

**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MEDİKAL TEŞHİSTE GRNN KULLANIMI
VE DEVRE BLOKLARININ TASARIMI**

Elektronik ve Haberleşme Mühendisi Revna ACAR

F.B.E. Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Elektronik Programında Hazırlanan

YÜKSEK LİSANS TEZİ

Tez Danışmanı : Doç. Dr. Tülay YILDIRIM (YTÜ)



Prof. Dr. Halit PAŞTAÇ 
Yrd. Doç. Dr. Lale Özyılmaz 

İSTANBUL, 2004

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	iv
KISALTMA LİSTESİ	v
ŞEKİL LİSTESİ	vi
ÇİZELGE LİSTESİ	vii
ÖNSÖZ	viii
ÖZET	ix
ABSTRACT	x
1 GİRİŞ	1
2 GENELLEŞTİRİLMİŞ REGRESYON AĞI	3
2.1 Genelleştirilmiş Regresyon	3
2.2 Genelleştirilmiş Regresyon Ağı Yapısı	5
2.3 Genelleştirilmiş Regresyon Ağı Yapısının Avantajları	7
3 GENELLEŞTİRİLMİŞ REGRESYON AĞININ MEDİKAL PROBLEMLERE UYGULANMASI	8
3.1 Kontakt Lens Problemi	9
3.2 Akciğer Kanseri Problemi	10
3.3 Pima-Indian Diyabet Problemi	12
3.4 Fetus Gelişimi Problemi	13
3.5 Göğüs Kanseri Problemi	15
3.6 Erythemato-Squamous Problemi	17
4 GENELLEŞTİRİLMİŞ REGRESYON AĞININ ALT BLOKLARININ TASARIMI	20
4.1 Çıkarma Devresi	22
4.1.1 Çıkarma Devresinin CMOS'larla Gerçekleştirilmesi	23
4.1.2 Çıkarma Devresinin Lineer Bölgede Çalışma Koşulları (DC Analiz)	23
4.2 Kare Alma/Bölme Devresi	24
4.2.1 Kare Alma/Bölme Devresinin CMOS'larla Gerçekleştirilmesi	24
4.2.2 Kare Alma/Bölme Devresinin Lineer Bölgede Çalışma Koşulları (DC Analiz)	27
4.3 Üstel Fonksiyon Devresi	28
4.3.1 Üstel Fonksiyon Devresinin CMOS'larla Gerçekleştirilmesi	29
4.3.2 Üstel Fonksiyon Devresinin Lineer Bölgede Çalışma Koşulları (DC Analiz)	31
4.4 Çarpma/Bölme Devresi	32
4.4.1 Çarpma/Bölme Devresinin CMOS'larla Gerçekleştirilmesi	32

4.4.2	Çarpma/Bölme Devresinin Lineer Bölgede Çalışma Koşulları (DC Analiz)	34
5	SONUÇ	35
	KAYNAKLAR.....	36
	EKLER	38
Ek 1	Kontakt Lens Problemi İçin Veritabanı	39
Ek 2	Akciğer Kanseri Problemi İçin Veritabanı.....	40
Ek 3	Pima-Indian Diyabet Problemi İçin Veritabanı	41
Ek 4	Fetus Gelişimi Problemi İçin Veritabanı	48
Ek 5	Göğüs Kanseri Problemi İçin Veritabanı	50
Ek 6	Erythemato-Squamous Problemi İçin Veritabanı.....	56
Ek 7	Çıkarma Devresi İçin TSPICE Simülasyon Dosyası.....	62
Ek 8	Kare Alma/Bölme Devresi İçin TSPICE Simülasyon Dosyası.....	63
Ek 9	Üstel Fonksiyon Devresi İçin TSPICE Simülasyon Dosyası.....	64
Ek 10	Çarpma/Bölme Devresi İçin TSPICE Simülasyon Dosyası.....	65
	ÖZGEÇMİŞ.....	66

SİMGE LİSTESİ

σ	Kernel fonksiyonu genişliği
D	Veri kümesi boyut sayısı
$f(x)$	Aktivasyon fonksiyonu
i	Eğitim örnek vektörü sayısı indeksi
j	Boyut indeksi
p	Örnek katmanında depolanan eğitim örnek vektörü sayısı



KISALTMA LİSTESİ

ADC	Analog Digital Converter
ASIC	Application Specific Integrated Circuit
CMOS	Complementary Metal Oxide Semiconductor
DAC	Digital Analog Converter
GRNN	General Regression Neural Network
LMS	Least Mean Squares
MLP	Multilayer Perceptron
MOSFET	Metal Oxide Semiconductor Field Effect Transistor
Pdf	Probability Density Function
PI	Pulsatility Index
RI	Resistance Index
S/D	Systolic/Diastolic Ratio
UA	Umbilical Artery
VLSI	Very Large Scale Integrated
W/L	Weight/Length Ratio
WI	Week Index
YSA	Yapay Sinir Ağı



ŞEKİL LİSTESİ

Şekil 2.1	Genelleştirilmiş Regresyon Ağı Yapısı.....	6
Şekil 4.1	GRNN Devre Yapısı Blok Diyagramı	21
Şekil 4.2	Akım Aynası.....	22
Şekil 4.3	Çıkarma devresi	23
Şekil 4.4	Çıkarma devresinin çıkış akımının ($ID(M7)$) ve (I_A-I_B) fonksiyonun I_B akımına göre değişimi.....	24
Şekil 4.5	Kare alma/bölme devresi.....	25
Şekil 4.6	Kare alma/bölme devresinin çıkış akımının ($ID(M13)$) ve (I_X^2/I_H) fonksiyonunun I_X akımına göre değişimi.....	27
Şekil 4.7	Üstel fonksiyon ile üstel fonksiyonun Taylor açılımının karşılaştırılması	29
Şekil 4.8	Üstel fonksiyon devresi	30
Şekil 4.9	Üstel fonksiyon devresinin çıkış akımının ($ID(M14)$) ve ($1-I_X+(I_X)^2/2$) fonksiyonunun I_X akımına göre değişimi.....	31
Şekil 4.10	Çarpma/bölme devresi.....	33
Şekil 4.11	Çarpma/bölme devresinin çıkış akımının $I(R)$ ve ($(I_{X1})^2-(I_{X2})^2/(4*I_E)$) fonksiyonunun I_X akımına göre değişimi.....	34

ÇİZELGE LİSTESİ

Çizelge 3.1	Lens veritabanı için alt kümelere ait örnek sayısı.....	9
Çizelge 3.2	Lens veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı.....	10
Çizelge 3.3	Akciğer kanseri veritabanı için alt kümelere ait örnek sayısı.....	11
Çizelge 3.4	Akciğer kanseri veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı.....	11
Çizelge 3.5	Pima-Indian diyabet veritabanı için alt kümelere ait örnek sayısı	12
Çizelge 3.6	Pima-Indian diyabet veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı.....	13
Çizelge 3.7	Normalize edilmiş Pima-Indian diyabet veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı.....	13
Çizelge 3.8	Fetus gelişimi veritabanı için alt kümelere ait örnek sayısı.....	14
Çizelge 3.9	Fetus gelişimi veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı	15
Çizelge 3.10	Normalize edilmiş fetus gelişimi veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı.....	15
Çizelge 3.11	Göğüs kanseri veritabanı için alt kümelere ait örnek sayısı	16
Çizelge 3.12	Göğüs kanseri veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı	16
Çizelge 3.13	Erythemato-Squamous veritabanı için alt kümelere ait örnek sayısı	17
Çizelge 3.14	Erythemato-Squamous veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı.....	18
Çizelge 3.15	Normalize edilmiş Erythemato-Squamous veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı.....	19

ÖNSÖZ

Tezimin konusunun belirlenmesinde ve çalışmamın hazırlanmasında bana yardımcı olan Doç. Dr. Tülay Yıldırım'a, tez çalışmam sırasında yardımlarını esirgemeyen oda arkadaşlarım Burcu Kapanoğlu, Nihan Coşkun ve Tuba Kıyan'a ve her zaman moral destekleriyle yanımda olan aileme, Yasemin Div'e ve Cem Vural'a teşekkür ederim.

İstanbul, 2004

Revna ACAR



ÖZET

Genelleştirilmiş Regresyon Ağı (GRNN) sürekli değişkenlerin kestirimine olanak tanıyan ve temel regresyon yüzeyine yakınsayan hafıza tabanlı bir ağ yapısıdır. Tek adımda öğrenmeye dayalı bir algoritmaya sahip olmasından dolayı, iteratif yöntemle öğrenen ağ yapılarından çok daha hızlıdır. Ağda depolanan örnek sayısı arttıkça, optimum regresyon yüzeyine yakınsar ve kestirim hatası sıfıra yaklaşır. Bir yapay sinir ağının performansını belirleyen etkenler genelleştirme yeteneği, çok amaçlı kullanılıp kullanılamayacağı, ağ yapısının karmaşıklığı ve elektronik tasarıma uygun olup olmadığıdır.

GRNN yapısı sistem modelleme ve sistem tanıma uygulamalarında sıklıkla kullanılmıştır. Yapının büyük boyutlu veri kümeleri ile yüksek doğruluklu sonuçlar verme yeteneği, bu ağ yapısının medikal teşhis alanında da kullanılabileceğini göstermektedir. GRNN'in katmanlı, yüksek derecede paralel yapısı ve tek adımda eğitime gerçekleştirmesi, ağın hızlı öğrenmesini ve donanımsal tasarımının basitleşmesini sağlar.

Bu çalışmada GRNN yapısı çeşitli medikal problemlerin teşhisi üzerinde denenmiş ve yapının performansı incelenmiştir. Bu amaçla geliştirilebilecek GRNN tabanlı bir sınıflayıcı tasarımında kullanılacak akım modlu analog tümdevre alt blokları TÜBİTAK-YİTAL 1.5 μ CMOS proses parametreleri kullanılarak tasarlanmıştır. Bu alt bloklar sırasıyla çıkarma devresi, kare alma/bölme devresi, üstel fonksiyon devresi ve çarpma/bölme devresidir.

Anahtar kelimeler: Genelleştirilmiş regresyon ağı, Medikal teşhis, Çıkarma devresi, Kare alma/bölme devresi, Üstel fonksiyon devresi, Çarpma/bölme devresi.

ABSTRACT

Generalized Regression Neural Network (GRNN) is a memory-based network that provides estimates of continuous variables and converges to the underlying regression surface. Owing to one pass learning algorithm, GRNN is faster than iterative methods. The estimate converges to the conditional mean regression surfaces as more and more examples are stored in the network structure. Important parameters, which determine the performance of an artificial neural network are the ability of generalization, whether or not it can be used for several purposes, the complexity of the network and the suitability for electronic implementations.

GRNN structure is widely used in system modelling and system identification applications. Obtaining successful results with data sets that has large number of samples, shows that this structure can effectively be used in medical diagnosis. Layered and highly parallel structure with one-pass learning leads to fast training and a simpler hardware design.

In this work, GRNN structure is experimented on different medical problems and the performance is examined. For this purpose, using TÜBİTAK-YİTAL 1.5 μ CMOS process parameters, current mode analogue integrated circuit sub blocks of a GRNN based classifier that can possibly be developed designed. These sub blocks are subtracter circuit, squarer/divider circuit, exponential circuit and multiplier/divider circuit respectively.

Keywords: General regression neural network, Medical diagnosis, Subtractor circuit, Squarer/divider circuit, Exponential circuit, Multiplier/divider circuit.

1. GİRİŞ

Medikal teşhis alanında yapay sinir ağı (YSA) modellerinin kullanımı son yıllarda çok önem kazanmıştır. YSA, insanlardan daha hızlı çalışır. YSA ile elde edilen sonuçların doktorlar tarafından değerlendirilmesi ile onların karar verme süreleri kısaltılabilir. Bu da hem verimlilik hem de zaman açısından kazanç sağlar. Bilgilere ve potansiyel çözümlere ait tüm detayları gözden geçirdiği için uygun ağ yapısı ve öğrenme algoritması kullanıldığında güvenilir sonuçlar verir. Bu yeteneği sayesinde YSA, teşhis esnasında doktorların gözünden kaçan ayrıntıları yakalayabilir. Ayrıca karantina uygulamaları gereken bazı hastalıklarda, YSA kullanılarak daha az insanın sağlık açısından riskli ortamlarda bulunması sağlanabilir.

YSA medikal alanda, sadece teşhis için değil; aynı zamanda modelleme, işaret işleme, sistem kontrol ve sınıflandırma işlemleri için de kullanılmıştır. Probleme esnek bir şekilde adapte olma yeteneği; YSA yapısını, nitel farkları temel alan sınıflama problemlerinin çözümü için uygun hale getirmektedir (Papik vd, 1997).

Çeşitli sınıflama problemlerinin çözümünde YSA yapılarının donanımsal gerçeklemeleri kullanılmıştır. Kakadu (Leong ve Jabri, 1992; 1993) olarak adlandırılan analog VLSI YSA yapısı, uygulamalı biyomedikal sistemlerde kullanılmak üzere tasarlanmış; giriş katmanında 10, saklı katmanda 6, ve çıkış katmanında 4 nöron içeren bir çok katmanlı algılayıcıdır (multi-layer perceptron-MLP). ‘Off-chip’ olarak gerçekleştirilmiş bu yapının performansı kalp ritmindeki düzensizlikleri sınıflama problemi için denenmiş ve başarılı sonuçlar vermiştir. (Jabri vd, 1996)

Genelleştirilmiş Regresyon Ağı (General Regression Neural Network-GRNN) ilk olarak (Specht, 1991) tarafından tanımlanmıştır. GRNN, sürekli değişkenlerin kestirimine olanak tanıyan ve temel regresyon yüzeyine yakınsayan hafıza tabanlı bir ağ yapısıdır. Tek adımda öğrenmeye dayalı bir algoritmaya sahip olmasından dolayı, iteratif yöntemle öğrenen ağ yapılarından çok daha hızlıdır. Ağda depolanan örnek sayısı arttıkça, optimum regresyon yüzeyine yakınsar ve kestirim hatası sıfıra yaklaşır (Specht, 1991).

Genelleştirilmiş Regresyon Ağı’nın (GRNN) büyük boyutlu veri kümeleri ile yüksek doğruluklu sonuçlar verme yeteneği, bu ağ yapısının medikal alanda kullanılabileceğini göstermektedir. Medikal alanda incelenen pek çok problem büyük boyutlu veri kümelerinden oluşmaktadır ve iteratif öğrenmeye sahip ağ yapılarıyla bu verilerin incelenmesi daha uzun zaman almaktadır. Ancak çeşitli boyut küçültme işlemleri yardımıyla bu süre kısaltılabilmektedir. Oysa GRNN, yüksek ölçüde paralel yapısı ve hızlı genelleştirme

yeteneđi sayesinde büyük veri kümesine sahip medikal teşhis problemlerinde optimum çözüm sağlar. Ayrıca, MLP kullanılması durumunda, ağırlıkların rastgele başlatılmasından dolayı sonuçlar kararlı olmayacak ve algoritmanın birden fazla kere çalıştırılması sonucu ortalama bir sonuç elde edilecektir. GRNN’de her çalıştırmadan sonra aynı sonuç elde edilmektedir.

GRNN’in katmanlı, yüksek derecede paralel yapısı ve tek adımda eğitime gerçekleştirmesi ađın donanımsal tasarımının basitleşmesini sağlar. Yapıyı donanımsal olarak oluşturmak için öncelikle her katmanda gerçekleştirilen matematiksel işlemleri iyi anlamak ve bu işlemleri doğru olarak yapacak alt bloklar tasarlamak gerekir. Sınıflanacak veri kümesinin boyutuna bađlı olarak, her katman için bu alt blokların sayısı ayarlanabilir. Devrelerin dinamik çıkış aralığına bađlı olarak veri kümesi ölçeklenmelidir.

Bu tez, literatürde ağırlıklı olarak sistem tanıma ve sistem kontrolünde kullanılmış olan GRNN yapısının medikal teşhis alanında da kullanılabileceđi konusunda yoğunlaşmıştır. Bu amaçla geliştirilebilecek GRNN tabanlı bir sınıflayıcı tasarımında kullanılacak tümdevre alt blokları tasarlanmıştır.

Bölüm 2’de genelleştirilmiş regresyon yaklaşımı ve GRNN ađ yapısı tanıtılmıştır.

Bölüm 3’te GRNN yapısı çeşitli medikal problemlerin sınıflandırılması üzerinde denenmiştir. Bu problemlerin veri kümelerinin GRNN kullanılarak sınıflandırılması sonucu elde edilen başarı, normalizasyon uygulanan veri kümelerinde elde edilen sınıflama başarıları ile karşılaştırılmıştır. Bu problemlerden kontakt lens ve fetus gelişimi problemi daha önce Konik Kesit Fonksiyonlu YSA yapısı kullanılarak incelenmiştir (Özyılmaz, 2000). (Kayaer ve Yıldırım, 2003) Pima-Indian diyabet problemi için çeşitli YSA yapıları denemiş ve en yüksek doğruluđu GRNN yapısı kullanarak elde etmişlerdir. Göğüs kanseri veritabanı ile yapılan çalışmalarda da istatistiksel YSA yapılarının yüksek sınıflama başarıları gösterdiđi görülmüştür (Kıyan ve Yıldırım, 2003). Son medikal problem olan Erythemato-Squamous hastalığının farklı tiplerinin sınıflandırılması için MLP yapısı kullanılmış ve sonuçlar problemin üzerinde daha önce denenmiş olan genetik algoritma, sinirsel bulanık sistemi ve Voting Feature Intervals (VFI) algoritması sonuçları ile karşılaştırılmıştır (Acar ve Yıldırım, 2004).

Bölüm 4’te medikal alanda kullanılabilecek GRNN tabanlı bir sınıflayıcı yapısını oluşturan alt bloklar YİTAL 1.5µ CMOS proses parametreleri kullanılarak tasarlanmıştır. TSPICE simülatör programı kullanılarak bu blokların simülasyonları yapılmış ve DC analiz sonucunda performansları gözlenmiştir. Sonuç olarak Bölüm 5’te çalışma süresince elde edilen sonuçlar yorumlanmıştır.

2. GENELLEŞTİRİLMİŞ REGRESYON AĞI

Genelleştirilmiş Regresyon Ağı (General Regression Neural Network-GRNN) ilk olarak (Specht, 1991) tarafından tanımlanmıştır. GRNN, sürekli değişkenlerin kestirimine olanak tanıyan ve temel regresyon yüzeyine yakınsayan hafıza tabanlı bir ağ yapısıdır. Tek adımda öğrenmeye dayalı bir algoritmaya sahip olmasından dolayı, iteratif yöntemle öğrenen ağ yapılarından çok daha hızlıdır. Ağda depolanan örnek sayısı arttıkça, optimum regresyon yüzeyine yakınsar ve kestirim hatası sıfıra yaklaşır (Specht, 1991). Bu bakımdan regresyon, mevcut dataya dayanan değişkenlerin ortalama en küçük kareler (Least Mean Squares-LMS) kestirimi olarak tanımlanabilir (Seng vd, 2002). GRNN, hızlı ve sürekli öğrenme yeteneği sayesinde dinamik sistem tanıma (Seng vd, 2002), sinirsel bulanık (neuro-fuzzy) kontrol sistemlerinin tasarımı (Seng vd, 1999; Zhang ve Suthaharan, 1997; Amaral, 2001), lineer olmayan adaptif kontrol (Schaffner ve Schröder, 1993) ve güç sistemlerinin analizi (Patton ve Ilic, 1993) gibi çeşitli endüstriyel uygulamalarda kullanım alanı bulmuştur.

2.1 Genelleştirilmiş Regresyon Yaklaşımı

Bağımlı değişken y 'nin x üzerindeki regresyonu, x 'in her değeri için y 'nin mümkün olan her değerinin hesaplanmasıdır. Bu da x 'in mümkün gürültülü ölçümlerinin sonlu sayısı ve ilgili y değerlerine dayanır. Söz konusu x ve y değerleri genellikle vektördür. Lineer regresyonda çıkış y , giriş x 'in lineer bir fonksiyonu olarak kabul edilir ve bilinmeyen parametreler olan a_i 'ler lineer katsayılar olarak tanımlanır. Burada tanıtılan yaklaşım, belirli fonksiyonel form tahmininin gerekliliğinden vazgeçip olasılık yoğunluk fonksiyonu (probability density function-pdf) şeklinde ifade edilen bir forma olanak tanır. Bu fonksiyon, Parzen pencere yaklaşımını kullanarak, deneysel olarak elde edilen datadan belirlenir. Böylelikle bu yaklaşım herhangi bir form tarafından sınırlanmamıştır ve uygun forma ait ön bilgi gerektirmez. (Specht, 1991)

Eğer x 'in ve y 'nin ortak pdf'i bilinirse, şartlı pdf ve beklenen değer hesaplanabilir. Burada, ortak pdf, parametrik olmayan kestirimciler kullanan örnek tarafından kestirilir. Sonuçtaki regresyon bağıntısı, paralel, yapay sinir ağı benzeri yapıda tamamlanır. Yapının parametreleri örneklerden direk olarak elde edildiğinden (iteratif değil), yapı öğrenir ve bir an önce genellemeye başlar. Paralel yapıyla tamamlanır ki, ayrıca x 'in yeni değeri için y değerlerini, yapay sinir ağının 4 katmanı boyunca yayılım zamanı ile belirlenen süre zarfında tahmin eder. (Specht, 1991)

Rasgele vektörel değişken x ile rasgele skaler değişken y 'nin bilinen birleşik sürekli pdf'ini temsil eden bir $f(x,y)$ fonksiyonunu ele alalım. X , rasgele değişken x 'in belirli ölçülmüş değeri olsun. Verilen X için y 'nin şartlı ortalaması (aynı zamanda y 'nin X üzerindeki regresyonu) (2.1) eşitliğinde verilmiştir. (Specht, 1991)

$$E[y/X] = \frac{\int_{-\infty}^{\infty} yf(X,y)dy}{\int_{-\infty}^{\infty} f(X,y)dy} \quad (2.1)$$

Eğer $f(x,y)$ yoğunluğu bilinmiyorsa, x ve y 'nin örnek gözlemlerinden kestirilebilir. Bu durumda Parzen tarafından önerilmiş uygun kestirim sınıfı, $f(x,y)$ 'nin parametrik olmayan yaklaşımı için kullanılacaktır. Cacoullos tarafından da bu sınıfın çok boyutlu durumlara uygulanabildiği gösterilmiştir. Eğer temel yoğunluk sürekli ve her x değerinde hesaplanan fonksiyonun ilk kısmi türevleri küçük olarak kabul edilirse, bu kestirimciler pdf tahmininde iyi bir seçimdir. (Specht, 1991)

Olasılık kestirimci $\hat{f}(X,Y)$, x ve y 'nin rasgele değişkenleri olan X^i ve Y^i örnek değerlerine dayanmaktadır. (2.2)'de n , örnek gözlem sayısı ve p ise vektörel değişken X 'in boyutudur. (Specht, 1991)

$$\hat{f}(X,Y) = \frac{1}{2\pi^{(p+1)/2} \sigma^{(p+1)}} \cdot \frac{1}{n} \cdot \sum_{i=1}^n \exp\left[-\frac{(X-X^i)^T(X-X^i)}{2\sigma^2}\right] \cdot \exp\left[-\frac{(Y-Y^i)^2}{2\sigma^2}\right] \quad (2.2)$$

$\hat{f}(X,Y)$ olasılık kestiriminin fiziksel açıklaması şudur: Her örnek X^i ve Y^i için σ genliğinin örnek olasılığı aynı atanır ve olasılık tahmini bu örnek olasılıkların toplamıdır.

