

YAPAY SINIR AĞLARI İLE LOJİSTİK REGRESYON ANALİZİ'NİN KARŞILAŞTIRILMASI

İmran KURT*

Mevlüt TÜRE**

ÖZET

Bu çalışmada, öğrencilerin alkol kullanımını etkileyen faktörlerin Lojistik Regresyon Analizi ve Yapay Sinir Ağları ile incelenmesi ve bu yöntemlerin alkol kullanan ve kullanmayan öğrencileri ayırmadaki performanslarının ROC eğrisi yöntemiyle karşılaştırılması amaçlandı.

Çalışmada, 2003-2004 Eğitim-Öğretim yılında Trakya Üniversitesi Tıp Fakültesi 1, 2, 3 ve 4'üncü sınıflarında okuyan öğrencilere Frontal Lob Kişilik Ölçeği ve alkol kullanma alışkanlıklarını tespit etmek için alkolle ilgili anket uygulandı.

Çalışmamızda, Lojistik Regresyon ve dört farklı yapay sinir ağı modeli oluşturuldu. Lojistik Regresyon Analizi sonucunda ders dışındaki zamanlarda bar, disko, kafe ya da kahvehaneye gitme (OR=1.920; $p<0.05$), dinin önem düzeyi (OR=0.454; $p<0.001$), alkol kullanan arkadaş sayısı (OR=2.441; $p<0.001$), alkol içmesi için arkadaşların ısrar düzeyi (OR=1.557; $p<0.01$) ve dürtüsellik (OR=1.826; $p<0.001$) değişkenlerinin öğrencilerin alkol kullanımı üzerinde önemli etkiye sahip oldukları bulundu. Lojistik Regresyon Analizi ile Yapay Sinir Ağları ve Yapay Sinir Ağları kendi aralarında karşılaştırıldığında; hiperbolik tanjant-hiperbolik tanjant fonksiyonlu ve hiperbolik tanjant-lojistik fonksiyonlu Yapay Sinir Ağları'nın ROC eğrisi altında kalan alanlarının farklı olmadığı fakat bu modellerin diğer modellerin alanlarından istatistiksel olarak daha büyük oldukları bulundu.

Sonuç olarak; çalışmalarda Yapay Sinir Ağları'nın Lojistik Regresyon Analizi'ne göre avantaj ve dezavantajları göz önünde bulundurularak amaca göre sınıflandırma ve modelleme çalışmalarının yürütülmesi gerektiğine ve Lojistik Regresyon Analizi'nin önemsiz değişkenlerin elenmesi için Yapay Sinir Ağları'nda bir eleme yöntemi olarak kullanılabileceğine karar verildi.

Anahtar Kelimeler: *Frontal Lob Kişilik Ölçeği, Lojistik Regresyon Analizi, Yapay Sinir Ağları, Geriye Yayılma Algoritması, Receiver Operating Characteristic (ROC) Eğrisi*

*Araş.Gör., Trakya Üniversitesi Tıp Fakültesi, Biyoistatistik Anabilim Dalı 22030 Edirne (Haberleşme Adresi)

**Yard.Doç.Dr., Trakya Üniversitesi Tıp Fakültesi, Biyoistatistik Anabilim Dalı Edirne

1. GİRİŞ

İncelenen olaylar, çoğunlukla birden fazla değişkenin etkisi altında kalmakta ve yapılan çalışmaların geçerli ve güvenilir olması için, incelenen olayı etkileyen birden çok değişkenin birlikte ele alınması gerekmektedir. Araştırmaların çoğunda bağımlı değişken ile bağımsız değişken/değişkenler arasındaki neden-sonuç ilişkisinin belirlenmesinde bazı kısıtlamalar altında, değişkenin ölçüm düzeyine bağlı olarak Çoklu Regresyon Analizi ve Lojistik Regresyon Analizi (LR) gibi klasik yöntemler kullanılmaktadır.

Günümüzde LR dışında kökeni tıp, matematik, fizik ve mühendislik alanlarına dayanan ve biyolojik sinirsel ağlardan esinlenilerek geliştirilen Yapay Sinir Ağları (YSA) ile daha karmaşık yapıda problemlere çözüm aranmaktadır. Çok geniş uygulama alanına sahip olan sinir ağlarının gelişim süreci, 1943-1958 yıllarını kapsamaktadır. Bu alanda yapılan ilk çalışmalar beyin hücrelerinin işlevlerinin ve birbirleri ile haberleşme şekillerinin ortaya çıkarılmasını amaçlamaktaydı. Günümüzde ise, birçok hücrenin belli bir düzende bir araya getirilmesi ve uygun öğrenme algoritmaları ile sinir ağları kurulabilmekte ve bu ağlar çok karmaşık problemleri başarıyla çözümleyebilmektedir (Haykin, 1999). Ayrıca gelişen bilim dünyasının olanaklarının gün geçtikçe çeşitlilik kazanması, karmaşık sistemleri ortaya çıkarmıştır. Bu durum, çözümü aranan problemlerin matematiksel modellerinin geliştirilmesini ve problemlere önerilen çözümlerde istenen hassasiyetin kazanılmasını güçleştirmiştir (Efe ve Kaynak, 2000). Bu anlamda YSA, elde edilen çözümlerin istenen özellikleri taşıması nedeniyle bir çok alanda tercih edilen bir yöntem haline gelmiştir.

YSA, bazı benzerlikleriyle LR'ye alternatif bir istatistiksel yöntemdir. Bu yöntem, öğrenme ve bilgileri hafızaya alma gibi, biyolojik süreçlerin simülasyonunu yapmak için kullanılan matematiksel denklemleri içerir. YSA, bağımsız değişkenlerin değerlerine dayanarak sonucu tahmin eden LR modelinin aynısını bulmayı amaçlar. Bununla birlikte model geliştirmede YSA ile LR'de kullanılan yaklaşımlar tamamen farklıdır (Tu, 1996).

Bu çalışmanın amacı, 2003-2004 Eğitim-Öğretim yılında Trakya Üniversitesi Tıp Fakültesi 1, 2, 3 ve 4'üncü sınıflarında okuyan öğrencilere alkol kullanma alışkanlıklarını tespit etmek için alkol ile ilgili bir anket ve öğrencilerin kişilik özelliklerini belirlemek için bazı frontal lob sendromlarıyla birleştirilmiş davranışları gösteren Frontal Lob Kişilik Ölçeği'nin uygulanması, öğrencilerin alkol kullanma alışkanlıklarına etkide bulunan değişkenlerin LR ve YSA ile incelenmesi ve bu yöntemlerin alkol kullanan ve kullanmayan öğrencileri ayırmadaki performanslarının Receiver Operating Characteristic (ROC) Eğrisi yöntemiyle karşılaştırılmasıdır.

2. GEREÇ ve YÖNTEM

Çalışmamızda, Trakya Üniversitesi Tıp Fakültesi'nde 2003-2004 Eğitim-Öğretim yılında 1, 2, 3 ve 4'üncü sınıflarda okuyan 654 öğrenci çalışma evrenini oluşturdu. Ulaşılabilen toplam 513 öğrenciye, alkol ile ilgili anket ve Frontal Lob Kişilik Ölçeği (Dinn vd, 2004; Aycicegi vd, 2003) uygulandı. Öğrencilerden 39'u

sorulara eksik cevaplar verdiği için çalışmadan çıkarıldı ve analizler 474 öğrenci üzerinden yapıldı.

