	3293210	275,2573138	0	0
2008	18550	436,4819285	19057	3655930	254,7502995	0	0
2009	18550	481,3001654	18550	3997815	273,9765287	1	481,3001654
2010	18598	478,1175774	18550	3997815	293,1752372	0	0

**Kaynak: TUİK ve GÜLBİRLİK**

### 3. YAPAY SİNİR AĞLARI YÖNTEMİ

Yapay sinir ağları, insan beyninin temel özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi farklı türdeki yetenekleri herhangi bir yardım almaksızın otomatik olarak gerçekleştirebilme amacıyla geliştirilen bilgisayar sistemleridir (Öztemel, 2003:29).

Yapay sinir ağları, canlı organizmalarda bulunan biyolojik sinir yapısından ilham alınarak yapılmıştır. Yapay sinir ağları, biyolojik öğrenmeyi esas alan sinir sistemine benzer bir yapıya sahiptir (Nabiyev, 2005:599).

Yapay sinir ağları yardımıyla sınıflandırma, örüntü tanıma, filtreleme, tahmin yapma, optimizasyon gibi çok çeşitli sorunlara çözümler bulunabilmektedir. Her problemin çözümüne dönük farklı ağ yapıları kullanılabilir. Adaline, Madaline, Çok Katmanlı Ağ (MLP), Doğrusal vektör parçalama modeli (LVQ), Adaptif Rezonans Teori (ART) gibi birçok ağ modeli buna örnek olarak verilebilir. Hangi problem tipine hangi ağın daha uygun olduğu karar verici tarafından belirlenir. Bu çalışmada ise Çok Katmanlı Ağ yapısı tercih edilmiştir.

Rumelhart ve arkadaşları tarafından geliştirilen Çok Katmanlı Ağlar, girdi ve çıktılar arasındaki ilişkilerin doğrusal olmadığı ortamlarda kullanılan yapay sinir ağı modelidir. Günlük olayların çoğu doğrusal olmayan bir nitelik taşımaktadır. Bu modele Hata Yayma Modeli veya Geri Yayılım Modeli (Backpropagation Network) de denilmektedir. Bu ağ çeşidi sınıflandırma, tahmin etme, tanıma, yorumlama ve teşhis etme gibi problemlerde başarılı bir şekilde kullanılmaktadır (Öztemel, 2003:76-105).

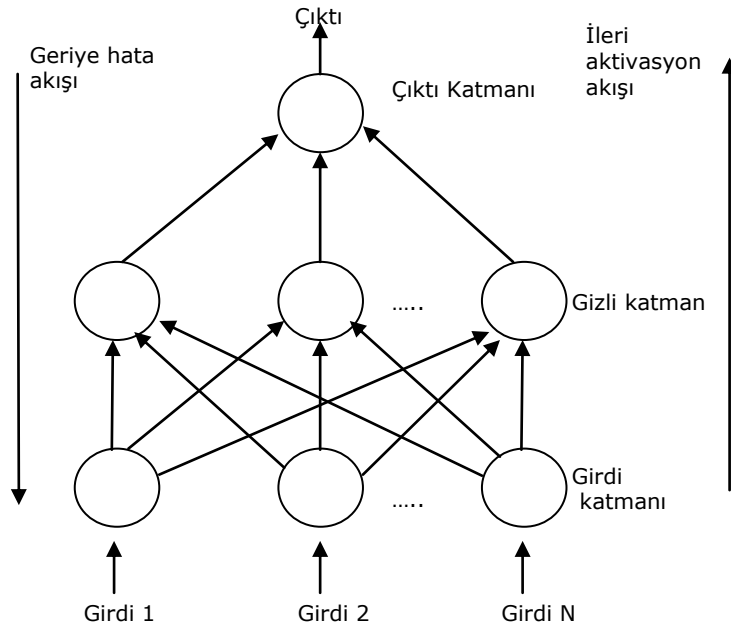
Çok katmanlı bir ağda nöronlar arası bağlantılar ve transfer fonksiyonu ile katman sayısı çok önemlidir. Her katmandaki nöronlar ve katman sayısı problemin karmaşıklığına ve tipine göre farklılık gösterir. Bu çalışmada olduğu gibi tahmin amaçlı bir problemde çok katmanlı ileri beslemeli bir ağ yapısının kullanılması gerekir. Bu ağın mimari yapısı şekil 1'de gösterilmiştir. Bu tip ağlarda en az üç katman yer alır. İlk katman "Girdi Katmanı" olarak adlandırılır ve bu katmana veriler (datalar) sunulur. Bu katmanda girdi sayısına bağlı olarak birçok nöron sayısı bulunmaktadır. Bir sonraki katmana "Saklı Katman" adı verilir. Problemin karmaşıklığına bağlı olarak Saklı Katman sayısı değişmektedir. Genelleme yapabilmek için veri setindeki korelasyonları ve nedensel ilişkileri Saklı Katman açıklar. Son katman ise "Çıktı Katmanı"dır.