(2.2)'deki birleşik olasılık kestirimi $\hat{f}$ 'i (2.1)'deki şartlı ortalamanın yerine koyarsak, verilen X için y 'nin şartlı ortalamasını elde ederiz. (2.1) ve (2.2)'yi birleştirip integral ve toplamayı yer değiştirirsek, istenen şartlı ortalamayı elde etmiş oluruz. Bu da $\hat{Y}(X)$ olarak adlandırılır. (Specht, 1991)

$$\hat{Y}(X) = \frac{\sum_{i=1}^n \exp\left[-\frac{(X - X^i)^T (X - X^i)}{2\sigma^2}\right] \cdot \int_{-\infty}^{\infty} y \exp\left[-\frac{(Y - Y^i)^2}{2\sigma^2}\right] dy}{\sum_{i=1}^n \exp\left[-\frac{(X - X^i)^T (X - X^i)}{2\sigma^2}\right] \cdot \int_{-\infty}^{\infty} \exp\left[-\frac{(Y - Y^i)^2}{2\sigma^2}\right] dy} \quad (2.3)$$

Skaler fonksiyon,

$$D_i^2 = (X - X^i)^T (X - X^i) \quad (2.4)$$

olarak tanımlanır ve (2.3)'te yerine konursa (2.5) eşitliği elde edilir.

$$\hat{y}(X) = \frac{\sum_{i=1}^n y^i \cdot \exp\left(-\frac{D_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{D_i^2}{2\sigma^2}\right)} \quad (2.5)$$

(2.5)'den hesaplanan ve gözlemler üzerindeki toplamaları içeren regresyon sonucu, nümerik veri içeren bütün problemlere uygulanabilir. (Specht, 1991)

2.2 Genelleştirilmiş Regresyon Ağı Yapısı


GRNN, 4 katmanlı bir yapıdır. Bu katmanlar sırasıyla, giriş katmanı, örnek katmanı, toplama katmanı ve çıkış katmanıdır (Şekil 2.1).

Giriş katmanı, D boyutlu X değişkenlerinden oluşan giriş vektörünü örnek katmanına iletir. Burada boyut kelimesi ağı giriş olarak sunulan veri kümesinin özellik sayısını belirtmektedir. Örnek katmanı ise bir kümeleme merkezi olarak p adet, (1xD) boyutunda eğitim vektörü depolar. Ağı yeni bir X giriş vektörü sunulduğunda, bu vektördeki her j. örnek ile örnek katmanında tutulan p adet eğitim vektörünün j. eğitim örneğinin farkı alınır. İki örnek arasındaki mesafeyi hesaplamak için bu farkın karesi veya mutlak değeri alınarak σ değerine bölünür (Specht, 1991).

$$d_i = -\sum_{j=1}^D \frac{(X_j - X_{ij})^2}{2\sigma^2} \quad (2.6)$$

Kernel fonksiyonunun genişlik değeri olan σ , nöronların algılama boyutu olarak da adlandırılabilir. Eğer σ , giriş vektörleri arasındaki tipik mesafeden daha küçük seçilirse, veri

daha doğru olarak uydurulur. Bununla birlikte, büyük σ değeri; verinin daha düzgün fakat daha az doğru olarak uydurulmasına neden olur (Li vd, 2003).



Şekil 2.1 Genelleştirilmiş Regresyon Ağı Yapısı (Seng vd, 2002)

Her eğitim örneği için hesaplanan mesafe, lineer olmayan bir aktivasyon fonksiyonundan geçirilir. Normalde bu aktivasyon fonksiyonu, üstel fonksiyon olarak seçilir. Örnek katmanı çıkışları toplama katmanına iletilir. (Specht, 1991)

Toplama katmanı, A ve B olarak adlandırılan 2 birimden oluşur. A biriminde her eğitim vektörü için ilgili eğitim vektörünün hedef çıkışı ile örnek katmanında hesaplanan değer çarpılır. Elde edilen p adet çarpım toplanır. B biriminde ise örnek katmanı çıkışlarının toplamı mevcuttur. Çıkış katmanı ise A'yı B'ye bölerek ilgili giriş vektörü için çıkış değerini elde eder. (Li vd, 2003)

$$\hat{y}(X) = E[y/X] = \frac{\sum_{i=1}^p y^i \cdot \exp(d_i)}{\sum_{i=1}^p \exp(d_i)} \quad (2.7)$$

2.3 Genelleştirilmiş Regresyon Ağı Yapısının Avantajları

GRNN yapısının sağladığı en önemli avantaj tek adımda eğitime gerçekleştirmesidir. Bu durum, ağıın hızını arttırdığı gibi; donanımı da basitleştirir. İteratif algoritmalarındaki güncelleme işlemi için eski ağırlık değerlerinin saklanması ve yeni ağırlık değerlerinin eski ağırlık değerlerine bağılı olarak elde edilmesi gerekir. Bu durumda ilave hafıza yapıları ve matematiksel hesaplama birimleri kullanılmalıdır. Oysa GRNN yapısı hafıza elemanına ihtiyaç duymaz. Ayrıca Şekil 2.1’de de görüldüğü gibi ağıın paralel yapısı, eğitim kümesindeki örnek sayısının ayarlanmasında kolaylık sağlar. GRNN yapısının avantajları özetlenecek olursa:

- Örnek sayısı arttıkça optimum regresyon yüzeyine yakınsaması ve kestirim hatasının sıfıra yaklaşması (Specht, 1991)
- Hızlı öğrenme ve genelleştirme yeteneğı (Specht, 1991)
- Giriş ve çıkış değışkenleri arasındaki lineer veya lineer olmayan ilişkiye yakın bir keyfi fonksiyon oluşturma yeteneğı (Seng vd, 2002)
- Yüksek derecede paralel yapı (Specht, 1991)
- Basit donanımsal gerçekleştirme (Specht, 1991)
- Basit yazılımsal gerçekleştirme (Specht, 1991)
- Hesaplamanın, hedef çıkışların minimum ve maksimum değıerleri ile sınırlı olması ve böylelikle sistem modellemede kararlılığıın sağlanması (Seng vd, 2002)
- İteratif yöntemlerden farklı olarak hata kriterinin yerel minimum noktasına yakınsamaması (Specht, 1991)

3. GENELLEŞTİRİLMİŞ REGRESYON AĞININ MEDİKAL PROBLEMLERE UYGULANMASI

Genelleştirilmiş Regresyon Ağı'nın (GRNN) büyük boyutlu veri kümeleri ile yüksek doğruluklu sonuçlar verme yeteneği, bu ağ yapısının medikal alanda kullanılabileceğini göstermektedir. Medikal alanda incelenen pek çok problem büyük boyutlu veri kümelerinden oluşmaktadır ve iteratif öğrenmeye sahip ağ yapılarıyla bu verilerin incelenmesi daha uzun zaman almaktadır. Ancak çeşitli boyut küçültme işlemleri yardımıyla bu süre kısaltılabilmektedir. Oysa GRNN, yüksek ölçüde paralel yapısı ve hızlı genelleştirme yeteneği sayesinde büyük veri kümesine sahip medikal teşhis problemlerinde optimum çözüm sağlar. Ayrıca, MLP kullanılması durumunda, ağırlıkların rastgele başlatılmasından dolayı sonuçlar kararlı olmayacak ve algoritmanın birden fazla kere çalıştırılması sonucu ortalama bir sonuç elde edilecektir. Oysa GRNN'de her çalıştırmadan sonra aynı sonuç elde edilmektedir.

Bu bölümde, GRNN'in performansı çeşitli medikal problemler üzerinde denenmiştir.

- Kontakt lens problemi
- Akciğer kanseri problemi
- Pima-Indian diyabet problemi
- Fetus gelişimi problemi
- Göğüs kanseri problemi
- Erythemato-Squamous problemi

GRNN ağının eğitimi ve ağın performansını ölçen test işlemi MATLAB 6.0 ve Neural Network Toolbox kullanılarak gerçekleştirilmiştir. Tüm veri kümelerinin nümerik değerleri ilk önce ağa aynen uygulanmış, daha sonra sınıflama performansını arttırmak amacıyla bu veri kümelerine normalizasyon uygulanmıştır. Normalizasyon sonucu örneklerin aynı aralık ve varyans değerlerine sahip olması, özellikle sonlu veri kümeleri üzerinde yapılan çalışmalar için oldukça yararlıdır (Specht, 1991)

Ağın performansını belirleyen en önemli kriter test işlemi sonucu elde edilen doğruluktur. Çünkü test kümesi, hastalığı önceden teşhis edilmemiş yeni hastaları temsil etmektedir. Ağ, eğitime işlemi sonunda problemi öğrenir ve test işlemi ile ağın genelleştirme performansı

ölçülür. Farklı σ genişlik değerleri kullanılarak simülasyonlar gerçekleştirilmiş ve en yüksek doğruluğa sahip test sonuçları ilgili σ değeri için verilmiştir.

Tüm veri kümeleri için ağı eğitimi sırasında 2-katlamalı çapraz-geçerlilik yöntemi kullanılmıştır. Bu yöntemde her sınıfa ait örnekler 2'ye bölünerek alt kümeler oluşturulur. Ağı performansını ölçmek için, ilk önce 1. alt küme ile eğitim gerçekleştirilip 2. alt küme ile test işlemi yapılır; daha sonra ağı, 2. alt küme ile eğitilip 1. alt küme ile test edilir. Elde edilen test doğruluk oranlarının ortalaması ağı sınıflama doğruluk oranıdır.

Yukarıda verilen veri kümelerinden ilk ikisi az sayıda örneğe sahipken, diğer veri kümeleri en az 200 örnek içermektedir. Veri kümelerindeki örnek sayısına göre GRNN'in sınıflama doğruluk oranı da değişmektedir.

3.1 Kontakt Lens Problemi

Kontakt lens veritabanında örnekler 3 sınıfta toplanmakta, bu sınıflar kişiyle uyumlu olabilecek kontakt lens tipini vermektedir. Eğitim ve test kümeleri toplam 24 örnekten oluşmaktadır. Bu örneklerin 15 tanesi üçüncü sınıfa, 5 tanesi ikinci sınıfa ve 4 tanesi de birinci sınıfa aittir. Sınıf isimleri ve alt kümelere ait örnek sayısı Çizelge 3.1'de verilmiştir.

Çizelge 3.1 Lens veritabanı için alt kümelere ait örnek sayısı

Sınıf Numarası	Sınıf İsmi	Örnek Sayısı	
		1.Alt Küme	2.Alt Küme
1	Sert Lens	2	2
2	Yumuşak Lens	3	2
3	Lens Kullanamaz	8	7

Her bir örnek 4 parametre ile temsil edilmektedir. Buradaki parametre kavramı, veri tabanının özellik sayısı veya başka bir deyişle GRNN ağı yapısındaki boyut bilgisine karşılık düşer. Bunlar kişinin yaşının genç, orta yaşlı veya yaşlı olmak üzere hangi gruba girdiği; görme bozukluğunun miyopi mi, hipermetropi mi olduğu, astigmatlığın olup olmadığı; gözyaşı üretme oranının azalmış veya normal olması durumlarıdır. Veri kümesinin detayları Ek 1'de verilmiştir.

Ağı genelleştirme yeteneğini ölçmek için ilk önce 13 örnekten oluşan 1. alt küme ile eğitim yapılmış ve 2. alt küme ile test edilmiştir. Test işleminin sonunda %54.5 doğruluk oranı elde edilmiştir. Eğitim kümesi olarak kullanılan 1. alt küme test işleminde de kullanıldığından oran %100 olmuştur. 2. aşamada ise 11 örnekten oluşan 2. alt küme ile eğitim yapılmış ve 1. alt

küme ile ağın performansı test edilmiştir. Burada ise oran %27.5 olarak bulunmuştur. Benzer şekilde, ağ eğitimde kullanılan veri kümesi ile test edildiğinde %100 doğruluk oranı elde edilmiştir. Ağın sınıflama doğruluk oranı ise %42'dir .

Çizelge 3.2 Lens veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı

GRNN $\sigma = 0.05 - 0.2$	Sınıflar				Sınıflama Doğruluk Oranı (%)	
	1	2	3	Toplam	Test	Eğitim
1.aşama	0 (2)	1 (3)	5 (8)	6 (13)	%54.6	%100
2.aşama	0 (2)	1 (2)	2 (7)	3 (11)	%27.3	%100
Ağın Sınıflama Doğruluk Oranı					%42	%100

Yukarıdaki çizelgede ve sınıflama doğruluk oranını gösteren diğer çizelgelerde parantez içinde verilenler sınıflanması gereken veri sayısını göstermektedir.

İkinci adım olarak ağın sınıflama performansını arttırmak için veri kümesi 0.1 ile 0.9 arasındaki değerlere normalize edilmiştir. Ancak performansın artmadığı gözlenmiştir.

3.2 Akciğer Kanseri Problemi

Akciğer kanseri veritabanı, 3 farklı patolojik akciğer kanseri tipini tanımlamaktadır. Örnekler 56 farklı parametre ile temsil edilmektedir. Ancak veritabanını oluşturanlar tarafından, parametreler ile ilgili herhangi bir bilgi verilmemiştir. Veri kümesinin detayları Ek 2'de verilmiştir.

Veri tabanı toplam 32 örnekten oluşmasına rağmen, 5 adet verinin bazı özellik bilgileri kayıptır. Bundan dolayı eğitim ve test kümeleri toplam 27 örnekten oluşmaktadır. Bu örneklerin 10 tanesi ikinci sınıfa, 9 tanesi üçüncü sınıfa ve 8 tanesi de birinci sınıfa aittir. Alt kümelere ait örnek sayısı Çizelge 3.3'de verilmiştir.

Çizelge 3.3 Akciğer kanseri veritabanı için alt kümelere ait örnek sayısı

Sınıf Numarası	Örnek Sayısı	
	1.Alt Küme	2.Alt Küme
1	4	4
2	5	5
3	5	4

Ağın genelleştirme yeteneğini ölçmek için ilk önce 14 örnekten oluşan 1. alt küme ile eğitim yapılmış ve 2. alt küme ile test edilmiştir. Test işleminin sonunda %46.1 doğruluk oranı elde edilmiştir. Eğitim kümesi olarak kullanılan 1. alt küme test işleminde de kullanıldığından oran %100 olmuştur. 2. aşamada ise 13 örnekten oluşan 2. alt küme ile eğitim yapılmış ve 1. alt küme ile ağın performansı test edilmiştir. Burada ise oran %50 olarak bulunmuştur. Benzer şekilde, ağ eğitimde kullanılan veri kümesi ile test edildiğinde %100 doğruluk oranı elde edilmiştir. Ağın sınıflama doğruluk oranı ise %48.1 olarak bulunmuştur. Çizelge 3.4’de GRNN’in bu problem üzerindeki performansı verilmiştir. Lens veri tabanında olduğu gibi burada da sınıflama doğruluk oranı oldukça düşüktür.

Çizelge 3.4 Akciğer kanseri veritabanı için test işlemi sonucunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı

GRNN $\sigma = 0.5$	Sınıflar				Sınıflama Doğruluk Oranı (%)	
	1	2	3	Toplam	Test	Eğitim
1.aşama	3 (4)	0 (5)	3 (4)	6 (13)	%46.1	%100
2.aşama	2 (4)	3 (5)	2 (5)	7 (14)	%50	%100
Ağın Sınıflama Doğruluk Oranı					%48.1	%100

İkinci adım olarak ağın sınıflama performansını arttırmak için veri kümesi 0.1 ile 0.9 arasındaki değerlere normalize edilmiştir. Ancak performansın artmadığı gözlenmiştir.

Sonuç olarak GRNN yapısının az sayıda örneğe sahip veri tabanlarının sınıflandırılmasında başarılı olmadığı görülmüştür. Normalizasyon işlemi de performansı arttırmak için yeterli olmamaktadır.

3.3 Pima-Indian Diyabet Problemi

Bu veritabanındaki bütün hastalar, Phoneix civarında yaşayan en az 21 yaşındaki Pima-Indian kadınlarıdır. Örnekler, bu hastalara uygulanan diyabet testinin pozitif veya negatif olmasına göre iki sınıfta toplanmıştır. Eğitim ve test kümeleri toplam 768 örnekten oluşmaktadır. Bu örneklerin 500 tanesi ikinci sınıfa ve 268 tanesi de birinci sınıfa aittir. Sınıf isimleri ve alt kümelere ait örnek sayısı Çizelge 3.5’de verilmiştir.

Çizelge 3.5 Pima-Indian diyabet veritabanı için alt kümelere ait örnek sayısı

Sınıf Numarası	Sınıf İsmi	Örnek Sayısı	
		1.Alt Küme	2.Alt Küme
1	Pozitif	250	250
2	Negatif	134	134

Her bir örnek 8 klinik bulgu ile temsil edilmektedir. Bunlar: Kişinin gebelik sayısı, oral glikoz tolerans testi sırasındaki plazma glikoz konsantrasyonu, diastolik kan basıncı (mm Hg), triseps deri çukuru kalınlığı (mm), 2 saatlik insülin serumu (mu U/ml), beden kütle indeksi ($\text{weight in kg}/(\text{height in m})^2$), diyabet soyağacı fonksiyonu ve hastanın yaş bilgisidir. Veri kümesinin detayları Ek 3’de verilmiştir.

Ağın genelleştirme yeteneğini ölçmek için ilk önce 384 örnekten oluşan 1. alt küme ile eğitim yapılmış ve 2. alt küme ile test edilmiştir. Test işleminin sonunda %63.8 doğruluk oranı elde edilmiştir. Eğitim kümesi olarak kullanılan 1. alt küme test işleminde de kullanıldığından oran %100 olmuştur. 2. aşamada ise yine 384 örnekten oluşan 2. alt küme ile eğitim yapılmış ve 1. alt küme ile ağın performansı test edilmiştir. Burada ise oran %65.36 olarak bulunmuştur. Benzer şekilde, ağ eğitimde kullanılan veri kümesi ile test edildiğinde %100 doğruluk oranı elde edilmiştir. Ağın sınıflama doğruluk oranı ise %64.6 olarak bulunmuştur. Çizelge 3.6’da GRNN’in bu problem üzerindeki performansı verilmiştir.

Çizelge 3.6 Pima-Indian diyabet veritabanı için test işlemi sonunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı

GRNN $\sigma = 1.5$	Sınıflar			Sınıflama Doğruluk Oranı (%)	
	1	2	Toplam	Test	Eğitim
1.aşama	176 (250)	69 (134)	245 (384)	%63.8	%100
2.aşama	185 (250)	66 (134)	251 (384)	%65.4	%100
Ağın Sınıflama Doğruluk Oranı				%64.6	%100

İkinci aşama olarak, veri kümesindeki bütün değerler, ait oldukları sütundaki en büyük değere bölünerek normalize edilmiştir. Takip eden bütün veri kümelerinde de aynı işlem uygulanmıştır. Sonuçta, doğruluk oranları her iki aşama için de artmış ve ağın sınıflama doğruluk oranı %70.83'e yükselmiştir. Elde edilen sonuçlar Çizelge 3.7'de görülmektedir.

Çizelge 3.7 Normalize edilmiş Pima-Indian diyabet veritabanı için test işlemi sonunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı

GRNN $\sigma = 0.013$	Sınıflar			Sınıflama Doğruluk Oranı (%)	
	1	2	Toplam	Test	Eğitim
1.aşama	206 (250)	66 (134)	272 (384)	%70.83	%100
2.aşama	190 (250)	82 (134)	272 (384)	%70.83	%100
Ağın Sınıflama Doğruluk Oranı				%70.83	%100

3.4 Fetus Gelişimi Problemi

Bu uygulamada amaç, fetus gelişiminin normal veya anormal olup olmadığının belirlenmesidir. Bunun için, gebelik sırasında fetusla plasenta arasındaki bağlantıyı sağlayan ve anneden gıda alımı ile bebekten atıkların temizlenmesini sağlayan bağ damarlarındaki (Umbilical Artery-UA) kan akış hızı dalga şekillerinin dopler ultrason ölçüm sonuçları kullanılmıştır. Haftalık ultrason ölçüm sonuçları ağa giriş bilgisi olarak verilmiş ve fetus

gelişimi hakkında çıkış bilgisi elde edilmiştir.