Alkol ile ilgili soruları içeren anketten aşağıdaki değişkenler çalışmaya alındı:

Bağımlı Değişken

- ❖ *Alkol Kullanıyor musunuz?*

Bağımsız Değişkenler

- ❖ *Cinsiyetiniz*
- ❖ *Üniversitenizdeki sosyal etkinliklere katılıyor musunuz?*
- ❖ *Ders dışındaki zamanınızda bir müzik aleti çalıyor musunuz?*
- ❖ *Bir spor kulübüne üye misiniz?*
- ❖ *Ders dışındaki zamanınızda bazı dernek faaliyetlerine katılıyor musunuz?*
- ❖ *Ders dışındaki zamanınızda bar, disko, kafe ya da kahvehaneye gidiyor musunuz?*
- ❖ *Ders dışındaki zamanınızda bilardo, atari salonuna ya da internet kafeye gidiyor musunuz?*
- ❖ *Annenizin eğitim düzeyi*
- ❖ *Hayatınızda bir sorun olduğu zaman, bunu anne ya da babanız ile paylaşabiliyor musunuz?*
- ❖ *Sizin hayatınızda din ne kadar önemlidir?*
- ❖ *Sizce arkadaşlarınızdan kaç tanesi alkol kullanıyor?*
- ❖ *Alkol içmek için arkadaşlarınız ne kadar ısrar eder?*

Öğrencilerin alkol kullanma alışkanlıklarını incelemeye psikolojik test ölçeklerinden biri olan ve alt kategorileri (Hemen hemen hiç-1, Nadiren-2, Bazen-3, Sık sık-4, Hemen hemen her zaman-5) 5'li Likert ölçekli 43 maddeden oluşan Frontal Lob Kişilik Ölçeği'ne uygulanan güvenilirlik analizi sonucunda Cronbach α değeri 0.82 bulundu. Frontal Lob Kişilik Ölçeği'ndeki 43 maddeye Açıklayıcı Faktör Analizi (AFA) uygulanarak özdeğerleri 1'den büyük olan faktörler belirlendi ve Kaiser'in varimax döndürme yöntemiyle boyut indirilmesi yapıldı. Bunun sonucunda *kendilik değeri, düzenlilik, enerji düzeyi, duygu durumu, dürtüsellik, toplumsal işlev ve girişimcilik* olmak üzere 7 faktör belirlendi.

LR ve YSA uygulanmadan önce 474 birimlik veri seti eğitim (n=427; %90) ve test seti (n=47; %10) olarak rasgele iki sete ayrıldı. LR, *alkol kullanımı* bağımlı değişken olmak üzere alkol ile ilgili sorular ve AFA sonucu elde edilen faktörlerden oluşan bağımsız değişkenler kullanılarak ilişkilerin modellenmesi, bağımlı değişken üzerinde anlamlı etkiye sahip olan bağımsız değişkenlerin belirlenmesi ve birimlerin sınıflandırılması için eğitim setine uygulandı.

YSA, LR sonucunda bağımlı değişken üzerinde anlamlı etkiye sahip olan bağımsız değişkenler alınarak eğitim setine uygulandı (Tu, 1996). YSA ile birimlerin alkol kullanımına göre sınıflandırılmasında farklı gizli nöron sayılarının denenmesi sonucunda gizli tabakadaki nöron sayısının 5 alınması gerektiğine karar verildi. YSA'ların hata kareler ortalaması (HKO) bakımından eğitim seti performansının test setine karşı rahatlıkla denetlenmesi ve en iyi ağırlıkların bulunduğu adımda öğrenme sürecinin dışarıdan müdahale olmadan kendini durdurması için maksimum adım sayısı

10000 olarak ayarlandı. Öğrenme sürecinde HKO bakımından her bir yapay sinir ağının eğitim setinin performansı, 50 adımda bir test setine karşı test edildi ve test setinin HKO'su artmaya başladığı noktada öğrenme süreci sona ererek veriye en uygun yapay sinir ağı bulundu. Öğrenme oranı, gizli tabakada 1 ve çıktı tabakasında 0.1 olarak alındı. Momentum sabiti ise gizli ve çıktı tabakasında 0.7 olarak alındı.

2.1. Lojistik Regresyon Analizi

LR analizi, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi tanımlayan bir matematiksel modelleme yaklaşımıdır. Diğer regresyon yöntemlerinden farkı, bağımlı değişkenin ikili ya da ikiden çok kategori içeren kesikli ya da kategorik olması durumunda uygulanabilen çok esnek bir yöntem olmasıdır (Özdamar, 1999; Tatlıdil, 1996; Armitage, 2000; Hosmer and Lemeshow, 2000; Kleinbaum, 1994; Sharma, 1996).

LR, bağımlı değişken üzerinde hangi bağımsız değişken/değişkenlerin önemli risk faktörü olduğu ve bu bağımsız değişken/değişkenlerin bağımlı değişkenin değerlerinin tahmininde ne düzeyde etkiye bulduklarını belirler. Ayrıca LR, bağımsız değişkenlerin etkilerine dayanarak verilerin sınıflandırılmasında kullanılan bir yöntemdir. Bu yöntem, olasılık kurallarına uygun olarak verilerin belirli sınıflara atanmasını sağlar (Özdamar, 1999; Tatlıdil, 1996).

Lojistik modelde, y iki kategorili bağımlı değişken ve $1 \times p$ boyutlu bağımsız değişken vektörü \mathbf{x} olmak üzere \mathbf{x} 'e göre y 'nin koşullu ortalamasını gösteren $\pi(\mathbf{x}) = E(y|\mathbf{x})$ niceliği kullanılır. LR modeli,

$$\pi(\mathbf{x}) = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p}}$$

biçiminde yazılır. Burada β_0 sabit, β_1 regresyon katsayısı ve $\pi(\mathbf{x})$, bağımlı değişkenin \mathbf{x} 'e bağlı olarak 1'e eşit olması koşullu olasılığıdır.

Bu modelde, $-\infty$ ile $+\infty$ arasında değer alabilen bağımsız değişkenlere dayanarak iki kategorili bağımlı değişkenin değerlerini tahmin etmek güçtür. Bu durumu ortadan kaldırmak için en iyi çözüm, bağımlı değişkenin olasılık değerinin $-\infty$ ile $+\infty$ arasında tanımlı hale getirilmesidir. Bu amaçla $\pi(\mathbf{x})$ 'e dayanarak LR modeline lojit dönüşüm uygulanmasıyla,

$$g(\mathbf{x}) = \ln\left(\frac{\pi(\mathbf{x})}{1 - \pi(\mathbf{x})}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$$

modeli elde edilir. Lojit $g(\mathbf{x})$, \mathbf{x} 'in aralığına bağlı kalarak $-\infty$ ile $+\infty$ arasında değer alabilen doğrusal bir fonksiyondur (Özdamar, 1999; Tatlıdil, 1996; Hosmer and Lemeshow, 2000; Kleinbaum, 1994).