Girdi Katmanından Saklı Katmana gelen bilgiler Saklı Katmanda işlem gördükten sonra Çıktı Katmanına ulaşır (Hamid ve Iqbal, 2004:1118).

Nöronlar kısmen ya da tamamen bağlantılı olabilirler. Tam bağlantılı bir ağda Şekil 1’de görüldüğü gibi Girdi Katmanındaki nöronların tamamı Saklı Katmandaki bütün nöronlara; Saklı Katmandaki bütün nöronlar ise, Çıktı Katmanındaki bütün nöronlara bağlıdır. Başlangıç ağırlıklarını taşıyan bağlantılar öğrenme sırasında değiştirilir (Hamid ve Iqbal, 2004:1119). “Geri Yayılım Ağı Algoritması” (backpropagation network) Delta Kuralı olarak bilinen bir nöronun gerçek çıktı değeri ile istenilen çıktı değeri arasındaki farkı azaltmak için giriş bağlantılarını yani ağırlıkları sürekli ayarlama ve geliştirme fikrine dayalı bir kuraldır (Kartalopoulos, 1996:46). Bu kuralda, öğrenme esnasındaki bağlantı ağırlıkları sürekli değiştirilerek, ağırlıklar için optimum değer bulunur. Bu ağ yapısında “Öğretmenli Öğrenme” yöntemi kullanılır. Öğretmenli öğrenmede hedef çıktı değerleriyle ilişkilendirilen her bir vektör, ağın öğrenmesi için ağa sunulur. Ağırlıklar, belirtilen öğrenme kuralına dayanarak düzeltilir (Hamid ve Iqbal, 2004:1119).

Çok katmanlı, ileri beslemeli ağlar, öğrenilmiş ilişkileri yeni bilgiler üzerinde iyi bir şekilde genelleştirdikleri için, öğrenme konusunda birçok başarılı uygulamaları bulunmaktadır. Bunu yapabilmek için, veri seti öğrenme ve test verisi olarak ikiye ayrılır. Test seti üzerinde ağın genelleme yapması sağlanır. Öğrenme oranı, başlangıç ağırlıkları, sigmoid fonksiyonunun eğimi, saklı katman sayısını da içine alan birçok öğrenme parametresinin optimal seçimi de önemlidir. Hata fonksiyonunun yerel minimuma yakınsaması yani, son ağırlıklar bileşeninin her zaman bir hata üretmesi söz konusudur. Son çalışmalarda, çok katmanlı ileri beslemeli ağlarda ortalama hata karelerinin toplamını minimum yapmak için, optimal ağırlıkların belirlenmesinde backpropagation öğrenme kuralı yerine genetik algoritmalar gibi sezgisel yaklaşımlar kullanılmaya başlanmıştır (Smith ve Grupta, 2000:1025-1027).