Eğitim ve test kümeleri toplam 200 örnekten oluşmaktadır. Bu örneklerin 148 tanesi birinci sınıfa, 62 tanesi de ikinci sınıfa aittir. Sınıf isimleri ve alt kümelere ait örnek sayısı Çizelge 3.8’de verilmiştir.

Çizelge 3.8 Fetus gelişimi veritabanı için alt kümelere ait örnek sayısı

Sınıf Numarası	Sınıf İsmi	Örnek Sayısı	
		1.Alt Küme	2.Alt Küme
1	Normal	106	42
2	Anormal	41	21

Örnekler dört parametre ile temsil edilmektedir. İlk parametre, hafta olarak gebelik süresidir (Week Index-WI). Diğerleri ise; ultrason ışını ile kan akış yönü arasındaki açıdan bağımsız olan, kan akış hızı dalga şekilleri ölçüm sonuçlarıdır. Bu açıdan bağımsız indeksler: Sistolik/Diastolik (S/D) oranı; direnç indeksi (resistance index-RI); nabız atışı indeksi (pulsatility index-PI) olarak sıralanır.

Burada $PI=(S-D)/\text{ortalama hız}$, $RI=(S-D)/D$ olarak tanımlanmaktadır. S/D, RI, PI parametrelerindeki düşüş, gebeliği olumlu yönde etkiler. Bir başka deyişle, anormal UA dalga şekli, normal bir gebelik için elde edilen aralığın üstünde bir PI (veya RI veya S/D oranı) değerine sahiptir. Doğumda genellikle yüksek bir S/D oranı, fetusun küçük boyutlu olmasına, yüksek hastalık veya ölüm oranına yol açar. Ek 4’te veri kümesinin detayları verilmiştir. (Güler vd,1999)

Ağın genelleştirme yeteneğini ölçmek için ilk önce 63 örnekten oluşan 1. alt küme ile eğitim yapılmış ve 2. alt küme ile test edilmiştir. Test işleminin sonunda %81 doğruluk oranı elde edilmiştir. Eğitim kümesi olarak kullanılan 1. alt küme test işleminde de kullanıldığından oran %100 olmuştur. 2. aşamada ise 147 örnekten oluşan 2. alt küme ile eğitim yapılmış ve 1. alt küme ile ağın performansı test edilmiştir. Burada ise oran %95.2 olarak bulunmuştur. Benzer şekilde, ağ eğitimde kullanılan veri kümesi ile test edildiğinde %100 doğruluk oranı elde edilmiştir. Ağın sınıflama doğruluk oranı ise %88.1 olarak bulunmuştur. Çizelge 3.9’da GRNN’in bu problem üzerindeki performansı verilmiştir.

Çizelge 3.9 Fetus gelişimi veritabanı için test işlemi sonunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı

GRNN $\sigma = 0.05$	Sınıflar			Sınıflama Doğruluk Oranı (%)	
	1	2	Toplam	Test	Eğitim
1.aşama	30 (42)	21 (21)	51 (63)	%81	%100
2.aşama	103 (106)	37 (41)	140 (147)	%95.2	%100
Ağın Sınıflama Doğruluk Oranı				%88.1	%100

Normalizasyon işlemi sonucunda ise doğruluk oranlarının her iki aşama için de arttığı ve ağın sınıflama doğruluk oranının %92.7' e yükseldiği görülmüştür. Elde edilen sonuçlar Çizelge 3.10'da verilmiştir.

Çizelge 3.10 Normalize edilmiş fetus gelişimi veritabanı için test işlemi sonunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı

GRNN $\sigma = 0.015$	Sınıflar			Sınıflama Doğruluk Oranı (%)	
	1	2	Toplam	Test	Eğitim
1.aşama	39 (42)	17 (21)	56 (62)	%88.9	%100
2.aşama	101 (106)	41 (41)	142 (147)	%96.5	%100
Ağın Sınıflama Doğruluk Oranı				%92.7	%100

3.5 Göğüs Kanseri Problemi

Bu çalışmada kullanılan göğüs kanseri veritabanı of Wisconsin Üniversite Hastanesi doktoru William H. Wohlberg'den elde edilmiştir. 699 örnekten her biri 9 özellik ve iyi huylu veya kötü huylu olmak üzere bir sınıf bilgisi içerir. 16 örnek eksik özellik içerdiğinden, simülasyonlarda kullanılan eğitim ve test kümeleri toplam 683 örnek içermektedir. Bu

örneklerin 444 tanesi iyi huylu sınıfına ve 239 tanesi de kötü huylu sınıfına aittir. Sınıf isimleri ve alt kümelere ait örnek sayısı Çizelge 3.11’de verilmiştir.

Çizelge 3.11 Göğüs kanseri veritabanı için alt kümelere ait örnek sayısı

Sınıf Numarası	Sınıf İsmi	Örnek Sayısı	
		1.Alt Küme	2.Alt Küme
2	İyi huylu	222	222
4	Kötü huylu	120	119

Veri kümesindeki örnekler 9 farklı özellik içermektedir. Bunlar; kütle kalınlığı, hücre büyüklüğünün üniformalığı, hücre şeklinin üniformalığı, marjinal yapışma, tek epithelial hücre büyüklüğü, yalın çekirdek, hafif kromatin, normal nükleoli ve mitozlar bilgisidir. Bütün veriler 1 ile 10 arasında değişen değerlere sahiptir. Ek 5’te veri kümesinin detayları verilmiştir.

Ağın genelleştirme yeteneğini ölçmek için ilk önce 342 örnekten oluşan 1. alt küme ile eğitim yapılmış ve 2. alt küme ile test edilmiştir. Test işleminin sonunda %96.18 doğruluk oranı elde edilmiştir. Eğitim kümesi olarak kullanılan 1. alt küme test işleminde de kullanıldığından oran %100 olmuştur. 2. aşamada ise 341 örnekten oluşan 2. alt küme ile eğitim yapılmış ve 1. alt küme ile ağın performansı test edilmiştir. Burada ise oran %95.9 olarak bulunmuştur. Benzer şekilde, ağ eğitimde kullanılan veri kümesi ile test edildiğinde %100 doğruluk oranı elde edilmiştir. Ağın sınıflama doğruluk oranı ise %96.04 olarak bulunmuştur. Çizelge 3.12’de GRNN’in bu problem üzerindeki performansı verilmiştir.

Çizelge 3.12 Göğüs kanseri veritabanı için test işlemi sonunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı

GRNN $\sigma = 0.4$	Sınıflar			Sınıflama Doğruluk Oranı (%)	
	2	4	Toplam	Test	Eğitim
1.aşama	220 (222)	108 (119)	328 (341)	%96.18	%100
2.aşama	213 (222)	115 (120)	328 (342)	%95.9	%100
Ağın Sınıflama Doğruluk Oranı				%96.04	%100

Bu problem için normalizasyon işleminin sınıflama doğruluk oranını arttırmadığı görülmüştür. Normalize edilmiş değerler için, $\sigma = 0.04$ seçilerek yukarıda anlatılan işlemler gerçekleştirildiğinde %96.04 sınıflama doğruluğu elde edilmiştir.

3.6 Erythemat-Squamous Problemi

Erythemat-Squamous hastalığının farklı tiplerinin teşhisi, dermatolojide ciddi bir sorundur. Tüm hastalık tipleri, deride kızarıklık (erythema) ve pul pul dökülme(scaling) klinik özelliklerini paylaşır. Bu gruptaki hastalıklar, psoriasis, seboreic dermatitis, lichen planus, pityriasis rosea, cronic dermatitis ve pityriasis rubra pilaris'tir. Teşhis için genellikle biyopsi gereklidir ancak bu rahatsızlıklar birden fazla histopatolojik özellikleri de içermektedir. Farklı tiplerin teşhisindeki diğer bir sorun da; başlangıç fazında bir hastalık tipinin, diğer tiplerin özelliğini göstermesi ve takip eden aşamalarda karakteristik özelliklere sahip olmasıdır. Hastalar ilk olarak 12 klinik bulgu ile değerlendirilmiş, daha sonra cilt örnekleri histopatolojik 22 bulgunun değerlendirilmesi için alınmıştır. Histopatolojik bulguların değerleri, örneklerin mikroskop altında analizi yoluyla tespit edilmiştir.

Erythemat-Squamous veritabanı toplam 366 örnekten oluşmasına rağmen, 8 adet verinin yaş bilgisi kayıptır. Bundan dolayı eğitim ve test kümeleri toplam 358 örnekten oluşmaktadır. Bu örneklerin 111 tanesi birinci sınıfa, 71 tanesi üçüncü sınıfa, 60 tanesi ikinci sınıfa, 48'er tanesi dördüncü ve beşinci sınıfa, 20 tanesi de altıncı sınıfa aittir. Alt kümelere ait örnek sayısı Çizelge 3.13'de verilmiştir.

Çizelge 3.13 Erythemat-Squamous veritabanı için alt kümelere ait örnek sayısı

Sınıf Numarası	Sınıf İsmi	Örnek Sayısı	
		1.Alt Küme	2.Alt Küme
1	Psoriasis	56	55
2	Seboreic Dermatitis	30	30
3	Lichen Planus	36	35
4	Pityriasis Rosea	24	24
5	Cronic Dermatitis	24	24
6	Pityriasis Rubra Pilaris	10	10

Veri kümesindeki örnekler 34 farklı özellik içermektedir. Bunlardan 12 tanesi klinik özellikler, 22 tanesi ise histopatolojik özelliklerdir. Klinik özelliklerden aile geçmiş bilgisi,

özellikler, 22 tanesi ise histopatolojik özelliklerdir. Klinik özelliklerden aile geçmiş bilgisi, eğer ailede bu hastalıklar daha önce gözlenmişse 1, gözlenmemişse 0 değerini almıştır. Yine klinik bir özellik olan yaş bilgisi, hastanın yaşını temsil eder. Diğer klinik ve histopatolojik bütün veriler 0 ile 3 arasında değişen değerlere sahiptir. Burada 0, özelliğin bulunmadığı durumu, 3 ise en yüksek olasılıklı durumu temsil etmektedir. Ek 6'da veri kümesinin detayları verilmiştir.

Ağın genelleştirme yeteneğini ölçmek için ilk önce 180 örnekten oluşan 1. alt küme ile eğitim yapılmış ve 2. alt küme ile test edilmiştir. Test işleminin sonunda %87.1 doğruluk oranı elde edilmiştir. Eğitim kümesi olarak kullanılan 1. alt küme test işleminde de kullanıldığından oran %100 olmuştur. 2. aşamada ise 178 örnekten oluşan 2. alt küme ile eğitim yapılmış ve 1. alt küme ile ağın performansı test edilmiştir. Burada ise oran %83.3 olarak bulunmuştur. Benzer şekilde, ağ eğitimde kullanılan veri kümesi ile test edildiğinde %100 doğruluk oranı elde edilmiştir. Ağın sınıflama doğruluk oranı ise %85.2 olarak bulunmuştur. Çizelge 3.14'de GRNN'in bu problem üzerindeki performansı verilmiştir.

Çizelge 3.14 Erythemat-Squamous veritabanı için test işlemi sonunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı

GRNN $\sigma = 0.5$	Sınıflar							Sınıflama Doğruluk Oranı (%)	
	1	2	3	4	5	6	Toplam	Test	Eğitim
1.aşama	51 (55)	23 (30)	35 (35)	15 (24)	21 (24)	10 (10)	155 (178)	%87.1	%100
2.aşama	51 (56)	17 (30)	36 (36)	17 (24)	20 (24)	9 (10)	150 (180)	%83.3	%100
Ağın Sınıflama Doğruluk Oranı								%85.2	%100

Normalizasyon işlemi sonucunda ise doğruluk oranlarının her iki aşama için de arttığı ve ağın sınıflama doğruluk oranının %92.7'ye yükseldiği görülmüştür. Elde edilen sonuçlar Çizelge 3.15'de verilmiştir.

Çizelge 3.15 Normalize edilmiş Erythemato-Squamous veritabanı için test işlemi sonunda doğru sınıflanan örnek sayısı ve GRNN yapısının sınıflama doğruluk oranı

GRNN $\sigma = 0.1$	Sınıflar							Sınıflama Doğruluk Oranı (%)	
	1	2	3	4	5	6	Toplam	Test	Eğitim
1.aşama	53 (55)	26 (30)	35 (35)	20 (24)	24 (24)	10 (10)	168 (178)	%94.3	%100
2.aşama	55 (56)	16 (30)	36 (36)	24 (24)	23 (24)	10 (10)	164 (180)	%91.1	%100
Ağın Sınıflama Doğruluk Oranı								%92.7	%100

Sonuç olarak, incelenen tüm veritabanları dikkate alındığında, örnek sayısı fazla olan veritabanlarının sınıflandırılmasında GRNN yapısı başarılı sonuçlar vermiştir. Ayrıca normalizasyon işlemi, aynı eğitim ve test kümeleri için ağın sınıflama doğruluğunun artmasına sebep olmuştur. Bu bakımdan GRNN, medikal teşhis alanında da, doktorlara yardımcı olmak amacıyla efektif bir şekilde kullanılabilir.

4. GENELLEŞTİRİLMİŞ REGRESYON AĞININ ALT BLOKLARININ TASARIMI


Bu bölümde, genelleştirilmiş regresyon ağını (GRNN) oluşturan alt bloklar tanıtılacaktır.

Bütün alt bloklar akım modu tekniği kullanılarak analog CMOS olarak tasarlanmıştır. Akım modlu devreleri toplama işlemi için ilave bir yapı gerektirmemesi (Toumazou vd, 1996), bu işlemin sıklıkla kullanıldığı GRNN yapısının donanımının basitleşmesine olanak tanır. Ayrıca, akım modlu devrelerde akımları kuvvetlendirmek için, karmaşık yapılar yerine 2 transistörden oluşan akım aynaları kullanılmaktadır.

Alt blokların analog olarak tasarlanması, DAC veya ADC gibi önişleme devrelerinin gerekliliğini de ortadan kaldırmıştır. Güç tüketiminin düşük olması ve az sayıda transistörle istenilen fonksiyonun gerçekleştirilmesi de analog tasarımın diğer avantajlarından (Razavi, 2001). Ayrıca yapay sinir ağlarının hata toleranslı yapısı analog tasarımın doğruluk eksikliğini kompanze eder.

CMOS teknolojisi ise son yıllarda mikroişlemci, hafıza ve ASIC yapıları için en yaygın kullanılan yarıiletken teknolojisidir. CMOS yapının diğer teknolojilere (bipolar, NMOS) oranla en üstün yanı çok daha düşük güç tüketimine olanak tanmasıdır. NMOS ve bipolar devrelerin tersine CMOS yapılarda statik güç tüketimi hemen hemen 0'dır. MOS transistörlerin gerçek hızı geçen 30 yılda üç misli artmış ve bipolar elemanlarla karşılaştırılabilir düzeye gelmiştir. (Razavi, 2001)

GRNN devre yapısı, sırasıyla çıkarma devresi, kare alma/bölme devresi , üstel fonksiyon devresi ve çarpma/bölme devresinden oluşur (Şekil 3.1). Giriş katmanındaki birim sayısı veri kümesinin özellik sayısını temsil eder. Örnek katmanında ise (özellik sayısı x örnek sayısı) kadar birim bulunmaktadır. Bu katmanda eğitim kümesindeki her örnek için özellik değerleri arasındaki mesafe (d_i) hesaplanır ve sigma değerine (σ) bölünür. Bulunan değer üstel fonksiyonu hesaplanır. Çıktılar her örnek için verilmiş hedef değerlerle (y_i) ile çarpılarak toplanır ve üstel fonksiyon çıktıların toplamına bölünür. Bu ağ yapısını gerçeklemek için öncelikle örnek katmanında d_i hesabı yapılmalıdır. Bunun için çıkarma devresi ve kare alma/bölme devresi gerçekleştirilmiştir. Üstel fonksiyon hesabı için tasarlanan devre, kare alma/bölme devresini temel alır. Toplama katmanında ise, yapı akım modlu olduğundan, ilave devre yapısına ihtiyaç yoktur. Çıkış katmanında ise çarpma/bölme devresi kullanılır. GRNN yapısı, iteratif öğrenmeden kaynaklanan karmaşık yapı yerine tek adımda eğitime gerçekleştirdiğinden daha basit donanımsal gerçeklemeye olanak tanır.




Şekil 4.1 GRNN Devre Yapısı Blok Diyagramı.

Şekil 3.1’de çıkarma devresinin akım girişleri olan I_{x1} ve I_{x11} sırasıyla test kümesi örneğini ve eğitime kümesi örneğini temsil etmekte; I_H ise σ genişlik parametresi değerine karşılık düşmektedir. Üstel fonksiyon devresi çıkışı olan I_{eD} , ilgili eğitim örneğinin hedef değeri olan I_{yD} ile çarpılıp, I_E akım değerine bölünmektedir. I_E akımı ise bütün üstel fonksiyon devresi çıkışlarının ($I_{e1}..I_{eD}$) toplamıdır. Çarpma/Bölme devrelerinin çıkışlarının toplamı ise, ilgili test kümesi ($I_{x1}..I_{xD}$) için ağırlık hesapladığı çıkışı vermektedir. Burada D ifadesi veri kümesinin özellik sayısını temsil ederken, p ise eğitim kümesindeki örnek sayısını vermektedir.

Genelleştirilmiş regresyon ağı tasarımıındaki çıkarma ve kare alma/bölme devrelerinin sayısı, farklı boyutlu sınıflandırma uygulamaları için rahatlıkla değiştirilebilir. Bu da GRNN devre yapısının modüler ve paralel olmasının sağladığı avantajlardan biridir. Girişler ise devrelerin dinamik aralığına bağlı olarak ölçeklenmelidir.

Bu tezde, oluşturulan tüm alt bloklar akım aynası yapıları içerir. Akım aynaları, akımı birebir

kopyalamak veya kuvvetlendirmek için kullanılır.



Şekil 4.2 Akım Aynası

Şekil 4.2'deki akım aynasında sol koldan aynalanacak akım, sağ kolda ise aynalanmış çıkış akımı görülmektedir. (4.1)'de çıkış akımının parametrik ifadesi verilmiştir.

$$\frac{I_{out}}{I_{in}} = \frac{\mu_0 C_{ox} a (W/L) (V_{GS} - V_T)^2 (1 + \lambda V_{DS})}{\mu_0 C_{ox} (W/L) (V_{GS} - V_T)^2 (1 + \lambda V_{DS})} = a \quad (4.1)$$

Burada $\mu_0 C_{ox} (W/L)$ ($= k$), V_{GS} ve V_T ifadeleri sırasıyla, MOSFET'in transkondüktans parametresi, gate ile source uçları arasındaki gerilim ve eşik gerilimidir.

(4.2)'de verilen koşul sağlanarak alt bloklardaki bütün MOS transistörlerin doyma (saturation) bölgesinde çalışması sağlanmıştır.

$$V_{DS} \geq V_{GS} - V_T \quad (4.2)$$

Bütün alt bloklar, sınıflandırılacak verinin 0 ile 0.5 arasında değişecek şekilde ölçeklemesine bağlı olarak tasarlanmıştır. Yani devre giriş akımları 0 ile 500uA arasında değişecektir. Ancak daha farklı ölçeklemeler için transistör boyutlarıyla oynanması gerekebilir.

Besleme gerilimi, bütün alt bloklar için $\pm 3.3V$ 'tur.

4.1 Çıkarma Devresi


GRNN devre yapısının ilk katını çıkarma devresi oluşturur. Bu bölümde çıkarma devresinin CMOS'larla gerçekleştirilmesi ve devrenin DC analizi yapılarak çıkarma devresinin ne kadar doğru çalıştığı gözlenmiştir.

4.1.1 Çıkarma Devresinin CMOS'larla Gerçekleştirilmesi

Çıkarma devresinin giriş çıkış bağıntısı (4.3)'de verilmiştir.

$$I_X = I_A - I_B \quad (4.3)$$

Burada I_A ve I_B akımları, sırasıyla test ve eğitim kümesinin örneklerini, I_X ise çıkarma devresinin çıkışını ve bir sonraki kat olan kare alma/bölme devresinin girişini temsil etmektedir. I_A ve I_B akımları 0 ile 500 μ A arasındadır.



Şekil 4.3 Çıkarma devresi (Liu vd, 2000)

Şekil 4.3'deki devre M1-M2, M3-M4, M5-M6 akım aynalarından oluşmaktadır. MOSFET boyutları ise YİTAL 1.5 μ CMOS teknolojisine göre uyarlanmıştır. Her çift için boyut oranları 1 olarak seçilerek, akımın kopyalanması sağlanmıştır. I_A , M1-M2 ve M3-M4 üzerinden aynalanarak, M5-M6 üzerinden aynalanan I_B ile farkı alınır. Bu devre $I_A > I_B$ koşulunda doğru çıkış verecektir.

Çizelge 4.1 Çıkarma devresinin transistör boyutları


MOSFET	Boyut-W/L ($\mu\text{m}/\mu\text{m}$)
M ₁ , M ₂	8/1.5
M ₃ , M ₄	10/1.5
M ₅ , M ₆	9.5/1.5
M ₇	5.5/2.5

4.1.2 Çıkarma Devresinin Lineer Bölgede Çalışma Koşulları (DC Analiz)

Şekil 4.1'de görülen çıkarma devresinin kullanıldığı GRNN devresinin sınıflama doğruluğunun yüksek olması için, çıkarma devresi lineer olarak çalışmalıdır. Bu nedenle çıkışa ilişkin akım değerlerinin, gerçek çıkarma işlemi sonucu ile örtüşmesi gerekir. Ancak

YSA'nın hata toleranslı yapısı analog tasarımın doğruluk eksikliğinin kompanze ettiğinden, bu farkın veri kümesine bağlı olarak minimum olması yeterlidir.