LR'de $\beta_0, \beta_1, \dots, \beta_p$ katsayılarını tahmin etmede en çok olabilirlik yöntemi yaygın olarak kullanılmaktadır (Hosmer and Lemeshow, 2000).

y_i , i 'inci birimin iki kategorili bağımlı değişken değeri ve \mathbf{x}_i , i 'inci birim için bağımsız değişken vektöründeki değerleri göstermek üzere (\mathbf{x}_i, y_i) n tane bağımsız gözlem çiftinden oluşan bir örneklem olsun ($i=1,2,\dots,n$). Eğer bağımlı değişken y , 0 ya da 1 olarak kodlanmışsa; $\pi(\mathbf{x})$, verilen \mathbf{x} için y 'nin 1'e eşit olmasının koşullu olasılığını ($P(y=1|\mathbf{x})$) verir. $1-\pi(\mathbf{x})$ ise, verilen \mathbf{x} için y 'nin 0'a eşit olmasının koşullu olasılığını ($P(y=0|\mathbf{x})$) verir. Böylece (\mathbf{x}_i, y_i) çiftleri için, $y_i = 1$ için olabilirlik fonksiyonuna katkı $\pi(\mathbf{x}_i)$ ve $y_i = 0$ için olabilirlik fonksiyonuna katkı $1-\pi(\mathbf{x}_i)$ 'dir. Burada $\pi(\mathbf{x}_i)$, \mathbf{x}_i 'de hesaplanan $\pi(\mathbf{x})$ olasılığını tanımlar. (\mathbf{x}_i, y_i) çiftleri için olasılık ya da olabilirlik fonksiyonuna katkı,

$$\zeta(\mathbf{x}_i) = \pi(\mathbf{x}_i)^{y_i} [1 - \pi(\mathbf{x}_i)]^{1-y_i}$$

eşitliğiyle elde edilir. Gözlemlerin bağımsız olduğu varsayıldığı için olabilirlik fonksiyonu,

$$l(\boldsymbol{\beta}) = \prod_{i=1}^n \zeta(\mathbf{x}_i) = \prod_{i=1}^n \pi(\mathbf{x}_i)^{y_i} [1 - \pi(\mathbf{x}_i)]^{1-y_i}$$

eşitliğiyle gösterilir ve en çok olabilirlik yöntemi bu eşitliği maksimum yapan $\boldsymbol{\beta}$ vektörünü tahmin etmemizi sağlar (Hosmer and Lemeshow, 2000; Kleinbaum, 1994).


2.2. Yapay Sinir Ağları

YSA, elle çözüm imkanı vermeyen son derece karmaşık yapıya sahip, insan beynindeki sinir ağları gibi çalışarak bilgisayar yardımıyla en zor problemlerin çözümünü sağlayan ve değişken yapısı konusunda herhangi bir kısıtlama getirmeksizin değişkenler arasındaki ilişkiyi ortaya koyan çok esnek bir yöntemdir (Efe ve Kaynak; 2000; Kurt vd, 2002; Gaudart vd, 2004).

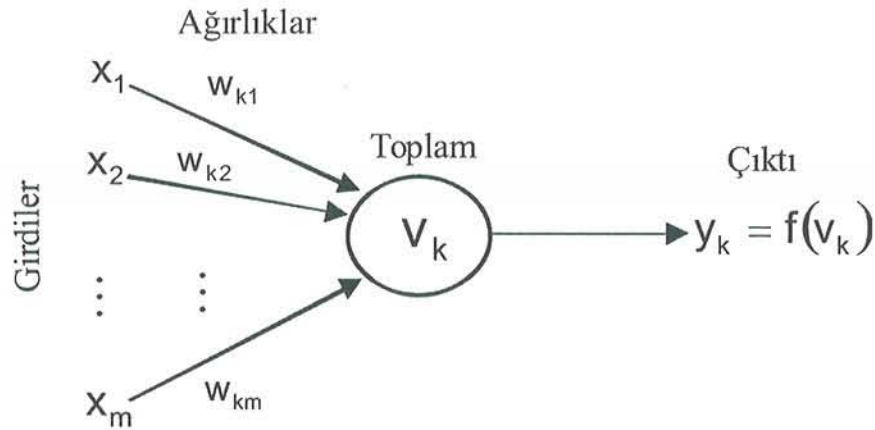
En genel biçimiyle YSA, ilgilenilen belirli bir fonksiyonu ortaya çıkaran beyin yapısının modelini tasarlayan bir makinedir. YSA, insan beynindeki nöronların işlevini yapay olarak gerçekleştiren basit hesap hücrelerinin birbirleriyle bağlantılarını kullanarak en iyi performansı elde etmeye çalışır (Haykin, 1999; Tu, 1996; Nasr vd, 2003).

İnsan beyninin kendini nasıl eğittiği konusunda çok sayıda teori üretilmesine rağmen günümüzde hala çok fazla bilgi yoktur. İnsan beyninin henüz tam anlamıyla keşfedilemeyen bu karmaşık yapısının öğeleri Şekil 1'de verilmiştir. Sinirleri ve bağlantılarıyla bahsedilen insan beyni hareketlerini taklit eden sistem YSA ile açıklanmaya çalışılmıştır (Şekil 1) (Cho, 2003; Francis, 2001).

YSA, nöronlar arasındaki bağlantıların yapısı bakımından ileri beslemeli (feedforward) ve geri beslemeli (recurrent) olmak üzere ikiye ayrılır. İleri beslemeli ağlar, ağ üzerinde bilgi akışını sürekli girdiden çıktıya doğru ilerleterek tabakalar arası geçişi sağlar. Geri beslemeli ağlarda ise, ağ yapısında geribesleme bağlantıları vardır. Sinir ağı, ağırlıklarının ayarlanmasında her bir adımda çıktıya ulaşıldıktan sonra zamanın belirli bir kısmında sinyalleri depolar ve yeniden kullanır (Haykin, 1999; Gaudart vd, 2004; Hassoun, c1995; Krose and Smagt, 1996).



Dendirit	↔	Girdi
Sinaps	↔	Ağırlık
Hücre gövdesi	↔	Toplam
Akson	↔	Çıktı



Şekil 1. Biyolojik ve yapay sinir ağı

YSA'da temel sorun en uygun ağırlık setinin belirlenmesidir. Bu ağırlıkların belirlenmesi için geçen öğrenme sürecinde danışmanlı öğrenme ve danışmansız öğrenme olarak isimlendirilen iki öğrenme stratejisi söz konusudur. Danışmanlı öğrenmede, sinir ağına girdi verisiyle başlayan öğrenme sürecinde elde edilen çıktı değerleri gözlenen çıktılarla karşılaştırılır ve gözlenen ile beklenen çıktılara göre hata hesaplanır. Sinir ağının ağırlıkları bu hatayı minimum yapmak için ayarlanır. Danışmansız öğrenmede ise, sinir ağının ağırlıkları gözlenen çıktılara göre ayarlanmaz. Girdi verisi için hangi çıktının en iyisi olduğuna ağ kendisi karar vererek ağırlıkları ayarlar (Haykin, 1999; Francis, 2001; Hassoun, c1995).

Geriyeye yayılma algoritması, YSA'nın parametrelerinin güncellenmesi için en yaygın olarak kullanılan yöntemdir. Geriyeye yayılma algoritması, ağ hatasının minimize edilmesi için ağın ağırlıklarının adım adım hesaplanması sürecidir (Haykin, 1999; Hassoun, c1995; Krose and Smagt, 1996; Rojas, 1991).

Geriyeye yayılma algoritmasınının t'inci adımdan (t+1)'inci adıma geçişte ağırlık değişimi,

$$w_{kj}(t+1) = w_{kj}(t) + \eta \delta_k(t) y_j(t)$$

eşitliğiyle gösterilir. Burada η , geriye yayılma algoritmasının öğrenme oranı parametresi olarak tanımlanan pozitif bir sayı; $\delta_k(t)$, t'inci adımda k nöronunun lokal hatası yani k nöronunun gözlenen çıktısı ile beklenen çıktısı arasındaki fark; $w_{kj}(t)$, t'inci adımda k nöronunun girdi değişkenine bir önceki tabakadaki j nöronunun bağlandığı ağırlığı ve $y_j(t)$, j nöronunun çıktılarını gösterir.