**Şekil 1: Çok Katmanlı ve Geri Beslemeli Bir Yapay Sinir Ağı Modeli**



**Kaynak: (Hamid ve Iqbal, 2004:1118)**

#### 4.ARAŞTIRMA SONUÇLARI

Yukarıdaki açıklamalar doğrultusunda yapay sinir ağı modelinde F2 (ağırlıklı iki yıl gecikmeli gül çiçeği reel fiyatları), Y1 (bir yıl gecikmeli gül çiçeği dikim alanı), EA (meyve veren elma ağacı sayısı), Z (zaman), EF (bir yıl gecikmeli elma reel fiyatları), ÜF (bir yıl gecikmeli üzüm reel fiyatları), D2 sabit kukla değişkeni), D2F2 (eğim kukla değişkeni) olmak üzere 8 adet bağımsız değişken mevcuttur. Dolayısıyla 31 adet yıllık verinin %70'i eğitim, %30'u test amaçlı olarak rassal olarak gruplandırılmıştır. D2, Z ve D2F2 F2, Y1, EA, EF ve ÜF değişkenlerinin, gelecek dönem değerleri bilinmemektedir. Dolayısıyla her bir değişkenin tahmini için farklı yapay sinir ağı modeli oluşturularak, gelecek döneme ilişkin değerleri tahmin edilmiştir. Her bir değişkenin tahmin edilecek döneme ilişkin değeri, bu değişkenin bağımlı olduğu ve zaman değişkeninin bağımsız olduğu bir model ile tahmin edilmiştir. Oluşturulan yapay sinir ağı modellerinde bir giriş (bağımsız değişken: zaman) ve bir çıkış (bağımlı değişken: F2, Y1, EA, EF ve ÜF ) katmanı mevcuttur. Her bir bağımsız değişkenin tahmini için oluşturulan modelde aradaki saklı katman sayısı ve nöron sayısı için değişik alternatif ağlar oluşturulmuştur. Oluşturulan alternatif ağların hangisinin daha iyi tahminde bulunduğuna karar verilirken tahmin performans ölçümlerine bakılmıştır. Tahmin performans ölçümleri için literatürde en çok 4 numaralı formül RMSE (Hata Kareleri Ortalamasının Karekökü), 5 numaralı formül MAPE (Mutlak Hata Oranları Ortalaması) ve 6 numaralı formül MSE (Hata Kareleri Ortalaması) değerlerine bakılmaktadır (Zhang ve Yu, 1997:500, Cho, 2003:328, De Lurgio, 1998:53). Oluşturulan alternatif ağlar değerlendirilirken tahmin performans ölçümleri küçük olan ağ tercih edilmiştir. Ölçümlerin istatistiksel ifadesi aşağıda verilmiştir. Ağların eğitilmesinde MATLAB 7.4 bilgisayar paket programı kullanılmıştır.

$$RMSE = \sqrt{\frac{\sum (y_t - \hat{y}_t)^2}{T}} \quad (4)$$

$$MAPE = \frac{1}{T} \sum \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100 \quad (5)$$

$$MSE = \frac{\sum (y_t - \hat{y}_t)^2}{T} \quad (6)$$



Burada;

$y_t$  = Gerçek gözlem değerleri,

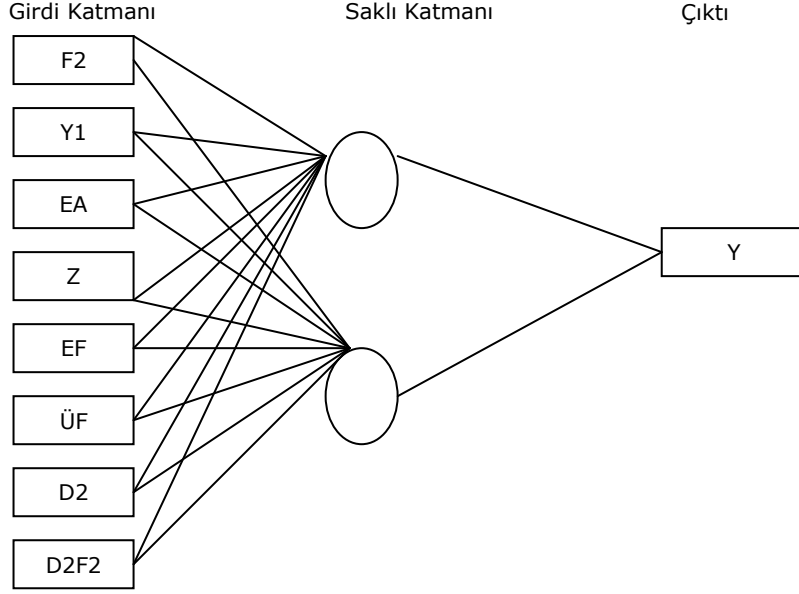
$\hat{y}_t$  = Tahmin edilen değerleri,

T = Tahmin sayısıdır.