Bu alt bölümde çıkarma devresinin TSPICE programından yararlanarak DC analizi yapılmıştır. Simülasyon işlemi TÜBİTAK YİTAL 1.5 μ parametreleri kullanılarak gerçekleştirilmiştir. Çıkarma devresine ilişkin simülasyon dosyası Ek 7'de verilmiştir.



Şekil 4.4 Çıkarma devresinin çıkış akımının ($ID(M7)$) ve ($I_A - I_B$) fonksiyonun I_B akımına göre değişimi

Şekil 4.4'te devrenin en fazla %10 hata ile çıkış verdiği görülmektedir. Çıkarma devresinin toplam güç tüketimi 8.67 mW'tır.

4.2 Kare Alma/Bölme Devresi


GRNN devre yapısının ikinci katını kare alma/bölme devresi oluşturur. Bu devre yapısı adaptif bulanık kontrol devrelerinde (Huang vd,1995) ve akım modlu bir sınıflayıcı devresinde (Liu vd, 2000) kullanılmıştır. Bu bölümde kare alma/bölme devresinin CMOS'larla gerçekleştirilmesi ve devrenin DC analizi yapılarak kare alma/bölme devresinin ne kadar doğru çalıştığı gözlenmiştir.

4.2.1 Kare Alma/Bölme Devresinin CMOS'larla Gerçekleştirilmesi

Kare Alma/Bölme devresinin giriş çıkış bağıntısı (4.4)'de verilmiştir.

$$I_{X^2} = \frac{I_X \cdot I_X}{I_H} \quad (4.4)$$

Devre iki giriş ve bir çıkıştan oluşmaktadır. Girişlerden I_X akımı çıkarma devresinin çıkışı, I_H ise σ genişlik değerini temsil eden akım büyüklüğüdür. Bu devre için I_H , 0.5 mA olarak alınmıştır. M13 transistörü ise bir sonraki katın girişini temsil etmektedir. Dolayısıyla devrenin çıkış akımı M13 transistörünün drain akımı olarak gösterilebilir.



Şekil 4.5 Kare alma/bölme devresi (Huang vd, 1995)

Devrede aynı transkondüktansa sahip M1, M2, M3, M4, M5 transistörleri I_H akımını, M6, M7, M8, M9 VE M10'dan oluşan kare alma devresine iletmek için, akım aynası yapısı oluştururlar. MOSFET boyutları ise YİTAL 1.5µ CMOS teknolojisine göre uyarlanmıştır.

Kare alma devresinde

$$\begin{aligned} k_6 &= k_7 = 2k \\ k_8 &= k_9 = k_{10} = k \end{aligned} \quad (4.6)$$

olarak seçilirse

$$I_H = 2k(V_{GS6} - V_T)^2 = 2k\left(\frac{V_1}{2} - V_T\right)^2 = \frac{k}{2}(V_1 - 2V_T)^2 \quad (4.7)$$

ifadesi elde edilir.

M8 ve M9 transistörlerinin V_{GS} gerilimleri sırasıyla V_b ve V_a 'dır.

$$\begin{aligned}
I_X &= I_{D9} - I_{D8} \\
I_X &= k(V_a - V_T)^2 - k(V_b - V_T)^2
\end{aligned} \tag{4.8}$$

I_X akım denkleminde

$$V_1 = V_a + V_b \tag{4.9}$$

eşitliği yerine konursa

$$I_X = k(V_1 - 2V_T)(V_a - V_b) \tag{4.10}$$

elde edilir.

$$\begin{aligned}
I_0 &= I_{D9} + I_{D8} - I_H \\
I_0 &= k(V_a - V_T)^2 + k(V_b - V_T)^2 - I_H
\end{aligned} \tag{4.11}$$

(4.11) eşitliğinde gerekli düzenlemeler yapıldığında (Bult ve Wallinga, 1987)

$$I_0 = \frac{k}{2}(V_1 - 2V_T)^2 + \frac{I_x^2}{2k(V_1 - 2V_T)^2} - I_H \tag{4.12}$$

elde edilir. Bu eşitlikte (4.7) yerine yazılırsa kare alma devresi (4.13) ifadesini gerçekler.

$$\begin{aligned}
I_0 &= I_H + \frac{I_x^2}{4I_H} - I_H \\
I_0 &= \frac{I_x^2}{4I_H}
\end{aligned} \tag{4.13}$$

Ayrıca M_{11} - M_{12} ile oluşturulan akım kuvvetlendiricisinde transkondüktans parametreleri

$$k_{12} = 4k_{11} \tag{4.14}$$

seçilerek devrenin çıkış akımının, I_0 büyüklüğünün 4 katı olmasını sağlar.


$$I_{x^2} = \frac{I_x^2}{I_H} \quad (I_H \geq I_X \text{ koşuluyla}) \tag{4.15}$$

Çizelge 4.2 Kare Alma/Bölme devresinin transistör boyutları

MOSFET	Boyut-W/L ($\mu\text{m}/\mu\text{m}$)
M ₁ , M ₂	2.5/1.5
M ₃ , M ₄ , M ₅	8/1.5
M ₆ , M ₇	5.5/1.5
M ₈ , M ₉ , M ₁₀	6/4.5
M ₁₁	30/1.5
M ₁₂	95/1.5
M ₁₃	2.5/1.5

4.2.2 Kare Alma/Bölme Devresinin Lineer Bölgede Çalışma Koşulları (DC Analiz)

Bu alt bölümde kare alma/bölme devresinin TSPICE programından yararlanarak DC analizi yapılmıştır. Simülasyon işlemi TÜBİTAK YİTAL 1.5 μ parametreleri kullanılarak gerçekleştirilmiştir. Devreye ilişkin simülasyon dosyası Ek 8’de verilmiştir.



Şekil 4.6 Kare alma/bölme devresinin çıkış akımının ($ID(M13)$) ve (I_X^2/I_H) fonksiyonunun I_X akımına göre değişimi

Simülasyonun başında I_X akımı 0.3mA, I_H ise 0.5mA olarak alınmış ve I_X akımı 0 ile 0.5mA arasında taratılmıştır. Şekil 4.6’da devrenin en fazla %6 hata ile çıkış verdiği görülmektedir. Kare alma/bölme devresinin toplam güç tüketimi 10.6 mW’tır.

4.3 Üstel fonksiyon Devresi

GRNN devre yapısının üçüncü katını üstel fonksiyon devresi oluşturur. Bu devre yapısı haberleşme uygulamalarında, disk sürücülerinde, medikal donanımlarda ve işitme cihazlarında kullanılmıştır. Geleneksel olarak üstel fonksiyon devreleri, bipolar transistörlerin üstel karakteristiklerinden faydalanılarak tasarlanır. CMOS teknolojisinde ise, yanıl (lateral) bipolar transistörler ve zayıf evirtim bölgesinde çalışan MOS transistörler kullanılabilir. Fakat frekans cevabı ve giriş dinamik aralığı yetersiz olacaktır. Bundan dolayı Taylor serisi açılımını temel alan ve doyma bölgesinde çalışan MOS transistörlerden oluşan üstel fonksiyon devreleri (pseudo-exponential) geliştirilmiştir. (Chang ve Liu, 2000)


Taylor serisi açılımı

$$e^x = 1 + \frac{1}{1!}x + \frac{1}{2!}x^2 + \dots + \frac{1}{n!}x^n + \dots \quad (4.16)$$

şeklinde ifade edilebilir. Eğer $|x| \ll 1$ ise (4.16),

$$e^x \cong 1 + x + \frac{1}{2}x^2 \quad (4.17)$$

ifadesine yaklaşır. (Chang ve Liu, 2000)



Şekil 4.7 Üstel fonksiyon ile üstel fonksiyonun Taylor açılımının karşılaştırılması

Hesaplanan sonuçlarda, $-0.575 \leq x \leq 0.815$ koşulu sağlandığında (4.17) eşitliğiyle üstel fonksiyon arasındaki hata %5'den az olur (Chang ve Liu, 2000).

Bu bölümde Taylor serisi yaklaşımını temel alan üstel fonksiyon devresinin CMOS'larla gerçekleştirilmesi ve devrenin DC analizi yapılarak üstel fonksiyon devresinin ne kadar doğru çalıştığı gözlenmiştir.

Ancak burada dikkat edilmesi gereken nokta (2.6) eşitliğindeki eksi ifadenin ve bu ifadeye bağlı olan, $\exp(d_i)$ ifadesinin

$$e^{-x} \cong 1 - x + \frac{1}{2}x^2 \quad (4.18)$$


eşitliğiyle sağlanmış olmasıdır.

4.3.1 Üstel Fonksiyon Devresinin CMOS'larla Gerçekleştirilmesi

Üstel fonksiyon devresinin giriş çıkış bağıntısı (4.19)'de verilmiştir.

$$I_e = 1 - I_x + \frac{I_x^2}{2} \quad (4.19)$$

Devre iki giriş ve bir çıkıştan oluşmaktadır. Girişlerden I_x akımı, her bir eğitim vektöründeki boyut sayısı kadar olan kare alma/bölme devrelerinin çıkışlarının toplamı, I_H ise σ genişlik değerini temsil eden akım büyüklüğüdür. Devrenin çıkış akımı olan I_e , bir sonraki katın girişini temsil eden M14 transistörünün drain akımı olarak gösterilir.



Şekil 4.8 Üstel fonksiyon devresi

(4.18) eşitliğini gerçeklemek üzere, kare alma/bölme devresini temel alan bir yapı tasarlanmıştır. C noktasında sabit akım kaynağı I_A ile I_{x^2} 'nin toplamından M9, M10 ve M13 ile aynalanan I_x akımı çıkartılırsa; sonuçta (4.19) ifadesi elde edilmiş olur. Yapıda

$$I_{x^2} = \frac{I_x I_x}{2} \quad (4.20)$$


koşulunu sağlamak için I_H 1mA seçilmiş ve transistör boyutları Çizelge 4.3'teki gibi ayarlanmıştır.

Çizelge 4.3 Üstel fonksiyon devresinin transistör boyutları

MOSFET	Boyut-W/L ($\mu\text{m}/\mu\text{m}$)
M ₁ , M ₂	2.5/1.5
M ₃ , M ₄ , M ₅	7/1.5
M ₆ , M ₇	25/1.5
M ₈ , M ₉ , M ₁₀ , M ₁₃	4.5/4.5
M ₁₁ , M ₁₂	8/1.5
M ₁₄	6/4.5

4.3.2 Üstel Fonksiyon Devresinin Lineer Bölgede Çalışma Koşulları (DC Analiz)

Bu alt bölümde üstel fonksiyon devresinin TSPICE programından yararlanarak DC analizi yapılmıştır. Simülasyon işlemi TÜBİTAK YİTAL 1.5 μ parametreleri kullanılarak gerçekleştirilmiştir. Devreye ilişkin simülasyon dosyası Ek 9’de verilmiştir.



Şekil 4.9 Üstel fonksiyon devresinin çıkış akımının ($ID(M14)$) ve $(1-I_X+(I_X)^2/2)$ fonksiyonunun I_X akımına göre değişimi

Üstel fonksiyon devresinin toplam güç tüketimi 17.4 mW’tır. Giriş 0 ile 1mA arasında değişirken çıkış aralığı %5.8 hata ile 8.5dB’dir.

4.4 Çarpma/Bölme Devresi

GRNN devre yapısının son katını çarpma/bölme devresi oluşturur. Literatürde, kuadratik translineer prensibini temel alan (Gai vd, 1997), eşik altı bölgesinde çalışan (Wilamowski, 1998) veya düşük besleme gerilimi kullanan (Blas vd, 2003) akım modlu farklı çarpma/bölme devreleri mevcuttur.

Analog çarpıcılar analog sistemlerde; örneğin modülatörlerde, faz ayırıcılarda, adaptif filtrelerde, RMS-DC çeviricilerde, fonksiyon sentezleyicilerde anahtar elemandır. Son zamanlarda bulanık mantık kontrol devrelerinde ve yapay sinir ağı yapılarında da kullanılmaktadır. (Gai vd, 1997)

Bu bölümde çarpma/bölme devresinin CMOS'larla gerçekleştirilmesi ve devrenin DC analizi yapılarak çarpma/bölme devresinin ne kadar doğru çalıştığı gözlenmiştir.

4.4.1 Çarpma/Bölme Devresinin CMOS'larla Gerçekleştirilmesi

Çarpma/Bölme devresinin giriş çıkış bağıntısı (4.21)'de verilmiştir.

$$I_C = \frac{I_{ep} I_{yp}}{I_E} \quad (4.21)$$

Devre üç giriş ve bir çıkıştan oluşmaktadır. Girişlerden I_{ep} akımı p. üstel fonksiyon devresi çıkışını simgelerken, I_{yp} ise p. eğitim örneğine karşılık düşen hedef çıkış değerini simgelemektedir. I_E akımı ise tüm üstel fonksiyon devrelerinin çıkışlarının toplamıdır.


(4.21) eşitliğini gerçeklemek üzere, kare alma/bölme devresini temel alan bir yapı tasarlanmıştır. Şekil 4.8'de verilen devrede I_{X1} ve I_{X2} akımlarını sırasıyla

$$\begin{aligned} I_{X1} &= I_e + I_y \\ I_{X2} &= I_e - I_y \end{aligned} \quad (4.21)$$

şeklinde gösterilirse, I_{01} ve I_{02} akımları sırasıyla

$$\begin{aligned} I_{01} &= \frac{(I_e + I_y)^2}{4I_E} \\ I_{02} &= \frac{(I_e - I_y)^2}{4I_E} \end{aligned} \quad (4.22)$$

şeklinde ifade edilir.



Şekil 4.10 Çarpma/bölme devresi

Devrenin yapısı, bu akımların M_{11} - M_{12} ve M_{21} - M_{22} çiftleriyle aynalanmasıyla oluşan I_{X1}^2 ile I_{X2}^2 akımlarının farkını alacak şekilde tasarlanmıştır.

$$I_C = \frac{(I_e + I_y)^2}{4I_E} - \frac{(I_e - I_y)^2}{4I_E} \quad (4.23)$$


$$I_C = \frac{I_e I_y}{I_E}$$

Çizelge 4.4 Çarpma/bölme devresinin transistör boyutları

MOSFET	Boyut-W/L ($\mu\text{m}/\mu\text{m}$)	MOSFET	Boyut-W/L ($\mu\text{m}/\mu\text{m}$)
M_1, M_2	11/1.5	M_{14}, M_{15}	17/1.5
M_3, M_4, M_5	17/1.5	M_{16}, M_{17}	10.5/1.5
M_6, M_7	10.5/1.5	$M_{18}, M_{19}, M_{20},$	16.5/4.5
M_8, M_9, M_{10}	16.5/4.5	M_8, M_9, M_{10}, M_{13}	4.5/4.5
M_{11}, M_{12}	16/1.5	M_{21}, M_{22}	16/1.5
M_{13}	5/2.5	M_{23}	5/2.5

4.4.2 Çarpma/Bölme Devresinin Lineer Bölgede Çalışma Koşulları (DC Analiz)

Bu alt bölümde çarpma/bölme devresinin TSPICE programından yararlanarak DC analizi yapılmıştır. Simülasyon işlemi TÜBİTAK YİTAL 1.5μ parametreleri kullanılarak gerçekleştirilmiştir. Devreye ilişkin simülasyon dosyası Ek 10'da verilmiştir.



Şekil 4.11 Çarpma/bölme devresinin çıkış akımının $I(R)$ ve $((I_{X1})^2 - (I_{X2})^2) / (4 * I_E)$ fonksiyonunun I_X akımına göre değişimi

Burada I_C akımı 1K değerine sahip bir direnç üzerinde gözlemlenmiştir. I_y akımı ise 0.9 mA olarak alınmıştır. Şekil 4.11'de devrenin en fazla %10 hata ile çıkış verdiği görülmektedir. Simülasyon sırasında çarpma/bölme devresinin toplam güç tüketimi 57.5 mW'tır.

5. SONUÇ

Bu tezde Genelleştirilmiş Regresyon Ağlarının medikal teşhis alanında kullanılabileceği gösterilmiş ve bu amaçla geliştirilebilecek GRNN tabanlı bir sınıflayıcı tasarımında kullanılacak tümdevre alt blokları tasarlanmıştır.

Ağın performansının belirlenmesinde genelleştirme yeteneği, farklı medikal problemler için kullanılabilirliği, ağ yapısının karmaşıklığı ve elektronik tasarıma uygunluğu incelenmiştir. Burada kontakt lens, akciğer kanseri, pima-indian diyabet, fetus gelişimi, göğüs kanseri ve erythemato-squamous problemleri ele alınmıştır. Ağın eğitilmesi ve genelleştirme yeteneğini ölçmek üzere test edilmesi için ilgili problemlerin veritabanları ikiye bölünmüş ve 2-katlamalı çapraz geçerlilik yöntemi uygulanmıştır. GRNN yapısı büyük boyutlu veri kümeleri ile yüksek doğruluklu sonuçlar verdiği için; toplam örnek sayısı 30'dan az olan kontakt lens ve akciğer kanseri veri kümelerinin sınıflama doğruluk oranları %50'den az olmuştur. Performansı arttırmak için veri kümesine uygulanan normalizasyon işlemi de, bu iki problem için ağın sınıflama doğruluk oranını arttırmamıştır. Ağın performansı, büyük boyutlu veri kümesine sahip diğer problemler üzerinde denendiğinde, sınıflama doğruluk oranı pima-indian diyabet problemi için %64.6, fetus gelişimi problemi için %88.1, göğüs kanseri problemi için %96.1 ve son olarak erythemato-squamous problemi için %85.2 olarak bulunmuştur. Bu veri kümeleri normalize edildiğinde, ağın sınıflama doğruluk oranı yükselerek, pima-indian diyabet problemi için %70.83, fetus gelişimi problemi için %92.7 ve erythemato-squamous problemi için %92.7 olmuştur. Normalizasyon işleminin gerekliliği hem sınıflama performansının artması hem de devre alt bloklarının tasarımı için gereklidir.

Bu amaçla geliştirilebilecek GRNN tabanlı bir sınıflayıcı tasarımında kullanılacak tümdevre alt blokları, akım modlu analog CMOS yapılar olarak TÜBİTAK-YİTAL 1.5 μ CMOS proses parametreleri kullanılarak tasarlanmıştır. Tasarımda minimum boyutlara sahip minimum sayıda transistör kullanılmasına özen gösterilmiştir. Bloklar TSPICE programı ile simüle edilmiş ve blokların belli bir hata payı ile yüksek doğruluklu performans gösterdikleri gözlenmiştir. YSA'nın hata toleranslı yapısı analog tasarımın doğruluk eksikliğinin kompanze ettiğinden, bu hata payının veri kümesine bağlı olarak minimum olması yeterlidir.

Gelecekteki çalışma, bu alt bloklardan yararlanarak, medikal teşhis alanında kullanılmak üzere GRNN tabanlı bir sınıflayıcı yapısı tasarlamak olabilir.

KAYNAKLAR

- Acar, R. ve Yıldırım T., (2004), "An Artificial Neural Network Approach to Diagnosis of Erythemato-Squamous Disease", 2nd. International Symposium on Electrical, Electronics and Computer Engineering (NEU-CEE), 11-13 Mar. 2004, Nicosia.
- Amaral, T.G.B ve Crisostomo, M.M., (2001), "Neuro-Fuzzy Control and Modelling in an Adaptive Information Visualization System", 2001 IEEE International Fuzzy Systems Conference, 2-5 Dec. 2001, Melbourne.
- Bult, K. ve Wallinga, H. (1987), "A Class of Analog CMOS Circuits Based on the Square-Law Characteristic of an MOS Transistor in Saturation", IEEE Journal of Solid-State Circuits, sc-22(3):357-365.
- Chang, C. ve Liu, S. (2000), "Pseudo Exponential Function for MOSFETs in Saturation", IEEE Transactions on Circuits and Systems-II: Analog and Digital Signal Processing, 47(11):1318-1321.
- Cruz-Blas, C.A., Lopez-Martin, A.J. ve Carlosena A. (2003), "1.5V four-quadrant CMOS current multiplier/divider", Electronics Letters, 39(5):434-436.
- Gai, W., Chen, H. ve Seevinck E. (1997), "Quadratic-translinear CMOS multiplier-divider circuit", Electronics Letters, 33(10):860-861.
- Huang, C., Chen, C. ve Liu, B. (1995), "Current Mode Linguistic Hedge Circuit for Adaptive Fuzzy Logic Controllers", Electronics Letters, 31(17):1517-1519.
- Jabri, M.A., Coggins, R.J. ve Flower, B.G. (1996), Adaptive Analog VLSI Neural Systems, Chapman & Hall, London.
- Kayaer, K. ve Yıldırım T., (2003), "Medical Diagnosis on Pima Indian Diabetes Using General Regression Neural Networks", Artificial Neural Networks and Neural Information Processing (ICANN/ICONIP), 26-29 June 2003, İstanbul.
- Kıyan, T. ve Yıldırım T., (2003), "Breast Cancer Diagnosis using Statistical Neural Networks", XII. TAINN Symposium, 2-4 July 2003, Çanakkale.
- Leong, P.H.W. ve Jabri, M., (1992) "A VLSI Neural Network for Arrhythmia Classification System", Proceedings of the International Joint Conference on Neural Networks, Baltimore, Maryland USA, 2, 678-683.
- Leong, P.H.W. ve Jabri, M.A., (1993) "A Low Power Analogue Neural Network Classifier Chip", Proceedings of the International Custom Integrated Circuits Conference, San Diego, USA, 4.5.1-4.5.4.
- Li, Z., Sun, J., Zhang, J. ve Wei, Z., (2003), "Computing Models Based on GRNNs", IEEE Canadian Conference on Electrical and Computer Engineering, 4-7 May 2003, Canada.
- Liu, B., Chen, C. ve Tsao, J. (2000), "A Modular Current-Mode Classifier Circuit for Template Matching Application", IEEE Transactions on Circuits and Systems-II: Analog and Digital Signal Processing, 47(2):145-151.
- Özyılmaz, L., (2000), Konik Kesit Fonksiyonlu Yapay Sinir Ağında Öğrenme Algoritmasının Geliştirilmesi ve Ağın Çeşitli Problemler için Performansı ile Duyarlılığının İncelenmesi, Doktora Tezi, Yıldız Teknik Üniversitesi, İstanbul.