Öğrenme oranının bahsedilen sakıncaları nedeniyle algoritmanın bir momentum sabitiyle ağ ağırlıklarını değiştirmesi tercih edilir. Momentum sabiti, her bir ağırlığın değişimini bir önceki ağırlığın değişimine bağımlı kılarak algoritmanın ağırlıklarının ayarlanmasını sağlar. Momentum sabiti (α), kullanılarak daha hızlı ve güçlü bir yakınsama gerçekleştirilir. Momentum sabiti kullanıldığında algoritma,

$$w_{kj}(t+1) = w_{kj}(t) + \eta \delta_k(t) y_j(t) + \alpha (w_{kj}(t) - w_{kj}(t-1))$$

eşitliğiyle gösterilir. Öğrenme oranı ve momentum sabiti, 0 ile 1 arasında değer alan pozitif sayılardır (Haykin, 1999; Nasr vd, 2003; Krose and Smagt, 1996; Rojas, 1991; Sundararajan and Saratchandran, 1998).

2.3. ROC Eğrisi Yöntemi

ROC eğrisi, tanı testlerinin performanslarının değerlendirilmesi ve kıyaslanması için yaygın olarak kullanılan bir yöntemdir. Bu yöntem, bir medikal testin en uygun duyarlılığını ve en uygun özgüllüğünü belirlemek için optimum kesim noktalarının belirlenmesini sağlar. ROC eğrisi yöntemi, tanı testinin sınıflandırma performansının iki boyutlu grafiksel gösterimidir. Sınıflandırmanın doğruluğu, ROC eğrisi altında kalan alanın büyüklüğüne bağlıdır (Dirican, 2001; Swaving vd, 1996; Hanley and Mcneil, 1983; Hosmer, 2000; Özdamar, 2003).

ROC eğrisi altında kalan alan, $A = F\left(\frac{b}{\sqrt{1+a^2}}\right)$ eşitliğiyle hesaplanır. Burada F kümülatif standart normal dağılım fonksiyonu, a eğim ve b sabit katsayılarıdır (Swaving vd, 1996; Hanley and Mcneil, 1983). ROC eğrisi altındaki alan, 0 ile 1 arasında değer almaktadır (Hosmer, 2000).

Aynı birimler üzerinde farklı iki tanı testi uygulanması durumunda bağımlı diziler elde edilir. Hanley ve McNeil (1983) tarafından geliştirilen yöntemle göre bağımlı dizilerde ROC eğrisi altında kalan alanların karşılaştırılmasında test istatistiği,

$$z = \frac{A_1 - A_2}{SH(A_1 - A_2)}$$

eşitliğiyle bulunur. Burada $SH(A_1 - A_2)$, A_1 ve A_2 alanları arasındaki farkın standart hatasıdır ve $SH(A_1 - A_2) = \sqrt{SH^2(A_1) + SH^2(A_2) - 2r_t SH(A_1) SH(A_2)}$ şeklinde hesaplanır. Burada r_t , A_1 ve A_2 alanları arasındaki korelasyon için tahmin edilen korelasyon katsayısı ve $SH(A)$ ise ROC eğrisi altında kalan alanın standart hatasıdır (Swaving vd, 1996, Hanley and Mcneil, 1983; Hanley and Mcneil, 1982; Mcclish, 1987).

3. BULGULAR

3.1. Lojistik Regresyon Analizi Sonuçları

Bağımlı değişken ile bağımsız değişkenler arasındaki ilişkinin modellenmesi amacıyla eğitim setine ileriye yönelik LR uygulandı ve *ders dışındaki zamanlarda bar, disko, kafe ya da kahvehaneye gitme* ($p<0.05$), *dinin önem düzeyi* ($p<0.001$), *alkol kullanan arkadaş sayısı* ($p<0.001$), *alkol içmesi için arkadaşların ısrar düzeyi* ($p<0.01$) ve *dürtüsellik* ($p<0.001$) değişkenlerinin öğrencilerin *alkol kullanımı* üzerinde önemli etkiye sahip oldukları bulundu (Tablo 1).

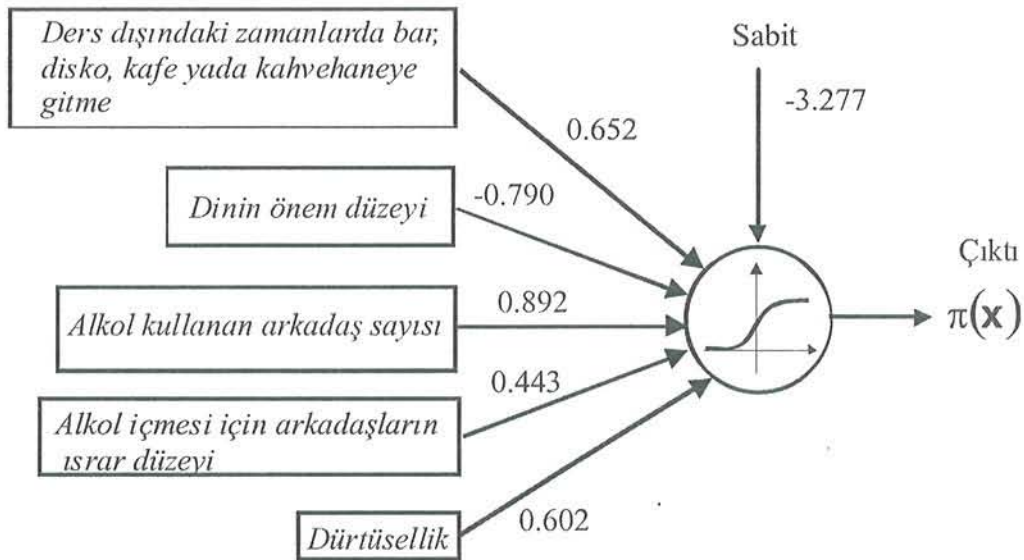
Tablo 1 incelendiğinde; ders dışındaki zamanlarda bar, disko, kafe ya da kahvehaneye gidenlerin gitmeyenlere göre alkol kullanma oranının 1.920 kat daha fazla olduğu (%95 güven aralığı 1.148-3.211), dinin önem düzeyi arttıkça alkol kullanma oranının %45.4 oranında azaldığı (%95 güven aralığı 0.337-0.611), alkol kullanan arkadaş sayısı arttıkça alkol kullanma oranının 2.441 kat arttığı (%95 güven aralığı 1.892-3.150), alkol içmesi için arkadaşların ısrar düzeyi arttıkça alkol kullanma oranının 1.557 kat arttığı (%95 güven aralığı 1.154-2.101) ve dürtüsellik puanı arttıkça alkol kullanma oranının 1.826 kat arttığı (%95 güven aralığı 1.412-2.359) bulundu.

Model uyumu Hosmer-Lemeshow testi ile incelendi ($\chi^2=3.289$, $sd=8$ ve $p=0.915$) ve LR modelinin alkol kullanan ve kullanmayan öğrencileri ayırmada yeterli bir model olduğu bulundu.

Tablo 1. Eğitim setinde LR modeline giren değişkenler

Değişkenler	β	p	OR	OR'nin % 95 Güven Aralığı	
				Alt Limit	Üst Limit
<i>Ders dışındaki zamanlarda bar, disko, kafe ya da kahvehaneye gitme</i>	0.652	0.013	1.920	1.148	3.211
<i>Dinin önem düzeyi</i>	-0.790	<0.001	0.454	0.337	0.611
<i>Alkol kullanan arkadaş sayısı</i>	0.892	<0.001	2.441	1.892	3.150
<i>Alkol içmesi için arkadaşların ısrar düzeyi</i>	0.443	0.004	1.557	1.154	2.101
<i>Dürtüsellik</i>	0.602	<0.001	1.826	1.412	2.359
Sabit	-3.277	<0.001	0.038		

Tablo 1'deki parametre tahminlerine göre LR modelinin grafiksel gösterimi Şekil 2'de verilmiştir.