**Tablo 4: Bağımsız Değişkenlerin ve Bağımlı Değişken Y'nin Tahmininde Kullanılan Ağ Yapıları**

Tahmin edilecek değişken	Giriş katmanı	Saklı katman	Çıkış katmanı	Giriş katmanındaki nöron sayısı	Saklı katmandaki nöron sayısı	Çıkış katmanındaki nöron sayısı
F2	1	1	1	1	4	1
Y1	1	1	1	1	2	1
EA	1	1	1	1	2	1
EF	1	1	1	1	1	1
ÜF	1	1	1	1	3	1
<b>Y</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>8</b>	<b>2</b>	<b>1</b>

F2, Y1, EA, EF ve ÜF bağımsız değişkenleri için kullanılan ağ yapıları Tablo 4'de verilmiştir. Bu ağ yapılarında giriş ve çıkış katmanlarında 1'er nöron bulunmaktadır. Bunun sebebi ise, zaman değişkeninin, bağımsız değişken olarak düşünülmesi ve giriş katmanına yazılmasıdır. Aynı şekilde tahmini yapılacak bağımlı değişkenin çıkış katmanına yazılmasıdır. Aradaki katman sayıları ve bu katmanlarda yer alacak nöron sayıları ise deneme yanılma yöntemi ile bulunmuştur. Oluşturulan alternatif ağların MSE, RMSE ve MAPE performans ölçümlerine bakılarak en küçük ölçüme sahip olan ağ yapısı tercih edilmiştir.



**Şekil 2: Y Değişkeninin Tahmininde Kullanılan Ağ Mimarisi**

Tablo 4'teki oluşturulan ağlar yardımıyla gelecek dönemdeki değerleri bilinmeyen F2, Y1, EA, EF, ÜF değişkenleri tahmin edildikten sonra bu çalışmada esas olarak tahmin edilecek değişken olan gül çiçeği dikim alanları (Y) değişkeninin tahmini için de farklı bir yapay sinir ağı modeli oluşturulmuştur. Tablo 4'te görüldüğü gibi gül çiçeği dikim alanlarının (Y) tahmininde kurulan ağda tahmin yoluyla bulunan F2, Y1, EA, EF ve ÜF değişkenlerinin yanı sıra D2, D2F2 ve Z değişkenleri de bağımsız değişken olarak kullanılmıştır. Şekil 2'de bağımlı değişken Y'nin tahmini için kullanılan ağ yapısı görülmektedir. Bu ağda Tablo 4'te gösterildiği gibi 3 katman yer almaktadır. Kullanılan ağ yapısı şekil 2'de görülmektedir. 1. katman yani giriş katmanında F2, Y1, EA, EF, ÜF, D2, D2F2 ve Z değişkenleri bağımsız değişkenler olarak yer alacağından 8 nöron yer almaktadır. Saklı katman sayısı tek ve içerdiği nöron sayısı 2 olarak düşünülmüştür. Çıkış katmanında da tek bir çıkış olacağından, yani Y bağımlı değişkenin değeri tahmin edileceğinden tek bir nöron olacaktır. Saklı katman sayısı ve içerdiği nöron sayısına karar verirken çeşitli denemeler yapılmış ve her bir ağın tahmin performans ölçümlerine bakılmıştır. Saklı katman sayısı 2 nöron olan ağın tahmin performans ölçümü en düşük çıktığı için bu ağ tercih edilmiştir. Modelden elde edilen tahmin değerleri ile gerçek değerler üzerinde yapılan ölçümlerde, MSE=0,000061449, RMSE=0,007838927, MAPE=0,1817498557 (%18,17498557) olarak bulunmuştur. Bu ölçümlere göre Witt ve Witt (2000) MAPE değerleri %10'un altında olan tahmin modellerini "yüksek doğruluk" derecesine sahip, %10 ile %20 arasında olan modelleri ise "doğru tahminler" olarak sınıflandırmıştır. Benzer şekilde Lewis (2002), MAPE değerleri %10'un altında olan modelleri "çok iyi", %10 ile %20 arasında olan modelleri "iyi",

%20 ile %50 arasında olan modelleri "kabul edilebilir" ve %50'nin altında olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır (Aktaran, Çuhadar ve Kayacan, 2005:6).