Papik, K., Molnar, B., Schaefer, R., Dombovari, Z., Tulassay, Z. ve Feher J. (1997), "Application Of Neural Networks In Medicine- A Review", International Medical Journal for Experimental and Clinical Research, 4(3):538-546.

Razavi, B. (2001), Design of Analog CMOS Integrated Circuits, McGraw-Hill, Singapore.

Schaffner, C. ve Schroder, D., (1993), "An Application of General Regression Neural Network to Nonlinear Adaptive Control", Fifth European Conf. On Power Electronic and Applications, Sept. 1993, Brighton.

Specht, D.F. (1991), "A General Regression Neural Network", IEEE Transactions on Neural Networks, 2(6):568-576.

Teo, L.S., Marzuki, K., Rubiyah, Y., (2002), "Adaptive GRNN for the Modelling of Dynamic Plants", 2002 IEEE International Symposium on Intelligent Control, 27-30 Oct. 2002, Vancouver.

Toumazou, C., Lidgey, F.J. ve Haigh, D.G. (1990), Analogue IC design: The Current Mode Approach, IEE Publications, London.

Wilamowski, B. M., (1998), "VLSI Analog Multiplier/divider Circuit", ISIE'98 International Symposium on Industrial Electronics, 7-10 July 1998, Pretoria.

Zhang, Z. ve Suthaharan, S., (1997), "Neuro-Fuzzy Control and Modelling in an Adaptive Information Visualization System", 1997 IEEE International Conference on Control Applications, 5-7 Oct. 1997, Hartford.

EKLER

Ek 1	Kontakt Lens Problemi İçin Veritabanı
Ek 2	Akciğer Kanseri Problemi İçin Veritabanı
Ek 3	Pima-Indian Diyabet Problemi İçin Veritabanı
Ek 4	Fetus Gelişimi Problemi İçin Veritabanı
Ek 5	Göğüs Kanseri Problemi İçin Veritabanı
Ek 6	Erythemato-Squamous Problemi İçin Veritabanı
Ek 7	Çıkarma Devresi İçin TSPICE Simülasyon Dosyası
Ek 8	Kare Alma/Bölme Devresi İçin TSPICE Simülasyon Dosyası
Ek 9	Üstel Fonksiyon Devresi İçin TSPICE Simülasyon Dosyası
Ek 10	Çarpma/Bölme Devresi İçin TSPICE Simülasyon Dosyası



Ek 1 Kontakt Lens Problemi İçin Veritabanı

(www.ics.uci.edu/pub/ml-repos/machine-learning-databases/lenses)

1 1 2 2 1
1 2 2 2 1
2 1 2 2 1
3 1 2 2 1
2 2 1 2 2
2 1 1 2 2
3 2 1 2 2
1 2 1 2 2
1 1 1 2 2
1 1 2 1 3
1 2 2 1 3
2 1 1 1 3
1 2 1 1 3
2 2 1 1 3
2 1 2 1 3
1 1 1 1 3
2 2 2 1 3
2 2 2 2 3
3 1 1 1 3
3 1 1 2 3
3 1 2 1 3
3 2 1 1 3
3 2 2 1 3
3 2 2 2 3

Ek 2 Akciğer Kanseri Problemi İçin Veritabanı

(www.ics.uci.edu/pub/ml-repos/machine-learning-databases/lung)

```

1 0 3 3 1 0 3 1 3 1 1 1 1 1 3 3 1 2 2 0 0 2 2 2 1 2 1 3 2 3 1 1 1 3 3 2 2 2 1 2 2 2 1 2 2 2 2 2 2 2 1 2 2
1 0 3 3 2 0 3 3 3 1 1 1 0 3 3 3 1 2 1 0 0 2 2 2 1 2 2 3 2 3 1 3 3 3 1 2 2 1 2 2 2 1 2 2 1 2 2 2 2 2 2 2 2 1 2
1 0 2 3 2 1 3 3 3 1 2 1 0 3 3 1 1 2 2 0 0 2 2 2 2 1 3 2 3 3 1 3 3 3 1 1 1 1 2 2 2 2 1 2 2 2 1 2 2 2 2 2 2 2 2
1 0 3 2 1 1 3 3 3 2 2 2 1 1 2 2 2 2 2 0 0 2 2 2 1 1 2 3 2 2 1 1 1 3 2 1 2 2 1 2 2 2 1 2 2 2 2 2 2 2 2 2 1 2 2
1 0 3 3 2 0 3 3 3 1 2 2 0 3 3 3 2 2 1 0 0 1 2 2 2 1 3 3 1 2 2 3 3 3 2 1 2 2 1 2 2 2 1 2 2 2 2 2 2 2 2 2 2 1 2
1 0 3 2 1 0 3 3 3 1 2 1 2 3 3 3 3 2 2 0 0 2 2 2 2 1 3 2 2 2 2 3 3 3 2 1 1 2 2 1 2 1 2 2 2 2 1 2 2 2 2 1 2 2 2 1 2
1 0 2 2 1 0 3 1 3 3 3 3 2 1 3 3 1 2 2 0 0 1 1 2 1 2 1 3 2 1 1 3 3 3 2 2 1 2 1 2 2 1 2 2 2 1 2 2 2 1 2 2 2 1 2 2
1 0 3 1 1 0 3 1 3 1 1 1 3 2 3 3 1 2 2 0 0 2 2 2 1 2 1 2 1 1 1 3 3 3 3 2 2 1 2 2 2 1 2 2 1 2 2 2 2 2 2 2 2 1 2 2
2 0 2 3 2 0 2 2 2 1 2 2 2 2 2 2 1 2 2 2 2 2 2 1 3 2 3 3 3 3 3 3 3 2 1 2 1 2 2 2 2 2 2 2 2 2 2 2 2 1 3 2 1 1 2 2
2 0 2 2 0 0 3 2 3 1 1 3 1 3 1 1 2 2 2 0 2 1 1 2 1 1 2 2 2 2 1 3 3 3 1 2 2 1 2 2 2 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2
2 0 2 3 2 0 1 2 1 1 2 1 0 1 2 2 1 2 1 0 2 2 2 2 1 2 1 2 2 3 1 3 3 3 1 2 2 1 2 2 2 2 1 2 2 2 2 2 2 2 2 1 1 2 2 1
2 0 2 1 1 0 1 2 2 1 2 1 1 2 2 2 1 2 2 0 2 2 2 2 1 2 1 3 2 2 1 1 1 1 1 2 2 1 2 2 2 1 2 2 2 2 2 2 2 2 2 2 2 1 2 2
2 0 2 2 1 1 2 3 3 1 1 1 1 2 2 2 1 2 2 0 1 2 2 2 1 2 1 2 2 2 1 1 1 3 2 1 1 2 1 2 2 2 1 2 2 1 2 2 2 2 2 2 1 1 1 2 2
2 0 3 2 2 1 2 2 2 1 1 2 1 2 3 3 2 2 2 0 1 2 2 2 1 2 3 2 2 1 2 2 2 3 1 3 2 1 2 2 2 1 2 2 1 2 2 2 2 2 2 2 2 2 2 2
2 0 3 2 2 0 1 1 3 1 1 1 0 1 3 3 1 2 2 0 2 2 2 2 1 1 2 2 2 2 1 3 3 3 3 3 1 2 2 1 2 1 2 2 2 2 2 2 2 2 2 2 2 1 2 2
2 0 2 1 1 0 2 1 3 1 1 1 0 3 1 3 1 2 2 0 0 1 2 2 3 3 3 2 2 2 1 3 3 3 1 1 1 2 1 2 2 2 1 2 1 2 2 2 2 2 2 2 1 1 1 2 2
2 0 1 2 1 0 3 3 3 1 2 2 1 1 3 3 1 2 2 0 0 2 2 2 1 2 1 3 2 3 1 1 1 3 1 1 2 2 1 2 2 2 1 2 2 2 2 2 2 2 2 2 1 1 2 2 1
2 0 3 3 2 0 2 1 3 1 1 3 3 3 3 3 1 2 2 0 0 2 2 1 1 2 2 3 3 3 3 3 3 3 2 2 2 1 2 1 2 1 2 2 2 2 2 2 2 1 2 2 2 2 2 1 2
3 0 2 3 1 1 2 2 1 1 1 1 1 1 2 2 1 2 2 2 2 1 2 1 1 1 1 2 2 3 1 3 3 3 1 1 1 3 1 3 3 3 3 3 3 3 3 3 3 3 1 3 3 2 2 1
3 0 2 3 1 1 1 2 1 1 1 2 1 1 1 2 2 1 1 1 2 1 2 1 1 2 2 2 2 2 1 3 3 3 2 2 2 3 3 1 1 2 2 3 2 2 2 2 2 2 2 2 2 2 2 2 1
3 0 3 3 1 0 3 3 1 1 1 2 1 1 2 2 2 2 2 2 2 1 1 1 1 1 2 2 2 2 3 3 3 3 2 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 3 2 2 2 1
3 0 2 2 2 0 2 1 2 1 1 1 0 2 2 3 1 2 2 2 2 2 2 2 3 3 3 2 2 1 2 2 2 2 3 1 2 2 2 2 1 2 1 1 2 2 1 2 2 2 2 2 2 1 2 1
3 0 2 2 1 0 2 2 2 1 1 2 0 2 2 2 1 2 2 2 2 2 2 2 1 2 1 3 3 3 1 3 3 2 2 3 1 2 1 3 2 2 3 2 2 2 3 3 2 2 3 2 2 2 2 1
3 0 3 2 2 0 2 2 2 1 1 2 0 2 2 2 1 2 2 2 2 2 2 2 1 1 2 2 2 2 2 2 1 1 1 2 1 1 3 1 3 3 3 2 3 2 2 2 2 2 3 1 2 2 2 2 2
3 0 2 1 1 0 2 2 1 1 1 1 0 1 1 1 2 1 2 0 2 1 1 1 1 1 2 2 1 2 1 3 3 3 1 1 3 3 3 2 3 1 2 2 3 3 2 2 2 3 2 2 2 2 2 1
3 0 2 3 2 1 2 2 3 1 1 2 1 2 2 2 1 2 2 0 2 2 2 1 1 2 2 2 2 2 1 2 2 3 2 2 2 1 2 2 2 1 2 2 2 2 2 2 2 2 2 2 2 1 2 2
3 0 2 3 1 0 2 3 3 1 1 1 1 2 2 2 1 2 2 0 2 2 2 2 1 2 1 2 2 2 1 1 1 1 1 2 2 1 2 2 2 1 2 2 1 2 2 2 2 2 2 2 2 2 2 2

```

Ek 3 Pima-Indian Diyabet Problemi İçin Veritabanı

(www.ics.uci.edu/pub/ml-repos/machine-learning-databases/pima indian)

1 85 66 29 0 26.6 0.351 31 0	0 102 78 40 90 34.5 0.238 24 0
4 131 68 21 166 33.1 0.160 28 0	2 111 60 0 0 26.2 0.343 23 0
1 164 82 43 67 32.8 0.341 50 0	1 128 82 17 183 27.5 0.115 22 0
4 84 90 23 56 39.5 0.159 25 0	10 92 62 0 0 25.9 0.167 31 0
1 100 74 12 46 19.5 0.149 28 0	5 104 74 0 0 28.8 0.153 48 0
0 102 86 17 105 29.3 0.695 27 0	2 94 76 18 66 31.6 0.649 23 0
4 128 70 0 0 34.3 0.303 24 0	6 98 58 33 190 34.0 0.430 43 0
1 124 60 32 0 35.8 0.514 21 0	9 154 78 30 100 30.9 0.164 45 0
4 90 0 0 0 28.0 0.610 31 0	6 165 68 26 168 33.6 0.631 49 0
3 103 72 30 152 27.6 0.730 27 0	1 99 58 10 0 25.4 0.551 21 0
2 157 74 35 440 39.4 0.134 30 0	10 68 106 23 49 35.5 0.285 47 0
0 107 60 25 0 26.4 0.133 23 0	3 123 100 35 240 57.3 0.880 22 0
1 91 54 25 100 25.2 0.234 23 0	8 91 82 0 0 35.6 0.587 68 0
1 117 60 23 106 33.8 0.466 27 0	0 99 0 0 0 25.0 0.253 22 0
5 123 74 40 77 34.1 0.269 28 0	4 127 88 11 155 34.5 0.598 28 0
2 120 54 0 0 26.8 0.455 27 0	4 118 70 0 0 44.5 0.904 26 0
1 106 70 28 135 34.2 0.142 22 0	2 122 76 27 200 35.9 0.483 26 0
2 101 58 35 90 21.8 0.155 22 0	0 134 58 20 291 26.4 0.352 21 0
1 120 80 48 200 38.9 1.162 41 0	3 102 74 0 0 29.5 0.121 32 0
11 127 106 0 0 39.0 0.190 51 0	10 94 72 18 0 23.1 0.595 56 0
10 162 84 0 0 27.7 0.182 54 0	3 158 64 13 387 31.2 0.295 24 0
1 112 80 45 132 34.8 0.217 24 0	5 126 78 27 22 29.6 0.439 40 0
1 88 78 29 76 32.0 0.365 29 0	2 127 46 21 335 34.4 0.176 22 0
4 189 110 31 0 28.5 0.680 37 0	1 108 60 46 178 35.5 0.415 24 0
1 116 70 28 0 27.4 0.204 21 0	0 93 60 0 0 35.3 0.263 25 0
3 84 68 30 106 31.9 0.591 25 0	2 101 58 17 265 24.2 0.614 23 0
6 114 88 0 0 27.8 0.247 66 0	2 56 56 28 45 24.2 0.332 22 0
1 88 62 24 44 29.9 0.422 23 0	0 95 64 39 105 44.6 0.366 22 0
1 84 64 23 115 36.9 0.471 28 0	5 136 82 0 0 0.0 0.640 69 0
7 124 70 33 215 25.5 0.161 37 0	2 129 74 26 205 33.2 0.591 25 0
1 97 70 40 0 38.1 0.218 30 0	3 130 64 0 0 23.1 0.314 22 0
1 92 62 25 41 19.5 0.482 25 0	1 107 50 19 0 28.3 0.181 29 0
0 152 82 39 272 41.5 0.270 27 0	1 140 74 26 180 24.1 0.828 23 0
1 111 62 13 182 24.0 0.138 23 0	8 107 80 0 0 24.6 0.856 34 0
3 106 54 21 158 30.9 0.292 24 0	2 90 60 0 0 23.5 0.191 25 0
0 67 76 0 0 45.3 0.194 46 0	2 121 70 32 95 39.1 0.886 23 0
1 89 24 19 25 27.8 0.559 21 0	8 110 76 0 0 27.8 0.237 58 0
1 109 38 18 120 23.1 0.407 26 0	11 103 68 40 0 46.2 0.126 42 0
1 108 88 19 0 27.1 0.400 24 0	11 85 74 0 0 30.1 0.300 35 0
6 96 0 0 0 23.7 0.190 28 0	1 87 68 34 77 37.6 0.401 24 0
1 124 74 36 0 27.8 0.100 30 0	6 99 60 19 54 26.9 0.497 32 0
3 106 72 0 0 25.8 0.207 27 0	0 91 80 0 0 32.4 0.601 27 0
6 105 80 28 0 32.5 0.878 26 0	2 95 54 14 88 26.1 0.748 22 0
6 117 96 0 0 28.7 0.157 30 0	1 99 72 30 18 38.6 0.412 21 0
2 68 62 13 15 20.1 0.257 23 0	6 92 62 32 126 32.0 0.085 46 0
2 112 86 42 160 38.4 0.246 28 0	4 154 72 29 126 31.3 0.338 37 0
2 92 76 20 0 24.2 1.698 28 0	3 78 70 0 0 32.5 0.270 39 0
6 183 94 0 0 40.8 1.461 45 0	2 130 96 0 0 22.6 0.268 21 0
0 94 70 27 115 43.5 0.347 21 0	3 111 58 31 44 29.5 0.430 22 0
2 108 64 0 0 30.8 0.158 21 0	2 98 60 17 120 34.7 0.198 22 0
4 90 88 47 54 37.7 0.362 29 0	1 143 86 30 330 30.1 0.892 23 0
0 125 68 0 0 24.7 0.206 21 0	1 119 44 47 63 35.5 0.280 25 0
0 132 78 0 0 32.4 0.393 21 0	6 108 44 20 130 24.0 0.813 35 0
5 128 80 0 0 34.6 0.144 45 0	10 133 68 0 0 27.0 0.245 36 0
4 94 65 22 0 24.7 0.148 21 0	6 109 60 27 0 25.0 0.206 27 0

12 121 78 17 0 26.5 0.259 62 0
 8 100 76 0 0 38.7 0.190 42 0
 1 93 56 11 0 22.5 0.417 22 0
 6 103 66 0 0 24.3 0.249 29 0
 0 73 0 0 0 21.1 0.342 25 0
 2 112 78 50 140 39.4 0.175 24 0
 2 82 52 22 115 28.5 1.699 25 0
 6 123 72 45 230 33.6 0.733 34 0
 1 89 66 23 94 28.1 0.167 21 0
 5 116 74 0 0 25.6 0.201 30 0
 10 115 0 0 0 35.3 0.134 29 0
 4 110 92 0 0 37.6 0.191 30 0
 10 139 80 0 0 27.1 1.441 57 0
 1 103 30 38 83 43.3 0.183 33 0
 3 126 88 41 235 39.3 0.704 27 0
 0 161 50 0 0 21.9 0.254 65 0
 6 151 62 31 120 35.5 0.692 28 0
 0 126 84 29 215 30.7 0.520 24 0
 8 112 72 0 0 23.6 0.840 58 0
 5 77 82 41 42 35.8 0.156 35 0
 3 150 76 0 0 21.0 0.207 37 0
 2 120 76 37 105 39.7 0.215 29 0
 0 137 68 14 148 24.8 0.143 21 0
 6 80 66 30 0 26.2 0.313 41 0
 0 106 70 37 148 39.4 0.605 22 0
 3 113 50 10 85 29.5 0.626 25 0
 2 112 68 22 94 34.1 0.315 26 0
 3 99 80 11 64 19.3 0.284 30 0
 3 115 66 39 140 38.1 0.150 28 0
 4 129 60 12 231 27.5 0.527 31 0
 2 112 75 32 0 35.7 0.148 21 0
 1 157 72 21 168 25.6 0.123 24 0
 6 105 70 32 68 30.8 0.122 37 0
 8 118 72 19 0 23.1 1.476 46 0
 2 87 58 16 52 32.7 0.166 25 0
 12 106 80 0 0 23.6 0.137 44 0
 1 95 60 18 58 23.9 0.260 22 0
 1 130 70 13 105 25.9 0.472 22 0
 1 95 74 21 73 25.9 0.673 36 0
 1 0 68 35 0 32.0 0.389 22 0
 5 122 86 0 0 34.7 0.290 33 0
 8 95 72 0 0 36.8 0.485 57 0
 8 126 88 36 108 38.5 0.349 49 0
 0 165 76 43 255 47.9 0.259 26 0
 0 117 0 0 0 33.8 0.932 44 0
 10 179 70 0 0 35.1 0.200 37 0
 2 99 52 15 94 24.6 0.637 21 0
 1 109 56 21 135 25.2 0.833 23 0
 1 153 82 42 485 40.6 0.687 23 0
 2 88 74 19 53 29.0 0.229 22 0
 4 151 90 38 0 29.7 0.294 36 0
 5 96 74 18 67 33.6 0.997 43 0
 2 128 64 42 0 40.0 1.101 24 0
 0 102 52 0 0 25.1 0.078 21 0
 0 104 64 23 116 27.8 0.454 23 0
 5 114 74 0 0 24.9 0.744 57 0
 2 108 62 32 56 25.2 0.128 21 0
 3 122 78 0 0 23.0 0.254 40 0
 1 71 78 50 45 33.2 0.422 21 0
 13 106 70 0 0 34.2 0.251 52 0