Şekil 2. LR modelinin grafiksel gösterimi

3.2. Yapay Sinir Ağları Sonuçları

LR analizi sonucunda *alkol kullanımı* üzerinde etkisi olduğu belirlenen *ders dışındaki zamanlarda bar, disko, kafe ya da kahvehaneye gitme*, *alkol kullanan arkadaş sayısı*, *alkol içmesi için arkadaşların ısrar düzeyi*, *dinin önem düzeyi* ve *dürtüsellik* değişkenleri YSA'larda girdi olarak alındı. Gizli tabakada lojistik ya da hiperbolik tanjant, çıktı tabakasında lojistik ya da hiperbolik tanjant aktivasyon fonksiyonları kullanılarak danışmanlık öğrenme stratejisi ile dört farklı ileri beslemeli çok tabakalı yapay sinir ağı oluşturuldu:

1. Gizli ve çıktı tabakasında lojistik fonksiyon kullanılan yapay sinir ağı (L-L)
2. Gizli tabakada lojistik ve çıktı tabakasında hiperbolik tanjant fonksiyon kullanılan yapay sinir ağı (L-HT)
3. Gizli ve çıktı tabakasında hiperbolik tanjant fonksiyon kullanılan yapay sinir ağı (HT-HT)
4. Gizli tabakada hiperbolik tanjant ve çıktı tabakasında lojistik fonksiyon kullanılan yapay sinir ağı (HT-L)

YSA'ların öğrenme süreçleri sonunda eğitim seti ve durdurma kriteri olarak seçilen test setinden elde edilen minimum HKO'ları ve minimuma ulaşılan adım sayısı Tablo 2'de verilmiştir.


Tablo 2. YSA'ların eğitim ve test setlerinin minimum HKO'ları ve adım sayısı

Veri Seti	Aktivasyon Fonksiyonu		Minimum HKO	Adım Sayısı
	Gizli Tabaka	Çıktı Tabakası		
Eğitim Seti	Lojistik	Lojistik	0.058	3031
	Lojistik	Hiperbolik Tanjant	0.235	219
	Hiperbolik Tanjant	Hiperbolik Tanjant	0.221	217
	Hiperbolik Tanjant	Lojistik	0.056	836
Test Seti	Lojistik	Lojistik	0.051	
	Lojistik	Hiperbolik Tanjant	0.211	
	Hiperbolik Tanjant	Hiperbolik Tanjant	0.199	
	Hiperbolik Tanjant	Lojistik	0.048	

Tablo 2 incelendiğinde; HT-L fonksiyonlu yapay sinir ağının en küçük HKO değerini verdiği, 2. en küçük HKO değerini L-L fonksiyonlu yapay sinir ağının verdiği, 3. olarak HT-HT fonksiyonlu yapay sinir ağının ve en büyük HKO değerini ise L-HT fonksiyonlu yapay sinir ağının verdiği bulundu. Böylece en iyi optimizasyonu sağlayan model, HT-L fonksiyonlu yapay sinir ağı olarak bulundu.

3.3. Lojistik Regresyon Analizi İle Yapay Sinir Ağları Sonuçlarının Karşılaştırılması

Şekil 3’de YSA’da en iyi ağırlıkların tahmin edildiği adımda elde edilen sınıflandırma sonuçları ve LR sonucunda elde edilen sınıflandırma sonuçları kullanılarak hesaplanan ROC eğrileri altında kalan alanlar gösterilmiştir. Şekil 3’de HT-HT fonksiyonlu yapay sinir ağının ROC eğrisi altında kalan alanının en büyük alan olduğu görülmektedir. En küçük ROC eğrisi altında kalan alan ise L-HT fonksiyonlu yapay sinir ağından elde edildi.



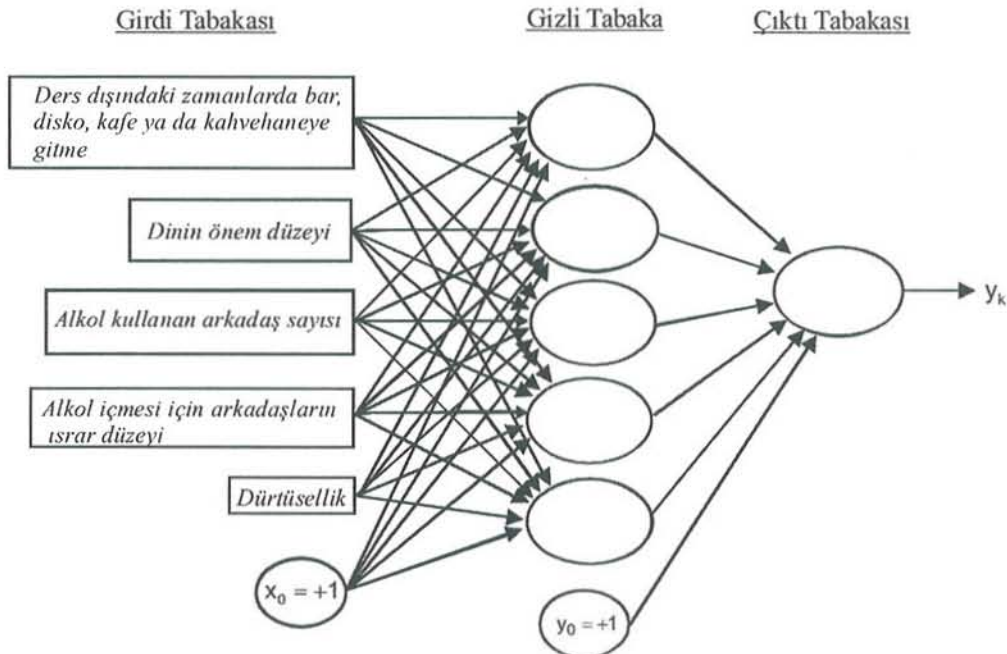
Şekil 3. Modellerin ROC eğrileri

Tablo 3'de ROC eğrisi altında kalan alanların ikili karşılaştırma sonuçları verilmiştir.

Tablo 3. ROC eğrisi altında kalan alanların karşılaştırılması

Yöntem	L-L	L-HT	HT-HT	HT-L
LR	$A_1-A_2 = 0.005$ $SH(A_1-A_2) = 0.003$ $p = 0.098$	$A_1-A_2 = 0.001$ $SH(A_1-A_2) = 0.004$ $p = 0.748$	$A_1-A_2 = 0.015$ $SH(A_1-A_2) = 0.006$ $p = 0.010$	$A_1-A_2 = 0.013$ $SH(A_1-A_2) = 0.005$ $p = 0.008$
L-L		$A_1-A_2 = 0.006$ $SH(A_1-A_2) = 0.004$ $p = 0.127$	$A_1-A_2 = 0.010$ $SH(A_1-A_2) = 0.005$ $p = 0.030$	$A_1-A_2 = 0.008$ $SH(A_1-A_2) = 0.003$ $p = 0.011$
L-HT			$A_1-A_2 = 0.016$ $SH(A_1-A_2) = 0.007$ $p = 0.010$	$A_1-A_2 = 0.014$ $SH(A_1-A_2) = 0.006$ $p = 0.009$
HT-HT				$A_1-A_2 = 0.002$ $SH(A_1-A_2) = 0.004$ $p = 0.648$

ROC eğrisi altında kalan alanların karşılaştırılması sonucunda HT-HT fonksiyonlu yapay sinir ağı modeli ile en iyi optimizasyonu sağlayan HT-L fonksiyonlu yapay sinir ağı modelinin eğri altında kalan alanlarının diğer modellerin alanlarından istatistiksel olarak daha büyük olduğu ve öğrencilerin alkol kullanımına göre sınıflandırılmasında LR ve diğer YSA modellerinden daha iyi oldukları bulundu (Tablo 3). Bu modellerin grafiksel gösterimi Şekil 4'de gösterilmiştir.