**Tablo 5: Tahmin Sonuçları**

Yıllar	Y	F2	Y1	EA	EF	ÜF
2011	19608	542,45	18115	4304900	306,04	391,76
2012	19698	544,04	18121	4488800	317,25	398,12

Tablo 5'te görüldüğü gibi Y'nin (gül çiçeği dikim alanı) tahmini için kullanılacak bağımsız değişkenler F2 (ağırlıklı iki yıl gecikmeli gül çiçeği reel fiyatları), Y1 (bir yıl gecikmeli gül çiçeği dikim alanı), EA (meyve veren elma ağacı sayısı), EF (bir yıl gecikmeli elma reel fiyatları) ve ÜF (bir yıl gecikmeli üzüm reel fiyatları) 2011 ve 2012 yılı için değerleri bilinmediği için her biri için farklı kurulan yapay sinir ağı modeli ile tahmin edilmiştir. Dolayısıyla bu bağımsız değişkenlerin tahminleri kullanılarak oluşturulan yeni yapay sinir ağı modeline göre Y'nin (gül çiçeği dikim alanları) tahmini değerleri 2011 yılı için 19.608 Da ve 2012 yılı için 19.698 Da olarak hesaplanmıştır. 2011 ve 2012 yılları için F2 (ağırlıklı iki yıl gecikmeli gül çiçeği reel fiyatları) değişkeninde de artış görüldüğü için Y değişkeninde artış gözlemlenmiştir.

### 3. SONUÇ

Gül çiçeğinden üretilen gülyağı, parfüm ve kozmetik sanayinin en önemli girdilerinden biri olarak görülmektedir. Gülyağı Türkiye'nin de önemli ihracat ürünlerinden biridir. Türkiye'de gülyağı üretimine dönük gül tarımı büyük ölçüde Isparta ilinde ve çevresinde yani Göller Bölgesi'nde yapılmaktadır.

Bu çalışmada yapay sinir ağı yöntemi kullanılarak gül çiçeği dikim alanları tahmin edilmiştir. Çalışma, yapay sinir ağı kullanılarak gül çiçeği dikim alanlarının tahmin edilebileceğini, böylece doğru tahminlerin elde edilmesi ile birlikte, ileriki yıllarda gül çiçeği üretimi ile ilgili olarak doğru tarım politikalarının hayata geçirilebileceğini göstermektedir. Gül çiçeği reel fiyatlarındaki dalgalanmalar gül çiçeği dikim alanlarının, dolayısıyla gül çiçeği-gülyağı arzının dalgalanmasına neden olmaktadır. Bu bağlamda bu çalışma, Isparta ilinde gül çiçeği üretimi konusunda karar verme konumunda olan kişi ve kurumların, geleceğe yönelik planlama ve uygulama çalışmalarında geleneksel tahmin yöntemlerine alternatif olarak yapay sinir ağı yöntemini kullanabileceklerini göstermektedir.

## KAYNAKÇA

- ALBENİ, M. (1996). "Göller Bölgesi'nde Gül Çiçeđi Üretimini İktisadi Sorunları ve Ekonometrik Analizi", Yayınlanmamış Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi: Isparta.
- CHO, V. (2003). "A Comparison of Three Different Approaches to Tourist Arrival Forecasting", *Tourism Management* , 24: 323-330.
- ÇUHADAR, Murat ve KAYACAN C. (2005), "Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme", *Anatolia:Turizm Araştırmaları Dergisi*, 16(1): 1990-2005.
- De LURGIO, A. S. (1998), *Forecasting Principles and Applications*, Irwin McGraw-Hill:Singapore.
- HAMİD, Shaikh, A. ve Zahid IQBAL (2004), "Using Neural Networks for Forecasting Volatility of S&P 500 Index Futures Prices", *Journal of Business Research*, 57: 1116-1125.
- GÜLBİRLİK (2011). <http://www.gulbirlik.com>, (10.10.2011)
- KARTALOPOULOS, Stamatios V. (1996), *Understanding Neural Network and Fuzzy Logic*, IEEE Press, Newyork.
- NABIYEV, V., V. (2005), *Yapay Zeka*, Seçkin Yayıncılık, Ankara.
- ÖZTEMEL, E (2003), *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul.
- SMITH, K.A. and GRUPTA, J.N.D. (2000) "Neural Networks in Business: Techniques and Applications for The Operations Researcher", *Computers & Operations Research*, 27: 1023-1044.
- TOSUN, İ., GÖNÜLLÜ M.T. ve ARSLANKAYA E. (2011), *Gülyađı Sanayi Proses Atıkları Özelliklerinin Belirlenmesi*, <http://www.yildiz.edu.tr/~gonul/bildiriler/b82.pdf>, (06.06.2011).
- ZHANG, G., HU, M.Y. (1998) "Neural Network Forecasting of the British Pound/US Dollar Exchange Rate", *Omega Int. J. Mgmt. Sci*, 26(4): 495-506.