2 100 70 52 57 40.5 0.677 25 0
 3 191 68 15 130 30.9 0.299 34 0
 4 95 70 32 0 32.1 0.612 24 0
 3 142 80 15 0 32.4 0.200 63 0
 2 108 62 10 278 25.3 0.881 22 0
 10 129 76 28 122 35.9 0.280 39 0
 1 139 46 19 83 28.7 0.654 22 0
 3 116 0 0 0 23.5 0.187 23 0
 3 99 62 19 74 21.8 0.279 26 0
 4 92 80 0 0 42.2 0.237 29 0
 4 137 84 0 0 31.2 0.252 30 0
 3 61 82 28 0 34.4 0.243 46 0
 1 90 62 12 43 27.2 0.580 24 0
 3 90 78 0 0 42.7 0.559 21 0
 12 88 74 40 54 35.3 0.378 48 0
 5 158 70 0 0 29.8 0.207 63 0
 5 103 108 37 0 39.2 0.305 65 0
 4 147 74 25 293 34.9 0.385 30 0
 5 99 54 28 83 34.0 0.499 30 0
 0 101 64 17 0 21.0 0.252 21 0
 3 81 86 16 66 27.5 0.306 22 0
 0 118 64 23 89 0.0 1.731 21 0
 0 84 64 22 66 35.8 0.545 21 0
 2 105 58 40 94 34.9 0.225 25 0
 2 122 52 43 158 36.2 0.816 28 0
 0 98 82 15 84 25.2 0.299 22 0
 1 87 60 37 75 37.2 0.509 22 0
 0 93 100 39 72 43.4 1.021 35 0
 1 107 72 30 82 30.8 0.821 24 0
 0 105 68 22 0 20.0 0.236 22 0
 1 109 60 8 182 25.4 0.947 21 0
 1 90 62 18 59 25.1 1.268 25 0
 1 125 70 24 110 24.3 0.221 25 0
 1 119 54 13 50 22.3 0.205 24 0
 3 100 68 23 81 31.6 0.949 28 0
 1 100 66 29 196 32.0 0.444 42 0
 1 131 64 14 415 23.7 0.389 21 0
 4 116 72 12 87 22.1 0.463 37 0
 2 127 58 24 275 27.7 1.600 25 0
 3 96 56 34 115 24.7 0.944 39 0
 3 82 70 0 0 21.1 0.389 25 0
 7 133 88 15 155 32.4 0.262 37 0
 7 136 74 26 135 26.0 0.647 51 0
 5 155 84 44 545 38.7 0.619 34 0
 4 96 56 17 49 20.8 0.340 26 0
 5 108 72 43 75 36.1 0.263 33 0
 0 78 88 29 40 36.9 0.434 21 0
 7 102 74 40 105 37.2 0.204 45 0
 0 114 80 34 285 44.2 0.167 27 0
 2 100 64 23 0 29.7 0.368 21 0
 3 148 66 25 0 32.5 0.256 22 0
 4 120 68 0 0 29.6 0.709 34 0
 4 110 66 0 0 31.9 0.471 29 0
 3 111 90 12 78 28.4 0.495 29 0
 2 87 0 23 0 28.9 0.773 25 0
 1 79 60 42 48 43.5 0.678 23 0
 2 75 64 24 55 29.7 0.370 33 0
 6 85 78 0 0 31.2 0.382 42 0
 5 143 78 0 0 45.0 0.190 47 0
 6 87 80 0 0 23.2 0.084 32 0

0 119 64 18 92 34.9 0.725 23 0
 1 0 74 20 23 27.7 0.299 21 0
 5 73 60 0 0 26.8 0.268 27 0
 4 141 74 0 0 27.6 0.244 40 0
 3 111 62 0 0 22.6 0.142 21 0
 9 123 70 44 94 33.1 0.374 40 0
 8 85 55 20 0 24.4 0.136 42 0
 1 105 58 0 0 24.3 0.187 21 0
 1 97 66 15 140 23.2 0.487 22 0
 13 145 82 19 110 22.2 0.245 57 0
 3 88 58 11 54 24.8 0.267 22 0
 6 92 92 0 0 19.9 0.188 28 0
 10 122 78 31 0 27.6 0.512 45 0
 4 103 60 33 192 24.0 0.966 33 0
 3 180 64 25 70 34.0 0.271 26 0
 7 159 64 0 0 27.4 0.294 40 0
 1 139 62 41 480 40.7 0.536 21 0
 0 173 78 32 265 46.5 1.159 58 0
 4 99 72 17 0 25.6 0.294 28 0
 8 194 80 0 0 26.1 0.551 67 0
 2 83 65 28 66 36.8 0.629 24 0
 2 89 90 30 0 33.5 0.292 42 0
 4 99 68 38 0 32.8 0.145 33 0
 3 80 0 0 0 0.0 0.174 22 0
 6 166 74 0 0 26.6 0.304 66 0
 5 110 68 0 0 26.0 0.292 30 0
 2 81 72 15 76 30.1 0.547 25 0
 7 133 84 0 0 40.2 0.696 37 0
 7 106 92 18 0 22.7 0.235 48 0
 1 146 56 0 0 29.7 0.564 29 0
 2 71 70 27 0 28.0 0.586 22 0
 11 138 76 0 0 33.2 0.420 35 0
 5 117 92 0 0 34.1 0.337 38 0
 5 109 75 26 0 36.0 0.546 60 0
 8 99 84 0 0 35.4 0.388 50 0
 7 150 66 42 342 34.7 0.718 42 0
 1 73 50 10 0 23.0 0.248 21 0
 7 105 0 0 0 0.0 0.305 24 0
 1 103 80 11 82 19.4 0.491 22 0
 1 101 50 15 36 24.2 0.526 26 0
 5 88 66 21 23 24.4 0.342 30 0
 5 99 74 27 0 29.0 0.203 32 0
 2 109 92 0 0 42.7 0.845 54 0
 5 44 62 0 0 25.0 0.587 36 0
 2 141 58 34 128 25.4 0.699 24 0
 0 100 88 60 110 46.8 0.962 31 0
 0 146 82 0 0 40.5 1.781 44 0
 0 105 64 41 142 41.5 0.173 22 0
 2 84 0 0 0 0.0 0.304 21 0
 1 95 66 13 38 19.6 0.334 25 0
 4 146 85 27 100 28.9 0.189 27 0
 5 139 64 35 140 28.6 0.411 26 0
 4 129 86 20 270 35.1 0.231 23 0
 1 79 75 30 0 32.0 0.396 22 0
 1 0 48 20 0 24.7 0.140 22 0
 7 62 78 0 0 32.6 0.391 41 0
 5 95 72 33 0 37.7 0.370 27 0
 2 112 66 22 0 25.0 0.307 24 0
 3 113 44 13 0 22.4 0.140 22 0
 2 74 0 0 0 0.0 0.102 22 0

7 83 78 26 71 29.3 0.767 36 0
 0 101 65 28 0 24.6 0.237 22 0
 2 110 74 29 125 32.4 0.698 27 0
 13 106 72 54 0 36.6 0.178 45 0
 2 100 68 25 71 38.5 0.324 26 0
 1 107 68 19 0 26.5 0.165 24 0
 1 80 55 0 0 19.1 0.258 21 0
 4 123 80 15 176 32.0 0.443 34 0
 7 81 78 40 48 46.7 0.261 42 0
 2 142 82 18 64 24.7 0.761 21 0
 6 144 72 27 228 33.9 0.255 40 0
 9 72 78 25 0 31.6 0.280 38 0
 6 137 61 0 0 24.2 0.151 55 0
 2 123 48 32 165 42.1 0.520 26 0
 0 101 62 0 0 21.9 0.336 25 0
 6 102 90 39 0 35.7 0.674 28 0
 1 112 72 30 176 34.4 0.528 25 0
 1 143 84 23 310 42.4 1.076 22 0
 1 143 74 22 61 26.2 0.256 21 0
 1 97 68 21 0 27.2 1.095 22 0
 1 83 68 0 0 18.2 0.624 27 0
 1 119 88 41 170 45.3 0.507 26 0
 2 94 68 18 76 26.0 0.561 21 0
 0 102 64 46 78 40.6 0.496 21 0
 2 115 64 22 0 30.8 0.421 21 0
 0 94 0 0 0 0.0 0.256 25 0
 0 135 94 46 145 40.6 0.284 26 0
 2 99 0 0 0 22.2 0.108 23 0
 3 89 74 16 85 30.4 0.551 38 0
 1 80 74 11 60 30.0 0.527 22 0
 2 139 75 0 0 25.6 0.167 29 0
 1 90 68 8 0 24.5 1.138 36 0
 12 140 85 33 0 37.4 0.244 41 0
 5 147 75 0 0 29.9 0.434 28 0
 1 97 70 15 0 18.2 0.147 21 0
 6 107 88 0 0 36.8 0.727 31 0
 2 83 66 23 50 32.2 0.497 22 0
 4 117 64 27 120 33.2 0.230 24 0
 1 100 72 12 70 25.3 0.658 28 0
 0 95 80 45 92 36.5 0.330 26 0
 0 120 74 18 63 30.5 0.285 26 0
 1 82 64 13 95 21.2 0.415 23 0
 0 91 68 32 210 39.9 0.381 25 0
 2 119 0 0 0 19.6 0.832 72 0
 2 100 54 28 105 37.8 0.498 24 0
 1 135 54 0 0 26.7 0.687 62 0
 5 86 68 28 71 30.2 0.364 24 0
 9 134 74 33 60 25.9 0.460 81 0
 9 120 72 22 56 20.8 0.733 48 0
 1 71 62 0 0 21.8 0.416 26 0
 8 74 70 40 49 35.3 0.705 39 0
 5 88 78 30 0 27.6 0.258 37 0
 10 115 98 0 0 24.0 1.022 34 0
 0 124 56 13 105 21.8 0.452 21 0
 0 74 52 10 36 27.8 0.269 22 0
 0 97 64 36 100 36.8 0.600 25 0
 6 154 78 41 140 46.1 0.571 27 0
 1 144 82 40 0 41.3 0.607 28 0
 0 137 70 38 0 33.2 0.170 22 0
 0 119 66 27 0 38.8 0.259 22 0

7 136 90 0 0 29.9 0.210 50 0
 4 114 64 0 0 28.9 0.126 24 0
 0 137 84 27 0 27.3 0.231 59 0
 7 114 76 17 110 23.8 0.466 31 0
 8 126 74 38 75 25.9 0.162 39 0
 4 132 86 31 0 28.0 0.419 63 0
 0 123 88 37 0 35.2 0.197 29 0
 4 85 58 22 49 27.8 0.306 28 0
 0 84 82 31 125 38.2 0.233 23 0
 2 92 62 28 0 31.6 0.130 24 0
 1 71 48 18 76 20.4 0.323 22 0
 6 93 50 30 64 28.7 0.356 23 0
 1 151 60 0 0 26.1 0.179 22 0
 0 125 96 0 0 22.5 0.262 21 0
 1 81 72 18 40 26.6 0.283 24 0
 2 85 65 0 0 39.6 0.930 27 0
 1 126 56 29 152 28.7 0.801 21 0
 6 154 74 32 193 29.3 0.839 39 0
 2 117 90 19 71 25.2 0.313 21 0
 3 84 72 32 0 37.2 0.267 28 0
 7 94 64 25 79 33.3 0.738 41 0
 3 96 78 39 0 37.3 0.238 40 0
 10 75 82 0 0 33.3 0.263 38 0
 1 130 60 23 170 28.6 0.692 21 0
 2 84 50 23 76 30.4 0.968 21 0
 8 120 78 0 0 25.0 0.409 64 0
 0 139 62 17 210 22.1 0.207 21 0
 9 91 68 0 0 24.2 0.200 58 0
 2 91 62 0 0 27.3 0.525 22 0
 3 99 54 19 86 25.6 0.154 24 0
 7 125 86 0 0 37.6 0.304 51 0
 13 76 60 0 0 32.8 0.180 41 0
 6 129 90 7 326 19.6 0.582 60 0
 2 68 70 32 66 25.0 0.187 25 0
 3 124 80 33 130 33.2 0.305 26 0
 6 114 0 0 0 0.0 0.189 26 0
 3 125 58 0 0 31.6 0.151 24 0
 3 87 60 18 0 21.8 0.444 21 0
 1 97 64 19 82 18.2 0.299 21 0
 3 116 74 15 105 26.3 0.107 24 0
 0 117 66 31 188 30.8 0.493 22 0
 0 111 65 0 0 24.6 0.660 31 0
 2 122 60 18 106 29.8 0.717 22 0
 4 83 86 19 0 29.3 0.317 34 0
 1 114 66 36 200 38.1 0.289 21 0
 5 117 86 30 105 39.1 0.251 42 0
 1 111 94 0 0 32.8 0.265 45 0
 4 112 78 40 0 39.4 0.236 38 0
 1 116 78 29 180 36.1 0.496 25 0
 0 141 84 26 0 32.4 0.433 22 0
 2 175 88 0 0 22.9 0.326 22 0
 2 92 52 0 0 30.1 0.141 22 0
 2 129 0 0 0 38.5 0.304 41 0
 4 110 76 20 100 28.4 0.118 27 0
 6 80 80 36 0 39.8 0.177 28 0
 2 106 56 27 165 29.0 0.426 22 0
 2 105 75 0 0 23.3 0.560 53 0
 4 95 60 32 0 35.4 0.284 28 0
 0 126 86 27 120 27.4 0.515 21 0
 8 65 72 23 0 32.0 0.600 42 0

2 99 60 17 160 36.6 0.453 21 0
 3 102 44 20 94 30.8 0.400 26 0
 1 109 58 18 116 28.5 0.219 22 0
 7 137 90 41 0 32.0 0.391 39 0
 13 153 88 37 140 40.6 1.174 39 0
 12 100 84 33 105 30.0 0.488 46 0
 9 89 62 0 0 22.5 0.142 33 0
 10 101 76 48 180 32.9 0.171 63 0
 2 122 70 27 0 36.8 0.340 27 0
 5 121 72 23 112 26.2 0.245 30 0
 1 93 70 31 0 30.4 0.315 23 0
 1 81 74 41 57 46.3 1.096 32 0
 1 121 78 39 74 39.0 0.261 28 0
 3 108 62 24 0 26.0 0.223 25 0
 1 106 76 0 0 37.5 0.197 26 0
 2 88 58 26 16 28.4 0.766 22 0
 0 107 76 0 0 45.3 0.686 24 0
 1 86 66 52 65 41.3 0.917 29 0
 6 91 0 0 0 29.8 0.501 31 0
 1 77 56 30 56 33.3 1.251 24 0
 0 105 90 0 0 29.6 0.197 46 0
 0 57 60 0 0 21.7 0.735 67 0
 0 127 80 37 210 36.3 0.804 23 0
 1 96 122 0 0 22.4 0.207 27 0
 4 144 58 28 140 29.5 0.287 37 0
 3 83 58 31 18 34.3 0.336 25 0
 1 89 76 34 37 31.2 0.192 23 0
 4 76 62 0 0 34.0 0.391 25 0
 5 78 48 0 0 33.7 0.654 25 0
 4 97 60 23 0 28.2 0.443 22 0
 4 99 76 15 51 23.2 0.223 21 0
 6 111 64 39 0 34.2 0.260 24 0
 2 107 74 30 100 33.6 0.404 23 0
 5 132 80 0 0 26.8 0.186 69 0
 3 120 70 30 135 42.9 0.452 30 0
 1 118 58 36 94 33.3 0.261 23 0
 8 84 74 31 0 38.3 0.457 39 0
 2 96 68 13 49 21.1 0.647 26 0
 2 125 60 20 140 33.8 0.088 31 0
 0 100 70 26 50 30.8 0.597 21 0
 0 93 60 25 92 28.7 0.532 22 0
 0 129 80 0 0 31.2 0.703 29 0
 5 105 72 29 325 36.9 0.159 28 0
 3 128 78 0 0 21.1 0.268 55 0
 5 106 82 30 0 39.5 0.286 38 0
 2 108 52 26 63 32.5 0.318 22 0
 4 154 62 31 284 32.8 0.237 23 0
 0 102 75 23 0 0.0 0.572 21 0
 9 57 80 37 0 32.8 0.096 41 0
 2 106 64 35 119 30.5 1.400 34 0
 5 147 78 0 0 33.7 0.218 65 0
 2 90 70 17 0 27.3 0.085 22 0
 1 136 74 50 204 37.4 0.399 24 0
 4 114 65 0 0 21.9 0.432 37 0
 0 113 80 16 0 31.0 0.874 21 0
 1 138 82 0 0 40.1 0.236 28 0
 0 108 68 20 0 27.3 0.787 32 0
 2 99 70 16 44 20.4 0.235 27 0
 6 103 72 32 190 37.7 0.324 55 0
 5 111 72 28 0 23.9 0.407 27 0

1 96 64 27 87 33.2 0.289 21 0	2 100 66 20 90 32.9 0.867 28 1
2 81 60 22 0 27.7 0.290 25 0	0 109 88 30 0 32.5 0.855 38 1
0 147 85 54 0 42.8 0.375 24 0	0 131 0 0 0 43.2 0.270 26 1
7 179 95 31 0 34.2 0.164 60 0	5 137 108 0 0 48.8 0.227 37 1
6 125 68 30 120 30.0 0.464 32 0	15 136 70 32 110 37.1 0.153 43 1
7 119 0 0 0 25.2 0.209 37 0	4 134 72 0 0 23.8 0.277 60 1
7 142 60 33 190 28.8 0.687 61 0	1 122 90 51 220 49.7 0.325 31 1
1 100 66 15 56 23.6 0.666 26 0	1 163 72 0 0 39.0 1.222 33 1
1 87 78 27 32 34.6 0.101 22 0	0 95 85 25 36 37.4 0.247 24 1
0 101 76 0 0 35.7 0.198 26 0	3 171 72 33 135 33.3 0.199 24 1
4 197 70 39 744 36.7 2.329 31 0	8 155 62 26 495 34.0 0.543 46 1
0 117 80 31 53 45.2 0.089 24 0	7 160 54 32 175 30.5 0.588 39 1
1 79 80 25 37 25.4 0.583 22 0	4 146 92 0 0 31.2 0.539 61 1
4 122 68 0 0 35.0 0.394 29 0	1 117 88 24 145 34.5 0.403 40 1
3 74 68 28 45 29.7 0.293 23 0	4 156 75 0 0 48.3 0.238 32 1
0 104 76 0 0 18.4 0.582 27 0	5 166 76 0 0 45.7 0.340 27 1
1 91 64 24 0 29.2 0.192 21 0	0 105 84 0 0 27.9 0.741 62 1
4 91 70 32 88 33.1 0.446 22 0	4 173 70 14 168 29.7 0.361 33 1
2 146 76 35 194 38.2 0.329 29 0	9 122 56 0 0 33.3 1.114 33 1
10 122 68 0 0 31.2 0.258 41 0	3 170 64 37 225 34.5 0.356 30 1
0 165 90 33 680 52.3 0.427 23 0	0 113 76 0 0 33.3 0.278 23 1
9 124 70 33 402 35.4 0.282 34 0	1 88 30 42 99 55.0 0.496 26 1
1 111 86 19 0 30.1 0.143 23 0	5 124 74 0 0 34.0 0.220 38 1
9 106 52 0 0 31.2 0.380 42 0	10 108 66 0 0 32.4 0.272 42 1
2 129 84 0 0 28.0 0.284 27 0	0 162 76 56 100 53.2 0.759 25 1
2 90 80 14 55 24.4 0.249 24 0	9 156 86 28 155 34.3 1.189 42 1
0 86 68 32 0 35.8 0.238 25 0	8 188 78 0 0 47.9 0.137 43 1
3 111 56 39 0 30.1 0.557 30 0	17 163 72 41 114 40.9 0.817 47 1
2 114 68 22 0 28.7 0.092 25 0	0 131 88 0 0 31.6 0.743 32 1
1 193 50 16 375 25.9 0.655 24 0	6 104 74 18 156 29.9 0.722 41 1
8 183 64 0 0 23.3 0.672 32 1	7 152 88 44 0 50.0 0.337 36 1
0 137 40 35 168 43.1 2.288 33 1	6 102 82 0 0 30.8 0.180 36 1
3 78 50 32 88 31.0 0.248 26 1	6 134 70 23 130 35.4 0.542 29 1
2 197 70 45 543 30.5 0.158 53 1	8 179 72 42 130 32.7 0.719 36 1
6 148 72 35 0 33.6 0.627 50 1	0 129 110 46 130 67.1 0.319 26 1
8 125 96 0 0 0.0 0.232 54 1	5 158 84 41 210 39.4 0.395 29 1
10 168 74 0 0 38.0 0.537 34 1	7 159 66 0 0 30.4 0.383 36 1
1 189 60 23 846 30.1 0.398 59 1	11 135 0 0 0 52.3 0.578 40 1
5 166 72 19 175 25.8 0.587 51 1	5 130 82 0 0 39.1 0.956 37 1
7 100 0 0 0 30.0 0.484 32 1	7 194 68 28 0 35.9 0.745 41 1
0 118 84 47 230 45.8 0.551 31 1	8 181 68 36 495 30.1 0.615 60 1
7 107 74 0 0 29.6 0.254 31 1	1 128 98 41 58 32.0 1.321 33 1
1 115 70 30 96 34.6 0.529 32 1	8 109 76 39 114 27.9 0.640 31 1
7 196 90 0 0 39.8 0.451 41 1	5 139 80 35 160 31.6 0.361 25 1
9 119 80 35 0 29.0 0.263 29 1	3 107 62 13 48 22.9 0.678 23 1
11 143 94 33 146 36.6 0.254 51 1	0 140 65 26 130 42.6 0.431 24 1
10 125 70 26 115 31.1 0.205 41 1	9 112 82 32 175 34.2 0.260 36 1
7 147 76 0 0 39.4 0.257 43 1	12 151 70 40 271 41.8 0.742 38 1
3 158 76 36 245 31.6 0.851 28 1	5 109 62 41 129 35.8 0.514 25 1
9 102 76 37 0 32.9 0.665 46 1	4 109 64 44 99 34.8 0.905 26 1
2 90 68 42 0 38.2 0.503 27 1	5 85 74 22 0 29.0 1.224 32 1
4 111 72 47 207 37.1 1.390 56 1	5 112 66 0 0 37.8 0.261 41 1
9 171 110 24 240 45.4 0.721 54 1	0 177 60 29 478 34.6 1.072 21 1
0 180 66 39 0 42.0 1.893 25 1	2 158 90 0 0 31.6 0.805 66 1
7 103 66 32 0 39.1 0.344 31 1	4 148 60 27 318 30.9 0.150 29 1
8 176 90 34 300 33.7 0.467 58 1	3 162 52 38 0 37.2 0.652 24 1
7 187 68 39 304 37.7 0.254 41 1	7 184 84 33 0 35.5 0.355 41 1
8 133 72 0 0 32.9 0.270 39 1	4 142 86 0 0 44.0 0.645 22 1
7 114 66 0 0 32.8 0.258 42 1	6 134 80 37 370 46.2 0.238 46 1
13 126 90 0 0 43.4 0.583 42 1	8 196 76 29 280 37.5 0.605 57 1