Şekil 4. HT-HT ile HT-L fonksiyonlu yapay sinir ağı modellerinin grafiksel gösterimi

4. TARTIŞMA

Çalışmamızda, hastalıkları tedavi etme ve önleme çalışmalarında önemli rol oynayan tıp doktorluğu mesleğinde gelecekte sağlık hizmetleri vermek üzere yetiştirilen tıp öğrencilerinin alkol kullanmasına neden olan faktörlerin belirlenmesinin yanı sıra, alkol kullanan ve kullanmayan öğrencileri sınıflandırmada LR ve YSA yöntemlerini karşılaştırmak amacıyla Trakya Üniversitesi Tıp Fakültesi'nde 2003-2004 Eğitim-Öğretim yılında öğrenim görmekte olan 1, 2, 3 ve 4'üncü sınıf öğrencilerinden elde edilen veriler kullanıldı.

Alkol kullanımı ile ilgili yapılan çalışmalarda gençlerin alkol kullanmasına yol açan nedenler arasında arkadaş etkisinin de rolü olduğunu, alkol kullanan arkadaşların varlığının ve baskısının alkol kullanımına başlama, devam etme ve tekrarlamasında esas faktör olduğunu ifade etmişlerdir (Köknel, 2001; Drobes, 2002). Çalışmamızda da benzer olarak arkadaş ısrarının ve alkol kullanan arkadaş sayısının alkol kullanımı üzerinde önemli etkisinin olduğu, arkadaş ısrarı (OR=1.557; p=0.004) ve alkol kullanan arkadaş sayısı (OR=2.441; p<0.001) arttıkça alkol kullanım oranında da artış olduğu bulundu. Öncü vd. (2001) alkol kültürünü inceledikleri makalelerinde, dini inançların alkol kullanımı üzerinde önemli etkisinin olduğunu bildirmişlerdir. Çalışmamızda da dinin önemini (hiç, biraz, önemli, çok önemli) sorguladığımızda öğrencilerin dine verdikleri önem arttıkça, alkol kullanım oranının azaldığı (OR=0.454; p<0.001) bulundu. Heşeminia vd. (2002) yurtlarda kalan öğrenciler üzerinde yaptıkları çalışmada annenin eğitim düzeyi ile alkol kullanımı arasında ilişki olduğunu, annenin eğitim düzeyi yükseldikçe alkol kullanma oranının da arttığını ve cinsiyet ile alkol kullanımı arasındaki ilişki değerlendirildiğinde ise erkek öğrencilerin kız öğrencilere göre daha yüksek oranda alkol kullandıklarını; Kirkcaldy vd. (2004) ortaokul ve lisede okuyan öğrencilerin alkol kullanımını etkileyen değişkenlerin belirlenmesi amacıyla yaptıkları çalışmalarında cinsiyetin alkol kullanımı üzerinde önemli etkisinin olduğunu belirlemişlerdir. Yaptığımız çalışmada ise öğrencilerin annelerinin eğitim düzeylerinin ve cinsiyetin alkol kullanımı üzerinde önemli etkisinin olmadığı bulundu. Türkcan (2002) yaptığı çalışmada alkol bağımlılığının gelişiminde beyin hücrelerinin alkolün varlığına uyum yapmasının rolü olduğunu ve kitap okuma, spor, yemek yeme ve çeşitli hobilerle ilgili uğraşların alkol kullanma isteğinin sıklığı ve şiddetini azalttığını belirtmiştir. Çalışmamızda ise öğrencilerin ders dışındaki uğraşlarını sorgulayan *üniversitedeki sosyal etkinliklere katılma, ders dışındaki zamanlarda bir müzik aleti çalma, bir spor kulübüne üye olma, ders dışındaki zamanlarda bazı dernek faaliyetlerine katılma* değişkenlerinin alkol kullanımı üzerinde önemli etkilerinin olmadığı, buna karşın *ders dışındaki zamanlarda bar, disko, kafe ya da kahvehaneye gitme* değişkeninin alkol kullanımı üzerinde önemli etkisinin olduğu ve ders dışındaki zamanlarda bar, disko, kafe ya da kahvehaneye gidenlerin gitmeyenlere göre alkol kullanım oranının daha fazla olduğu (OR=1.920; p=0.013) bulundu.

Beyin bölgeleri ve alkol kullanımı ile yapılan çalışmalarda alkol kullanımının yansıttığı dürtüsel ve antisosyal davranışlar, heyecan ve yenilik arayışı, asilik ve bir çok kişilik özelliğindeki eksikliklerin orbitofrontal disfonksiyondaki yetersizliklerden kaynaklandığı; özellikle 25 yaşından önce başlayan alkol bağımlısı bireylerde dışa dönüklük ve dürtüsel davranışın daha fazla olduğu; orbitofrontal lob işlev görme

olgunlaşmasında gecikme olan bireylerin alkol bağımlılığına daha fazla eğilimli olduğunu, ayrıca orbitofrontal lob işlevlerindeki bozulmanın impuls kontrolündeki bozulmaya yol açtığını ve birey dürtülerinin yerine getirilmesini istediği için alkol kullanma isteğinin dışavurumunun daha fazla oranda olduğu bildirilmiştir (Akvardar, 2003; Türkcan, 2002; Dinn, 2004). Çalışmamızda da alkol kullanan ve kullanmayan öğrencilerin kişilik özelliklerini belirlemek için bazı frontal lob sendromlarıyla birleştirilmiş davranışları gösteren Frontal Lob Kişilik Ölçeği'nden elde edilen faktörlerden *dürtüsellik* faktörünün *alkol kullanımı* üzerinde önemli etkiye sahip olduğu, alkol kullanan öğrencilerde dürtüsel davranışların daha fazla olduğu (OR=1.826; p<0.001) bulundu.

Farklı uygulama alanları ve farklı veri setlerinde LR ile YSA'nın karşılaştırıldığı bazı çalışmalarda, LR ile YSA'nın benzer sonuçlar verdiği ve bu nedenle YSA'nın LR yerine tercih edilmesinin bir avantajı olmadığına karar vermişlerdir (Rowland vd, 1998; Ottenbacher vd, 2001; Ottenbacher vd, 2004). LR ve YSA'nın farklı sonuçlar verdiği çalışmalarda ise kullandıkları veri setinde YSA modelinin tahmin performansının LR modelinden daha iyi olduğu bulunmuştur (Hajmeer and Basheer, 2003; Dreiseitl and Ohno-Machado 2002; Nguyen vd, 2002; Remzi vd, 2003; Ergün vd, 2004; Türe vd, 2003; Yamamura vd, 2004; Manel vd, 1999). Yaptığımız çalışmada *ders dışındaki zamanlarda bar, disko, kafe ya da kahvehaneye gitme, dinin önem düzeyi, alkol kullanan arkadaş sayısı, alkol içmesi için arkadaşların ısrar düzeyi ve dürtüsellik* değişkenleri bakımından öğrencilerin alkol kullanıp kullanmama durumlarına göre sınıflandırılmasında LR ile YSA ve YSA'lar kendi aralarında karşılaştırıldığında; LR, L-L ve L-HT fonksiyonlu YSA'ların ROC eğrisi altında kalan alanlarının birbirinden istatistiksel olarak farklı olmadığı; HT-HT ve HT-L fonksiyonlu YSA'ların ROC eğrisi altında kalan alanlarının LR, L-L ve L-HT fonksiyonlu YSA'lardan daha büyük olduğu; HT-HT ve HT-L fonksiyonlu YSA'ların ROC eğrisi altında kalan alanları birbiriyle karşılaştırıldığında istatistiksel olarak farklı olmadığı bulundu.