5 162 104 0 0 37.7 0.151 52 1
 4 171 72 0 0 43.6 0.479 26 1
 7 181 84 21 192 35.9 0.586 51 1
 0 179 90 27 0 44.1 0.686 23 1
 9 164 84 21 0 30.8 0.831 32 1
 3 139 54 0 0 25.6 0.402 22 1
 6 119 50 22 176 27.1 1.318 33 1
 12 92 62 7 258 27.6 0.926 44 1
 1 113 64 35 0 33.6 0.543 21 1
 9 184 85 15 0 30.0 1.213 49 1
 11 155 76 28 150 33.3 1.353 51 1
 3 141 0 0 0 30.0 0.761 27 1
 4 123 62 0 0 32.0 0.226 35 1
 0 138 0 0 0 36.3 0.933 25 1
 2 146 0 0 0 27.5 0.240 28 1
 10 101 86 37 0 45.6 1.136 38 1
 7 106 60 24 0 26.5 0.296 29 1
 0 146 70 0 0 37.9 0.334 28 1
 14 100 78 25 184 36.6 0.412 46 1
 2 146 70 38 360 28.0 0.337 29 1
 0 167 0 0 0 32.3 0.839 30 1
 2 144 58 33 135 31.6 0.422 25 1
 7 161 86 0 0 30.4 0.165 47 1
 2 108 80 0 0 27.0 0.259 52 1
 1 119 86 39 220 45.6 0.808 29 1
 5 115 98 0 0 52.9 0.209 28 1
 0 107 62 30 74 36.6 0.757 25 1
 2 128 78 37 182 43.3 1.224 31 1
 1 128 48 45 194 40.5 0.613 24 1
 10 161 68 23 132 25.5 0.326 47 1
 0 128 68 19 180 30.5 1.391 25 1
 2 124 68 28 205 32.9 0.875 30 1
 2 155 74 17 96 26.6 0.433 27 1
 7 109 80 31 0 35.9 1.127 43 1
 3 182 74 0 0 30.5 0.345 29 1
 6 194 78 0 0 23.5 0.129 59 1
 3 112 74 30 0 31.6 0.197 25 1
 0 124 70 20 0 27.4 0.254 36 1
 13 152 90 33 29 26.8 0.731 43 1
 1 122 64 32 156 35.1 0.692 30 1
 2 102 86 36 120 45.5 0.127 23 1
 9 165 88 0 0 30.4 0.302 49 1
 1 125 50 40 167 33.3 0.962 28 1
 1 196 76 36 249 36.5 0.875 29 1
 5 189 64 33 325 31.2 0.583 29 1
 13 129 0 30 0 39.9 0.569 44 1
 4 146 78 0 0 38.5 0.520 67 1
 6 124 72 0 0 27.6 0.368 29 1
 1 180 0 0 0 43.3 0.282 41 1
 5 115 76 0 0 31.2 0.343 44 1
 9 152 78 34 171 34.2 0.893 33 1
 1 133 102 28 140 32.8 0.234 45 1
 3 173 82 48 465 38.4 2.137 25 1
 12 140 82 43 325 39.2 0.528 58 1
 5 0 80 32 0 41.0 0.346 37 1
 7 178 84 0 0 39.9 0.331 41 1
 5 116 74 29 0 32.3 0.660 35 1
 8 105 100 36 0 43.3 0.239 45 1
 5 144 82 26 285 32.0 0.452 58 1
 4 158 78 0 0 32.9 0.803 31 1
 0 131 66 40 0 34.3 0.196 22 1
 3 193 70 31 0 34.9 0.241 25 1
 4 95 64 0 0 32.0 0.161 31 1
 5 136 84 41 88 35.0 0.286 35 1
 5 168 64 0 0 32.9 0.135 41 1
 4 115 72 0 0 28.9 0.376 46 1
 8 197 74 0 0 25.9 1.191 39 1
 1 172 68 49 579 42.4 0.702 28 1
 0 138 60 35 167 34.6 0.534 21 1
 3 173 84 33 474 35.7 0.258 22 1
 4 144 82 32 0 38.5 0.554 37 1
 3 129 64 29 115 26.4 0.219 28 1
 8 151 78 32 210 42.9 0.516 36 1
 4 184 78 39 277 37.0 0.264 31 1
 1 181 64 30 180 34.1 0.328 38 1
 1 95 82 25 180 35.0 0.233 43 1
 0 141 0 0 0 42.4 0.205 29 1
 0 189 104 25 0 34.3 0.435 41 1
 8 108 70 0 0 30.5 0.955 33 1
 4 117 62 12 0 29.7 0.380 30 1
 0 180 78 63 14 59.4 2.420 25 1
 2 134 70 0 0 28.9 0.542 23 1
 0 104 64 37 64 33.6 0.510 22 1
 14 175 62 30 0 33.6 0.212 38 1
 10 148 84 48 237 37.6 1.001 51 1
 2 105 80 45 191 33.7 0.711 29 1
 4 125 70 18 122 28.9 1.144 45 1
 8 120 0 0 0 30.0 0.183 38 1
 3 158 70 30 328 35.5 0.344 35 1
 6 0 68 41 0 39.0 0.727 41 1
 0 145 0 0 0 44.2 0.630 31 1
 0 135 68 42 250 42.3 0.365 24 1
 7 195 70 33 145 25.1 0.163 55 1
 3 163 70 18 105 31.6 0.268 28 1
 9 145 88 34 165 30.3 0.771 53 1
 9 130 70 0 0 34.2 0.652 45 1
 12 84 72 31 0 29.7 0.297 46 1
 0 180 90 26 90 36.5 0.314 35 1
 4 132 0 0 0 32.9 0.302 23 1
 3 129 92 49 155 36.4 0.968 32 1
 8 100 74 40 215 39.4 0.661 43 1
 3 128 72 25 190 32.4 0.549 27 1
 10 90 85 32 0 34.9 0.825 56 1
 8 186 6 90 35 225 34.5 0.423 37 1
 6 125 76 0 0 33.8 0.121 54 1
 0 198 66 32 274 41.3 0.502 28 1
 5 187 76 27 207 43.6 1.034 53 1
 0 121 66 30 165 34.3 0.203 33 1
 2 118 80 0 0 42.9 0.693 21 1
 2 197 70 99 0 34.7 0.575 62 1
 0 151 90 46 0 42.1 0.371 21 1
 8 124 76 24 600 28.7 0.687 52 1
 3 176 86 27 156 33.3 1.154 52 1
 11 111 84 40 0 46.8 0.925 45 1
 3 132 80 0 0 34.4 0.402 44 1
 8 143 66 0 0 34.9 0.129 41 1
 0 188 82 14 185 32.0 0.682 22 1
 7 150 78 29 126 35.2 0.692 54 1
 4 183 0 0 0 28.4 0.212 36 1
 1 181 78 42 293 40.0 1.258 22 1

3 174 58 22 194 32.9 0.593 36 1
 1 173 74 0 0 36.8 0.088 38 1
 7 168 88 42 321 38.2 0.787 40 1
 11 138 74 26 144 36.1 0.557 50 1
 7 114 64 0 0 27.4 0.732 34 1
 9 112 82 24 0 28.2 1.282 50 1
 13 104 72 0 0 31.2 0.465 38 1
 0 119 0 0 0 32.4 0.141 24 1
 7 97 76 32 91 40.9 0.871 32 1
 6 147 80 0 0 29.5 0.178 50 1
 1 167 74 17 144 23.4 0.447 33 1
 0 179 50 36 159 37.8 0.455 22 1
 11 136 84 35 130 28.3 0.260 42 1
 2 155 52 27 540 38.7 0.240 25 1
 1 199 76 43 0 42.9 1.394 22 1
 8 167 106 46 231 37.6 0.165 43 1
 3 80 82 31 70 34.2 1.292 27 1
 9 145 80 46 130 37.9 0.637 40 1
 6 115 60 39 0 33.7 0.245 40 1
 4 145 82 18 0 32.5 0.235 70 1
 10 111 70 27 0 27.5 0.141 40 1
 13 158 114 0 0 42.3 0.257 44 1
 4 125 80 0 0 32.3 0.536 27 1
 1 144 82 46 180 46.1 0.335 46 1
 3 121 52 0 0 36.0 0.127 25 1
 6 195 70 0 0 30.9 0.328 31 1
 9 156 86 0 0 24.8 0.230 53 1
 0 162 76 36 0 49.6 0.364 26 1
 7 129 68 49 125 38.5 0.439 43 1

7 142 90 24 480 30.4 0.128 43 1
 3 169 74 19 125 29.9 0.268 31 1
 6 125 78 31 0 27.6 0.565 49 1
 1 168 88 29 0 35.0 0.905 52 1
 10 115 0 0 0 0.0 0.261 30 1
 1 147 94 41 0 49.3 0.358 27 1
 3 187 70 22 200 36.4 0.408 36 1
 6 162 62 0 0 24.3 0.178 50 1
 1 102 74 0 0 39.5 0.293 42 1
 11 120 80 37 150 42.3 0.785 48 1
 4 136 70 0 0 31.2 1.182 22 1
 0 181 88 44 510 43.3 0.222 26 1
 3 130 78 23 79 28.4 0.323 34 1
 8 120 86 0 0 28.4 0.259 22 1
 2 174 88 37 120 44.5 0.646 24 1
 8 154 78 32 0 32.4 0.443 45 1
 1 128 88 39 110 36.5 1.057 37 1
 7 187 50 33 392 33.9 0.826 34 1
 3 173 78 39 185 33.8 0.970 31 1
 0 123 72 0 0 36.3 0.258 52 1
 9 140 94 0 0 32.7 0.734 45 1
 6 190 92 0 0 35.5 0.278 66 1
 9 170 74 31 0 44.0 0.403 43 1
 9 164 78 0 0 32.8 0.148 45 1
 2 93 64 32 160 38.0 0.674 23 1
 1 149 68 29 127 29.3 0.349 42 1
 1 126 60 0 0 30.1 0.349 47 1
 10 129 62 36 0 41.2 0.441 38 1
 5 97 76 27 0 35.6 0.378 52 1

Ek 4 Fetus Gelişimi Problemi İçin Veritabanı

1. Alt Küme:

0.500 1.06 0.65 3.02 0.9 0.1	0.750 1.15 0.67 3.40 0.9 0.1
0.500 1.10 0.70 3.30 0.9 0.1	0.775 0.90 0.61 2.80 0.9 0.1
0.500 1.25 0.75 3.50 0.9 0.1	0.775 0.96 0.62 2.90 0.9 0.1
0.500 1.20 0.73 3.40 0.9 0.1	0.775 0.98 0.68 3.30 0.9 0.1
0.500 1.40 0.84 7.00 0.9 0.1	0.775 1.10 0.65 3.50 0.9 0.1
0.500 1.37 0.80 6.00 0.9 0.1	0.775 1.20 0.70 3.70 0.9 0.1
0.525 0.99 0.65 3.00 0.9 0.1	0.800 0.70 0.53 2.30 0.9 0.1
0.525 1.20 0.68 3.30 0.9 0.1	0.800 0.80 0.55 2.50 0.9 0.1
0.525 1.15 0.66 3.60 0.9 0.1	0.800 0.95 0.60 2.80 0.9 0.1
0.525 1.23 0.70 4.00 0.9 0.1	0.800 1.15 0.65 3.50 0.9 0.1
0.525 1.30 0.74 4.18 0.9 0.1	0.800 1.10 0.66 3.70 0.9 0.1
0.550 0.98 0.64 2.90 0.9 0.1	0.825 0.70 0.56 2.30 0.9 0.1
0.550 1.00 0.65 3.05 0.9 0.1	0.825 0.80 0.57 2.40 0.9 0.1
0.550 1.15 0.67 3.00 0.9 0.1	0.825 0.85 0.58 2.50 0.9 0.1
0.550 1.18 0.69 3.50 0.9 0.1	0.825 0.95 0.65 2.90 0.9 0.1
0.550 1.20 0.70 3.90 0.9 0.1	0.825 0.98 0.66 3.30 0.9 0.1
0.575 0.94 0.63 2.80 0.9 0.1	0.850 0.80 0.57 2.45 0.9 0.1
0.575 1.05 0.68 3.20 0.9 0.1	0.850 0.85 0.60 2.55 0.9 0.1
0.575 1.10 0.65 3.00 0.9 0.1	0.850 0.88 0.61 2.65 0.9 0.1
0.575 1.70 0.71 3.40 0.9 0.1	0.850 1.00 0.64 2.80 0.9 0.1
0.575 1.20 0.75 3.60 0.9 0.1	0.850 1.05 0.65 2.95 0.9 0.1
0.600 0.90 0.62 2.70 0.9 0.1	0.875 0.70 0.52 2.30 0.9 0.1
0.600 0.95 0.64 2.90 0.9 0.1	0.875 0.75 0.51 2.40 0.9 0.1
0.600 1.00 0.65 3.10 0.9 0.1	0.875 0.85 0.56 2.55 0.9 0.1
0.600 1.10 0.69 3.40 0.9 0.1	0.875 0.90 0.60 2.80 0.9 0.1
0.600 1.19 0.72 3.60 0.9 0.1	0.875 0.98 0.63 3.00 0.9 0.1
0.625 0.88 0.61 2.60 0.9 0.1	0.900 0.70 0.50 2.40 0.9 0.1
0.625 0.90 0.63 3.00 0.9 0.1	0.900 0.75 0.53 2.45 0.9 0.1
0.625 0.95 0.65 3.50 0.9 0.1	0.900 0.80 0.55 2.55 0.9 0.1
0.625 1.10 0.68 3.70 0.9 0.1	0.900 0.85 0.58 2.65 0.9 0.1
0.625 1.15 0.70 4.00 0.9 0.1	0.900 1.04 0.65 3.25 0.9 0.1
0.650 0.85 0.60 2.60 0.9 0.1	0.925 0.56 0.45 2.05 0.9 0.1
0.650 0.90 0.63 2.80 0.9 0.1	0.925 0.60 0.48 2.25 0.9 0.1
0.650 0.95 0.64 2.90 0.9 0.1	0.925 0.65 0.51 2.38 0.9 0.1
0.650 0.98 0.65 3.10 0.9 0.1	0.925 0.95 0.57 2.78 0.9 0.1
0.650 1.02 0.66 3.30 0.9 0.1	0.925 1.03 0.63 3.20 0.9 0.1
0.675 0.83 0.58 2.55 0.9 0.1	0.950 0.54 0.44 2.00 0.9 0.1
0.675 0.87 0.59 2.60 0.9 0.1	0.950 0.61 0.46 2.15 0.9 0.1
0.675 0.90 0.60 2.65 0.9 0.1	0.950 0.68 0.48 2.30 0.9 0.1
0.675 0.97 0.63 2.67 0.9 0.1	0.950 0.88 0.55 2.80 0.9 0.1
0.675 1.09 0.66 3.30 0.9 0.1	0.950 1.00 0.62 3.10 0.9 0.1
0.700 0.79 0.56 2.50 0.9 0.1	0.975 0.53 0.43 2.00 0.9 0.1
0.700 0.85 0.60 2.70 0.9 0.1	0.975 0.60 0.45 2.10 0.9 0.1
0.700 0.95 0.62 2.90 0.9 0.1	0.975 0.68 0.46 2.20 0.9 0.1
0.700 1.08 0.64 3.20 0.9 0.1	0.975 0.70 0.48 2.20 0.9 0.1
0.700 1.20 0.69 3.60 0.9 0.1	0.975 0.97 0.61 2.95 0.9 0.1
0.725 0.76 0.56 2.40 0.9 0.1	1.000 0.51 0.41 1.95 0.9 0.1
0.725 0.81 0.58 2.60 0.9 0.1	1.000 0.55 0.43 2.00 0.9 0.1
0.725 0.88 0.61 2.80 0.9 0.1	1.000 0.65 0.45 2.10 0.9 0.1
0.725 0.95 0.63 2.90 0.9 0.1	1.000 0.72 0.51 2.20 0.9 0.1
0.725 0.98 0.64 3.00 0.9 0.1	1.000 0.80 0.55 2.65 0.9 0.1
0.750 0.75 0.51 2.40 0.9 0.1	0.500 1.50 0.95 7.70 0.1 0.9
0.750 0.80 0.59 2.80 0.9 0.1	0.525 1.55 0.93 7.20 0.1 0.9
0.750 0.97 0.63 3.00 0.9 0.1	0.525 1.56 0.95 7.30 0.1 0.9
0.750 1.10 0.65 3.10 0.9 0.1	0.550 1.50 0.85 7.00 0.1 0.9

0.550 1.51 0.87 7.30 0.1 0.9
 0.575 1.50 0.83 6.30 0.1 0.9
 0.575 1.51 0.85 6.50 0.1 0.9
 0.600 1.45 0.84 5.50 0.1 0.9
 0.600 1.46 0.87 5.70 0.1 0.9
 0.625 1.35 0.82 5.50 0.1 0.9
 0.625 1.40 0.85 5.70 0.1 0.9
 0.650 1.40 0.80 5.00 0.1 0.9
 0.650 1.45 0.83 5.10 0.1 0.9
 0.675 1.40 0.80 5.50 0.1 0.9
 0.675 1.45 0.83 6.00 0.1 0.9
 0.700 1.41 0.79 4.80 0.1 0.9
 0.700 1.45 0.80 4.70 0.1 0.9
 0.725 1.33 0.81 4.50 0.1 0.9
 0.725 1.40 0.83 4.30 0.1 0.9
 0.750 1.30 0.77 4.50 0.1 0.9
 0.750 1.35 0.80 4.80 0.1 0.9
 0.775 1.30 0.80 4.00 0.1 0.9
 0.775 1.40 0.85 4.50 0.1 0.9

0.800 1.25 0.75 4.00 0.1 0.9
 0.800 1.25 0.76 4.40 0.1 0.9
 0.825 1.20 0.75 4.00 0.1 0.9
 0.825 1.25 0.76 4.40 0.1 0.9
 0.850 1.25 0.75 4.10 0.1 0.9
 0.850 1.27 0.80 4.20 0.1 0.9
 0.875 1.18 0.71 3.90 0.1 0.9
 0.875 1.21 0.73 4.10 0.1 0.9
 0.900 1.35 0.71 3.50 0.1 0.9
 0.900 1.25 0.75 3.55 0.1 0.9
 0.925 1.25 0.71 3.50 0.1 0.9
 0.925 1.30 0.68 3.61 0.1 0.9
 0.950 1.50 0.68 3.50 0.1 0.9
 0.950 1.70 0.71 3.80 0.1 0.9
 0.975 1.45 0.71 3.75 0.1 0.9
 0.975 1.55 0.68 3.60 0.1 0.9
 1.000 1.35 0.85 3.15 0.1 0.9
 1.000 1.50 1.05 3.45 0.1 0.9

2. Alt Küme:

0.500 1.35 0.77 4.40 0.9 0.1
 0.500 1.31 0.76 4.80 0.9 0.1
 0.525 1.41 0.80 5.10 0.9 0.1
 0.525 1.45 0.83 6.00 0.9 0.1
 0.550 1.25 0.73 3.95 0.9 0.1
 0.550 1.30 0.75 4.30 0.9 0.1
 0.575 1.22 0.77 3.80 0.9 0.1
 0.575 1.28 0.80 6.00 0.9 0.1
 0.600 1.25 0.75 4.50 0.9 0.1
 0.600 1.28 0.79 5.20 0.9 0.1
 0.625 1.20 0.75 4.50 0.9 0.1
 0.625 1.22 0.78 5.00 0.9 0.1
 0.650 1.12 0.67 3.40 0.9 0.1
 0.650 1.20 0.75 4.80 0.9 0.1
 0.675 1.20 0.70 4.20 0.9 0.1
 0.675 1.25 0.75 4.40 0.9 0.1
 0.700 1.27 0.72 3.90 0.9 0.1
 0.700 1.35 0.76 4.20 0.9 0.1
 0.725 1.00 0.65 3.10 0.9 0.1
 0.725 1.26 0.75 4.00 0.9 0.1
 0.750 1.20 0.70 3.80 0.9 0.1
 0.750 1.22 0.73 4.00 0.9 0.1
 0.775 0.75 0.55 2.30 0.9 0.1
 0.775 0.85 0.58 2.50 0.9 0.1
 0.800 0.85 0.58 2.60 0.9 0.1
 0.800 0.90 0.59 2.70 0.9 0.1
 0.825 0.88 0.59 2.60 0.9 0.1
 0.825 0.90 0.61 2.70 0.9 0.1
 0.850 0.70 0.50 2.30 0.9 0.1
 0.850 0.75 0.55 2.40 0.9 0.1
 0.875 0.78 0.54 2.45 0.9 0.1
 0.875 0.80 0.55 2.50 0.9 0.1