YSA'nın LR'ye karşı avantaj ve dezavantajları incelendiğinde:

1. LR, bağımlı değişken üzerinde etkisi olan değişkenleri modele alarak etkili olmayan değişkenleri eleyebilme yeteneğine sahiptir. YSA ise etkisi olmayan değişkenleri modelden çıkarmaz.
2. LR'de veri setinin ikiye ayrılması zorunluluğu yoktur. YSA'da ise aşırı uyumdan kaçınmak için durdurma kriteri olarak verilerin en az %10'unun test setine ayrılması gerekir. Bu durum da veri seti hacminin azalmasına neden olur.
3. LR sadece lojistik fonksiyonu kullanan istatistiksel modelleme yöntemidir. YSA'da ise araştırmacı, amacına göre farklı YSA'lar oluşturma, kullanacağı yapay sinir ağını kendisi tasarlayabilme ve farklı tasarımları deneyerek veriye en uygun ağı oluşturabilme özgürlüğüne sahiptir.
4. LR ile uygun modelin bulunması bilgisayarla çok kısa zamanda gerçekleşebilir. YSA'da veriye en uygun modele karar verilmesi süreci çok fazla bilgisayar zamanı gerektirmektedir.
5. LR ile oluşturulan modelin yapısı YSA'ya göre daha basittir. Çok karmaşık olan yapısı nedeniyle YSA'da, model oluşturma ve sonuçların değerlendirilmesi aşamaları, mutlaka bu konuda yeterli bilgiye sahip uzman kişilerden yardım alınarak yapılabilir.

6. LR, modelin parametre tahminleri ve OR değerleri hakkında detaylı bilgi verir. YSA modelinin gizli tabaka sayısı ve gizli nöron sayısı fazla olduğunda parametre tahminlerinin yorumlanması zorlaşır ve aynı zamanda OR değerleri hakkında bilgi vermez.

5. SONUÇLAR

Bu çalışmada alkol kullanan ve kullanmayan öğrencilerin sınıflandırılmasında ROC eğrisi yöntemine göre HT-HT fonksiyonlu yapay sinir ağı ile HT-L fonksiyonlu yapay sinir ağının ROC eğrisi altında kalan alanları arasındaki farkın anlamsız olduğu ve bu modellerin sınıflandırma performanslarının diğer modellerden daha iyi olduğu sonucuna varıldı.

Bu sonuçlar ışığında:

1. Sağlık alanında çalışacak ve yeri geldiğinde hastaları alkol, sigara veya madde bağımlılığından kurtarmak için tedavi yöntemleri geliştirmede uğraş vermesi gereken konumda olan geleceğin doktorlarını alkol, sigara veya madde bağımlılığı bakımından öğrencilik döneminde bilinçlendirecek eğitim programları, bağımlılıktan kaynaklanan kişilik yapılarındaki bozuklukların iyileştirilmesi için tedavi programları hazırlanmalı ve yaşam tarzlarını daha sağlıklı hale getirecek olanaklar sağlanmalı; tıp fakülteleri öğrencileri yanında ulusal düzeyde tüm üniversiteler ve fakülteler arası öğrenciler alkol, sigara ve madde bağımlılığı gibi kötü alışkanlıklar yönünden izlenmeli, bunlara yol açan sorunların saptanması için ileriye dönük çalışmalar yapılmalıdır.

2. Alkol, sigara ve madde kullanımına neden olan sorun genellikle tek nedene bağlı olmadığı için alkol, sigara ve madde kullanım nedenleri bir arada ele alınıp bu sorunu tanımlayan ve nedenlerin etkileri hakkında bilgi veren çok değişkenli istatistiksel yöntemler kullanılarak gelecekte bu konuda yapılacak çalışmalara ışık tutması için istatistiksel modelleme çalışmaları yapılmalı ve daha iyi tahminleme yapılması için değişik modellerle incelenmelidir.

3. LR, modelin parametre tahminleri ve OR değerleri hakkında bilgi vermesi ve sonuçlarının kolay yorumlanabilir olması açısından YSA'dan daha avantajlıdır. Bu nedenle eğer uygulama sonucunda YSA'nın sınıflandırma performansı LR'den kötü ise LR modeli tercih edilmelidir. Eğer YSA'nın performansı LR'den daha iyi ise önemsiz değişkenlerin modelden çıkarılmasında LR YSA için bir ön eleme yöntemi olarak kullanılmalıdır.

4. Karmaşık yapısı nedeniyle YSA'nın oluşturulma ve değerlendirilme aşamaları, yeterli bilgi ve deneyime sahip uzman kişiler tarafından yapılmalıdır.

KAYNAKLAR

- AKVARDAR, Y. (2003), *Alkol bağımlılığında kişilik özellikleri*, Bağımlılık Dergisi, 4(1), 26-30.
- ARMITAGE, P., BERRY, G. (1994), *Statistical methods in medical research*, USA: Blackwell Science Ltd.
- AYCICEGI, A., DINN, W.M., HARRIS, C.L. (2003), *Prefrontal lob nöropsikolojik test bataryası: sağlıklı yetişkinlerden elde edilen test sonuçları*, Psikoloji Çalışmaları, 23, 1-26.
- CHO, H. (2003), *Neural network*, Erişim:[<http://msi.postech.ac.kr/course/ie723/neural-1.pdf>]. Erişim Tarihi: 20.03.2003
- DİRİCAN, A. (2001), *Evaluation of the diagnostic test's performance and their comparisons*, Cerrahpaşa J Med, 32, 25-30.
- DREISEITL, S., OHNO-MACHADO, L. (2002), *Logistic regression and artificial neural network classification models: a methodology review*, Journal of Biomedical Informatics, 35, 352-359.
- DINN, W.M., AYCICEGI, A., HARRIS, C.L. (2004), *Cigarette smoking in a student sample: Neurocognitive and clinical correlates*, Addictive Behaviors, 29, 107-126.
- DROBES, J. (2002), *Concurrent alcohol and tobacco dependence mechanisms and treatment*, Alcohol Research & Health, 26(2), 136-142.
- EFE, Ö., KAYNAK, O. (2000), *Yapay sinir ağları ve uygulamaları*, İstanbul: Boğaziçi Üniversitesi.
- ERGÜN, U., SERHATLIOĞLU, S., HARDALAÇ, F., GÜLER, İ. (2004), *Classification of carotid artery stenosis of patients with diabetes by neural network and logistic regression*, Computers in Biology and Medicine (In press).
- FRANCIS, L. (2001), *The basics of neural networks demystified*, Contingencies November/December, 56-61.
- GAUDART, J., GIUSIANO, B., HUIART, L. (2004), *Comparison of the performance of multi-layer perceptron and linear regression for epidemiological data*, Computational Statistics & Data Analysis, 44, 547-570.
- HAJMEER, M., BASHEER, I. (2003), *Comparison of logistic regression and neural network-based classifiers for bacterial growth*, Food Microbiology, 20, 43-55.
- HANLEY, J.A., MCNEIL, B.J. (1982), *The meaning and use of the area under a receiver operating characteristic (ROC) curve*, Radiology, 143(1), 29-36.
- HANLEY, J.A., MCNEIL, B.J. (1983), *A method of comparing the areas under receiver operating characteristic curves derived from the same cases*, Radiology, 148(3), 839-843.

- HASSOUN, M.H. (c1995), *Fundamentals of artificial neural networks*, Cambridge, Mass:MIT Press.
- HAYKIN, S. (1999). *Neural network: a comprehensive foundation*, Upper Saddle River, NJ: Prentice Hall.
- HEŞEMİNİA, T., ÇALIŞKAN, D., IŞIK, A. (2002), *Ankara'da yüksek öğretim öğrenci yurtlarında kalan öğrencilerin beslenme sorunları*, İbni Sina Tıp Dergisi, 7, 155-166.
- HOSMER, D.W., LEMESHOW, S. (2000), *Applied logistic regression*, New York: John Wiley & Sons.
- KIRKCALDY, B.D., SIEFEN, G., SURALL, D., BISCHOFF, R.J. (2004), *Predictors of drug and alcohol abuse among children and adolescents*, Personality and Individual Differences, 36, 247-265.
- KLEINBAUM, D.G. (1994), *Logistic regression: a self-learning text*, New York: Springer-Verlag.
- KÖKNEL, Ö. (2001), *Alkol ve madde bağımlılığı altkültürü*, Bağımlılık Dergisi, 2(2) [http://www.bagimlilik.net/sayi4/alkol_alkulturu.pdf].
- KROSE, B., SMAGT, P. (1996), *An introduction to neural networks*, Amsterdam: The University of Amsterdam.
- KURT, İ., TÜRE, M., SÜT, N., YAVUZ, E. (2002), *Sinir ağları ile sistolik kan basıncı değerlerinin tahmini*. Diyarbakır: 6. Biyoistatistik Kongresi.
- MANEL, S., DIAS, J.M., ORMEROD, S.J. (1999), *Comparing discriminant analysis, neural networks and logistic regression for predicting species distributions: a case study with a Himalayan river bird*, Ecological Modelling, 120, 337-347.
- MCCLISH, D.K. (1987), *Comparing the areas under more than two independent ROC curves*, Med Decis Making, 7, 149-155.
- NASR, G.E., BADR, E.A., JOUN, C. (2003), *Backpropagation neural networks for modeling gasoline consumption*, Energy Conversion & Management, 44, 893-905.
- NGUYEN, T., MALLEY, R., INKELIS, S.H., KUPPERMANN, N. (2002), *Comparison of prediction models for adverse outcome in pediatric meningococcal disease using artificial neural network and logistic regression analyses*, Journal of Clinical Epidemiology, 55, 687-695.
- OTTENBACHER, K.J., SMITH, P.M., ILLIG, S.B., LINN, R.T., FIELDER, R.C., GRANGER, C.V. (2001), *Comparison of logistic regression and neural networks to predict rehospitalization in patients with stroke*, Journal of Clinical Epidemiology, 54, 1159-1165.
- OTTENBACHER, K.J., LINN, R.T., SMITH, P.M., ILLIG, S.B., MANCUSO, M., GRANBER, C.V. (2004), *Comparison of logistic regression and neural network analysis applied to predicting living setting after hip fracture*, Ann Epidemiol (In press).
- ÖNCÜ, F., ÖGEL, K., ÇAKMAK, D. (2001), *Alkol kültürü-1: tarihsel süreç ve meyhane kültürü*, Bağımlılık Dergisi, 2(3) [http://www.bagimlilik.net/sayi5/alkol_kulturu1.pdf].

ÖZDAMAR, K. (1999), *Paket programlarla istatistiksel veri analizi-1*, Eskişehir: Kaan Kitabevi.

ÖZDAMAR, K. (2003), *SPSS ile biyoistatistik*, Eskişehir: Kaan Kitabevi.

REMZI, M., ANAGNOSTOU, T., RAVERY, V., ZLOTTA, A., STEPHAN, C., MARBERGER, M. et al. (2003), *An artificial neural networks to predict the outcome of repeat prostate biopsies*, *Adult Urology*, 62, 456-460.

ROJAS, R. (1991), *Neural networks: a systematic introduction*, Berlin: Springer.

ROWLAND, T., OHNO-MACHADO, L., OHRN, A. (1998), *Comparison of multiple prediction models for ambulation following spinal cord injury*, *Proc. AMIA Annual Symposium: 1998 November 7-11; Orlando, FL, USA*, 528-532.

SHARMA, S. (1996), *Applied multivariate techniques*, New York: John Wiley & Sons.

SUNDARARAJAN, N., SARATCHANDRAN, P. (1998), *Parallel architectures for artificial neural networks: paradigms and implementations*, California: IEEE Computer Society Press.

SWAVING, M., VAN HOUWELINGEN, H., OTTES, F.P., STEERNEMAN, T. (1996), *Statistical comparison of ROC curves from multiple readers*, *Med Decis Making*, 16, 143-152.

TATLIDİL, H. (1996), *Uygulamalı çok değişkenli istatistiksel analiz*, Ankara: Akademi Matbaası.

TU, J.V. (1996), *Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes*, *J Clin Epidemiol*, 49(11), 1225-1231.

TÜRE, M., KURT, İ., YAVUZ, E. (2003), *Comparison of multiple prediction models for degree of arter stenosis determined angiographically*, In: Fredman L, Burgut R, Dafni U (Eds.) *EMR 2003. The Second International Biometric Society Conference of The Eastern Mediterranean Region: 2003 January 12-15; Antalya, Türkiye*.

TÜRKCAN, A. (2002), *Alkol kullanma isteğinin (craving) mekanizması*, *Bağımlılık Dergisi*, 3(1), 37-42.

YAMAMURA, S., KAWADA, K., TAKEHIRA, R., NISHIZAWA, K., KATAYAMA, S., HIRANO, M. et al. (2004), *Artificial neural network modeling to predict the plasma concentration of aminoglycosides in burn patients*, *Biomedicine & Pharmacotherapy* (In press).

COMPARISON OF ARTIFICIAL NEURAL NETWORKS AND LOGISTIC REGRESSION ANALYSIS

ABSTRACT

In this study, the factors that affect students' alcohol use behaviors were examined by Logistic Regression Analysis and Artificial Neural Networks. In order to evaluate their success on separation of alcohol user and non-user students, these methods' performance were compared using ROC curve method.

In our study, in order to determine severity of alcohol use among 1, 2, 3 and 4th year students in Trakya University Medical Faculty, 2003-2004, a questionnaire concerning alcohol to predict alcohol use behaviors and Frontal Lobe Personality Scale were performed.

Logistic Regression and four different Artificial Neural Networks models were. Logistic Regression Analysis showed that the following variables effect alcohol use behaviors of students considerably high: to go to bar, disco or café in their spare time (OR=1.920; $p<0.05$), importance level of religion (OR=0.454; $p<0.001$), the number of alcohol user friends (OR=2.441; $p<0.001$), the insistence of friends on drinking alcohol (OR=1.557; $p<0.01$) and impulsivite (OR=1.826; $p<0.001$). When Logistic Regression Analysis with Artificial Neural Networks and Artificial Neural Networks each other were compared, there is no difference were observed that the area under the ROC curves of hyperbolic tangent-hyperbolic tangent function and hyperbolic tangent-logistic function Artificial Neural Networks but these models have statistically larger areas than the other models.

We could summarize the results of this study as follows: researchers are necessary to take into account advantages and disadvantages of Artificial Neural Networks and Logistic Regression in the classification and modeling, and Logistic Regression Analysis may also use as an elimination methods (in order to eliminate insignificant variables of Logistic Regression) Analysis in Artificial Neural Networks.

Key Words: *Frontal Lobe Personality Scale, Logistic Regression Analysis, Artificial Neural Networks, Backpropagation Algorithm, Receiver Operating Characteristic (ROC) Curve*