0.900 0.59 0.46 2.10 0.9 0.1
 0.900 0.63 0.48 2.35 0.9 0.1
 0.925 0.70 0.53 2.41 0.9 0.1
 0.925 0.78 0.54 2.45 0.9 0.1
 0.950 0.70 0.50 2.35 0.9 0.1
 0.950 0.75 0.52 2.40 0.9 0.1
 0.975 0.74 0.51 2.30 0.9 0.1
 0.975 0.80 0.55 2.55 0.9 0.1
 1.000 0.70 0.48 2.15 0.9 0.1
 1.000 0.95 0.60 2.90 0.9 0.1
 0.500 1.47 0.90 7.50 0.1 0.9
 0.525 1.54 0.94 7.10 0.1 0.9
 0.550 1.49 0.85 7.10 0.1 0.9
 0.575 1.53 0.87 7.00 0.1 0.9
 0.600 1.50 0.90 6.00 0.1 0.9
 0.625 1.45 0.87 6.00 0.1 0.9
 0.650 1.48 0.85 5.30 0.1 0.9
 0.675 1.50 0.90 6.20 0.1 0.9
 0.700 1.48 0.83 5.00 0.1 0.9
 0.725 1.45 0.84 4.70 0.1 0.9
 0.750 1.41 0.81 4.90 0.1 0.9
 0.775 1.35 0.83 4.30 0.1 0.9
 0.800 1.30 0.80 4.50 0.1 0.9
 0.825 1.28 0.77 4.50 0.1 0.9
 0.850 1.20 0.70 4.00 0.1 0.9
 0.875 1.23 0.80 4.30 0.1 0.9
 0.900 1.28 0.78 3.65 0.1 0.9
 0.925 1.28 0.74 3.55 0.1 0.9
 0.950 1.95 0.73 4.00 0.1 0.9
 0.975 1.25 0.75 3.25 0.1 0.9
 1.000 1.25 0.80 3.00 0.1 0.9

Ek 5 Göğüs Kanseri Problemi İçin Veritabanı

(www.ics.uci.edu/pub/ml-repos/machine-learning-databases/breast)

1000025 5 1 1 1 2 1 3 1 1 2	1113483 5 2 3 1 6 10 5 1 1 4
1002945 5 4 4 5 7 10 3 2 1 2	1113906 9 5 5 2 2 2 5 1 1 4
1015425 3 1 1 1 2 2 3 1 1 2	1115282 5 3 5 5 3 3 4 10 1 4
1016277 6 8 8 1 3 4 3 7 1 2	1115293 1 1 1 1 2 2 2 1 1 2
1017023 4 1 1 3 2 1 3 1 1 2	1116116 9 10 10 1 10 8 3 3 1 4
1017122 8 10 10 8 7 10 9 7 1 4	1116132 6 3 4 1 5 2 3 9 1 4
1018099 1 1 1 1 2 10 3 1 1 2	1116192 1 1 1 1 2 1 2 1 1 2
1018561 2 1 2 1 2 1 3 1 1 2	1116998 10 4 2 1 3 2 4 3 10 4
1033078 2 1 1 1 2 1 1 1 5 2	1117152 4 1 1 1 2 1 3 1 1 2
1033078 4 2 1 1 2 1 2 1 1 2	1118039 5 3 4 1 8 10 4 9 1 4
1035283 1 1 1 1 1 1 3 1 1 2	1120559 8 3 8 3 4 9 8 9 8 4
1036172 2 1 1 1 2 1 2 1 1 2	1121732 1 1 1 1 2 1 3 2 1 2
1041801 5 3 3 3 2 3 4 4 1 4	1121919 5 1 3 1 2 1 2 1 1 2
1043999 1 1 1 1 2 3 3 1 1 2	1123061 6 10 2 8 10 2 7 8 10 4
1044572 8 7 5 10 7 9 5 5 4 4	1124651 1 3 3 2 2 1 7 2 1 2
1047630 7 4 6 4 6 1 4 3 1 4	1125035 9 4 5 10 6 10 4 8 1 4
1048672 4 1 1 1 2 1 2 1 1 2	1126417 10 6 4 1 3 4 3 2 3 4
1049815 4 1 1 1 2 1 3 1 1 2	1131294 1 1 2 1 2 2 4 2 1 2
1050670 10 7 7 6 4 10 4 1 2 4	1132347 1 1 4 1 2 1 2 1 1 2
1050718 6 1 1 1 2 1 3 1 1 2	1133041 5 3 1 2 2 1 2 1 1 2
1054590 7 3 2 10 5 10 5 4 4 4	1133136 3 1 1 1 2 3 3 1 1 2
1054593 10 5 5 3 6 7 7 10 1 4	1136142 2 1 1 1 3 1 2 1 1 2
1056784 3 1 1 1 2 1 2 1 1 2	1137156 2 2 2 1 1 1 7 1 1 2
1059552 1 1 1 1 2 1 3 1 1 2	1143978 4 1 1 2 2 1 2 1 1 2
1065726 5 2 3 4 2 7 3 6 1 4	1143978 5 2 1 1 2 1 3 1 1 2
1066373 3 2 1 1 1 1 2 1 1 2	1147044 3 1 1 1 2 2 7 1 1 2
1066979 5 1 1 1 2 1 2 1 1 2	1147699 3 5 7 8 8 9 7 10 7 4
1067444 2 1 1 1 2 1 2 1 1 2	1147748 5 10 6 1 10 4 4 10 10 4
1070935 1 1 3 1 2 1 1 1 1 2	1148278 3 3 6 4 5 8 4 4 1 4
1070935 3 1 1 1 1 1 2 1 1 2	1148873 3 6 6 6 5 10 6 8 3 4
1071760 2 1 1 1 2 1 3 1 1 2	1152331 4 1 1 1 2 1 3 1 1 2
1072179 10 7 7 3 8 5 7 4 3 4	1155546 2 1 1 2 3 1 2 1 1 2
1074610 2 1 1 2 2 1 3 1 1 2	1156272 1 1 1 1 2 1 3 1 1 2
1075123 3 1 2 1 2 1 2 1 1 2	1156948 3 1 1 2 2 1 1 1 1 2
1079304 2 1 1 1 2 1 2 1 1 2	1157734 4 1 1 1 2 1 3 1 1 2
1080185 10 10 10 8 6 1 8 9 1 4	1158247 1 1 1 1 2 1 2 1 1 2
1081791 6 2 1 1 1 1 7 1 1 2	1160476 2 1 1 1 2 1 3 1 1 2
1084584 5 4 4 9 2 10 5 6 1 4	1164066 1 1 1 1 2 1 3 1 1 2
1091262 2 5 3 3 6 7 7 5 1 4	1165297 2 1 1 2 2 1 1 1 1 2
1099510 10 4 3 1 3 3 6 5 2 4	1165790 5 1 1 1 2 1 3 1 1 2
1100524 6 10 10 2 8 10 7 3 3 4	1165926 9 6 9 2 10 6 2 9 10 4
1102573 5 6 5 6 10 1 3 1 1 4	1166630 7 5 6 10 5 10 7 9 4 4
1103608 10 10 10 4 8 1 8 10 1 4	1166654 10 3 5 1 10 5 3 10 2 4
1103722 1 1 1 1 2 1 2 1 2 2	1167439 2 3 4 4 2 5 2 5 1 4
1105257 3 7 7 4 4 9 4 8 1 4	1167471 4 1 2 1 2 1 3 1 1 2
1105524 1 1 1 1 2 1 2 1 1 2	1168359 8 2 3 1 6 3 7 1 1 4
1106095 4 1 1 3 2 1 3 1 1 2	1168736 10 10 10 10 10 1 8 8 8 4
1106829 7 8 7 2 4 8 3 8 2 4	1169049 7 3 4 4 3 3 3 2 7 4
1108370 9 5 8 1 2 3 2 1 5 4	1170419 10 10 10 8 2 10 4 1 1 4
1108449 5 3 3 4 2 4 3 4 1 4	1170420 1 6 8 10 8 10 5 7 1 4
1110102 10 3 6 2 3 5 4 10 2 4	1171710 1 1 1 1 2 1 2 3 1 2
1110503 5 5 5 8 10 8 7 3 7 4	1171710 6 5 4 4 3 9 7 8 3 4
1110524 10 5 5 6 8 8 7 1 1 4	1171795 1 3 1 2 2 2 5 3 2 2
1111249 10 6 6 3 4 5 3 6 1 4	1171845 8 6 4 3 5 9 3 1 1 4
1112209 8 10 10 1 3 6 3 9 1 4	1172152 10 3 3 10 2 10 7 3 3 4
1113038 8 2 4 1 5 1 5 4 4 4	1173216 10 10 10 3 10 8 8 1 1 4

1173235 3 3 2 1 2 3 3 1 1 2	1202125 4 1 1 1 2 1 3 1 1 2
1173347 1 1 1 1 2 5 1 1 1 2	1202812 5 3 3 3 6 10 3 1 1 4
1173347 8 3 3 1 2 2 3 2 1 2	1203096 1 1 1 1 1 1 3 1 1 2
1173509 4 5 5 10 4 10 7 5 8 4	1204242 1 1 1 1 2 1 1 1 1 2
1173514 1 1 1 1 4 3 1 1 1 2	1204898 6 1 1 1 2 1 3 1 1 2
1173681 3 2 1 1 2 2 3 1 1 2	1205138 5 8 8 8 5 10 7 8 1 4
1174057 1 1 2 2 2 1 3 1 1 2	1205579 8 7 6 4 4 10 5 1 1 4
1174057 4 2 1 1 2 2 3 1 1 2	1206089 2 1 1 1 1 1 3 1 1 2
1174131 10 10 10 2 10 10 5 3 3 4	1206695 1 5 8 6 5 8 7 10 1 4
1174428 5 3 5 1 8 10 5 3 1 4	1206841 10 5 6 10 6 10 7 7 10 4
1175937 5 4 6 7 9 7 8 10 1 4	1207986 5 8 4 10 5 8 9 10 1 4
1176406 1 1 1 1 2 1 2 1 1 2	1208301 1 2 3 1 2 1 3 1 1 2
1176881 7 5 3 7 4 10 7 5 5 4	1210963 10 10 10 8 6 8 7 10 1 4
1177027 3 1 1 1 2 1 3 1 1 2	1211202 7 5 10 10 10 10 4 10 3 4
1177399 8 3 5 4 5 10 1 6 2 4	1212232 5 1 1 1 2 1 2 1 1 2
1177512 1 1 1 1 10 1 1 1 1 2	1212251 1 1 1 1 2 1 3 1 1 2
1178580 5 1 3 1 2 1 2 1 1 2	1212422 3 1 1 1 2 1 3 1 1 2
1179818 2 1 1 1 2 1 3 1 1 2	1212422 4 1 1 1 2 1 3 1 1 2
1180194 5 10 8 10 8 10 3 6 3 4	1213375 8 4 4 5 4 7 7 8 2 2
1180523 3 1 1 1 2 1 2 2 1 2	1213383 5 1 1 4 2 1 3 1 1 2
1180831 3 1 1 1 3 1 2 1 1 2	1214092 1 1 1 1 2 1 1 1 1 2
1181356 5 1 1 1 2 2 3 3 1 2	1214556 3 1 1 1 2 1 2 1 1 2
1182404 4 1 1 1 2 1 2 1 1 2	1214966 9 7 7 5 5 10 7 8 3 4
1182410 3 1 1 1 2 1 1 1 1 2	1216694 10 8 8 4 10 10 8 1 1 4
1183240 4 1 2 1 2 1 2 1 1 2	1216947 1 1 1 1 2 1 3 1 1 2
1183516 3 1 1 1 2 1 1 1 1 2	1217051 5 1 1 1 2 1 3 1 1 2
1183911 2 1 1 1 2 1 1 1 1 2	1217264 1 1 1 1 2 1 3 1 1 2
1183983 9 5 5 4 4 5 4 3 3 4	1218105 5 10 10 9 6 10 7 10 5 4
1184184 1 1 1 1 2 5 1 1 1 2	1218741 10 10 9 3 7 5 3 5 1 4
1184241 2 1 1 1 2 1 2 1 1 2	1218860 1 1 1 1 1 1 3 1 1 2
1185609 3 4 5 2 6 8 4 1 1 4	1218860 1 1 1 1 1 1 3 1 1 2
1185610 1 1 1 1 3 2 2 1 1 2	1219406 5 1 1 1 1 1 3 1 1 2
1187457 3 1 1 3 8 1 5 8 1 2	1219525 8 10 10 10 5 10 8 10 6 4
1187805 8 8 7 4 10 10 7 8 7 4	1219859 8 10 8 8 4 8 7 7 1 4
1188472 1 1 1 1 1 1 3 1 1 2	1220330 1 1 1 1 2 1 3 1 1 2
1189266 7 2 4 1 6 10 5 4 3 4	1221863 10 10 10 10 7 10 7 10 4 4
1189286 10 10 8 6 4 5 8 10 1 4	1222047 10 10 10 10 3 10 10 6 1 4
1190394 4 1 1 1 2 3 1 1 1 2	1222936 8 7 8 7 5 5 5 10 2 4
1190485 1 1 1 1 2 1 1 1 1 2	1223282 1 1 1 1 2 1 2 1 1 2
1192325 5 5 5 6 3 10 3 1 1 4	1223426 1 1 1 1 2 1 3 1 1 2
1193091 1 2 2 1 2 1 2 1 1 2	1223793 6 10 7 7 6 4 8 10 2 4
1193210 2 1 1 1 2 1 3 1 1 2	1223967 6 1 3 1 2 1 3 1 1 2
1196295 9 9 10 3 6 10 7 10 6 4	1224329 1 1 1 2 2 1 3 1 1 2
1196915 10 7 7 4 5 10 5 7 2 4	1225799 10 6 4 3 10 10 9 10 1 4
1197080 4 1 1 1 2 1 3 2 1 2	1226012 4 1 1 3 1 5 2 1 1 4
1197270 3 1 1 1 2 1 3 1 1 2	1226612 7 5 6 3 3 8 7 4 1 4
1197440 1 1 1 2 1 3 1 1 7 2	1227210 10 5 5 6 3 10 7 9 2 4
1197979 4 1 1 1 2 2 3 2 1 2	1227244 1 1 1 1 2 1 2 1 1 2
1197993 5 6 7 8 8 10 3 10 3 4	1227481 10 5 7 4 4 10 8 9 1 4
1198128 10 8 10 10 6 1 3 1 10 4	1228152 8 9 9 5 3 5 7 7 1 4
1198641 3 1 1 1 2 1 3 1 1 2	1228311 1 1 1 1 1 1 3 1 1 2
1199219 1 1 1 2 1 1 1 1 1 2	1230175 10 10 10 3 10 10 9 10 1 4
1199731 3 1 1 1 2 1 1 1 1 2	1230688 7 4 7 4 3 7 7 6 1 4
1199983 1 1 1 1 2 1 3 1 1 2	1231387 6 8 7 5 6 8 8 9 2 4
1200772 1 1 1 1 2 1 2 1 1 2	1231706 8 4 6 3 3 1 4 3 1 2
1200847 6 10 10 10 8 10 10 10 7 4	1232225 10 4 5 5 5 10 4 1 1 4
1200892 8 6 5 4 3 10 6 1 1 4	1236043 3 3 2 1 3 1 3 6 1 2
1200952 5 8 7 7 10 10 5 7 1 4	1241559 10 8 8 2 8 10 4 8 10 4
1201834 2 1 1 1 2 1 3 1 1 2	1241679 9 8 8 5 6 2 4 10 4 4
1201936 5 10 10 3 8 1 5 10 3 4	1242364 8 10 10 8 6 9 3 10 10 4

1243256 10 4 3 2 3 10 5 3 2 4
 1270479 5 1 3 3 2 2 2 3 1 2
 1276091 3 1 1 3 1 1 3 1 1 2
 1277018 2 1 1 1 2 1 3 1 1 2
 128059 1 1 1 1 2 5 5 1 1 2
 1285531 1 1 1 1 2 1 3 1 1 2
 1287775 5 1 1 2 2 2 3 1 1 2
 144888 8 10 10 8 5 10 7 8 1 4
 145447 8 4 4 1 2 9 3 3 1 4
 167528 4 1 1 1 2 1 3 6 1 2
 183913 1 2 2 1 2 1 1 1 1 2
 191250 10 4 4 10 2 10 5 3 3 4
 1017023 6 3 3 5 3 10 3 5 3 2
 1100524 6 10 10 2 8 10 7 3 3 4
 1116116 9 10 10 1 10 8 3 3 1 4
 1168736 5 6 6 2 4 10 3 6 1 4
 1182404 3 1 1 1 2 1 1 1 1 2
 1182404 3 1 1 1 2 1 2 1 1 2
 1198641 3 1 1 1 2 1 3 1 1 2
 242970 5 7 7 1 5 8 3 4 1 2
 255644 10 5 8 10 3 10 5 1 3 4
 263538 5 10 10 6 10 10 10 6 5 4
 274137 8 8 9 4 5 10 7 8 1 4
 303213 10 4 4 10 6 10 5 5 1 4
 314428 7 9 4 10 10 3 5 3 3 4
 1182404 5 1 4 1 2 1 3 2 1 2
 1198641 10 10 6 3 3 10 4 3 2 4
 320675 3 3 5 2 3 10 7 1 1 4
 324427 10 8 8 2 3 4 8 7 8 4
 385103 1 1 1 1 2 1 3 1 1 2
 390840 8 4 7 1 3 10 3 9 2 4
 411453 5 1 1 1 2 1 3 1 1 2
 320675 3 3 5 2 3 10 7 1 1 4
 428903 7 2 4 1 3 4 3 3 1 4
 431495 3 1 1 1 2 1 3 2 1 2
 434518 3 1 1 1 2 1 2 1 1 2
 452264 1 1 1 1 2 1 2 1 1 2
 456282 1 1 1 1 2 1 3 1 1 2
 476903 10 5 7 3 3 7 3 3 8 4
 486283 3 1 1 1 2 1 3 1 1 2
 486662 2 1 1 2 2 1 3 1 1 2
 488173 1 4 3 10 4 10 5 6 1 4
 492268 10 4 6 1 2 10 5 3 1 4
 508234 7 4 5 10 2 10 3 8 2 4
 527363 8 10 10 10 8 10 10 7 3 4
 529329 10 10 10 10 10 10 4 10 10 4
 535331 3 1 1 1 3 1 2 1 1 2
 543558 6 1 3 1 4 5 5 10 1 4
 555977 5 6 6 8 6 10 4 10 4 4
 560680 1 1 1 1 2 1 1 1 1 2
 561477 1 1 1 1 2 1 3 1 1 2
 601265 10 4 4 6 2 10 2 3 1 4
 606722 5 5 7 8 6 10 7 4 1 4
 616240 5 3 4 3 4 5 4 7 1 2
 625201 8 2 1 1 5 1 1 1 1 2
 63375 9 1 2 6 4 10 7 7 2 4
 635844 8 4 10 5 4 4 7 10 1 4
 636130 1 1 1 1 2 1 3 1 1 2
 640744 10 10 10 7 9 10 7 10 10 4
 646904 1 1 1 1 2 1 3 1 1 2

653777 8 3 4 9 3 10 3 3 1 4
 659642 10 8 4 4 4 10 3 10 4 4
 666090 1 1 1 1 2 1 3 1 1 2
 666942 1 1 1 1 2 1 3 1 1 2
 667204 7 8 7 6 4 3 8 8 4 4
 673637 3 1 1 1 2 5 5 1 1 2
 684955 2 1 1 1 3 1 2 1 1 2
 688033 1 1 1 1 2 1 1 1 1 2
 691628 8 6 4 10 10 1 3 5 1 4
 693702 1 1 1 1 2 1 1 1 1 2
 704097 1 1 1 1 1 1 2 1 1 2
 706426 5 5 5 2 5 10 4 3 1 4
 709287 6 8 7 8 6 8 8 9 1 4
 718641 1 1 1 1 5 1 3 1 1 2
 721482 4 4 4 4 6 5 7 3 1 2
 730881 7 6 3 2 5 10 7 4 6 4
 733639 3 1 1 1 2 1 3 1 1 2
 733823 5 4 6 10 2 10 4 1 1 4
 740492 1 1 1 1 2 1 3 1 1 2
 743348 3 2 2 1 2 1 2 3 1 2
 752904 10 1 1 1 2 10 5 4 1 4
 756136 1 1 1 1 2 1 2 1 1 2
 760001 8 10 3 2 6 4 3 10 1 4
 760239 10 4 6 4 5 10 7 1 1 4
 76389 10 4 7 2 2 8 6 1 1 4
 764974 5 1 1 1 2 1 3 1 2 2
 770066 5 2 2 2 2 1 2 2 1 2
 785208 5 4 6 6 4 10 4 3 1 4
 785615 8 6 7 3 3 10 3 4 2 4
 792744 1 1 1 1 2 1 1 1 1 2
 797327 6 5 5 8 4 10 3 4 1 4
 798429 1 1 1 1 2 1 3 1 1 2
 704097 1 1 1 1 1 1 2 1 1 2
 806423 8 5 5 5 2 10 4 3 1 4
 809912 10 3 3 1 2 10 7 6 1 4
 810104 1 1 1 1 2 1 3 1 1 2
 814265 2 1 1 1 2 1 1 1 1 2
 814911 1 1 1 1 2 1 1 1 1 2
 822829 7 6 4 8 10 10 9 5 3 4
 826923 1 1 1 1 2 1 1 1 1 2
 830690 5 2 2 2 3 1 1 3 1 2
 831268 1 1 1 1 1 1 1 3 1 2
 832226 3 4 4 10 5 1 3 3 1 4
 832567 4 2 3 5 3 8 7 6 1 4
 836433 5 1 1 3 2 1 1 1 1 2
 837082 2 1 1 1 2 1 3 1 1 2
 846832 3 4 5 3 7 3 4 6 1 2
 850831 2 7 10 10 7 10 4 9 4 4
 855524 1 1 1 1 2 1 2 1 1 2
 857774 4 1 1 1 3 1 2 2 1 2
 859164 5 3 3 1 3 3 3 3 3 4
 859350 8 10 10 7 10 10 7 3 8 4
 866325 8 10 5 3 8 4 4 10 3 4
 873549 10 3 5 4 3 7 3 5 3 4
 877291 6 10 10 10 10 10 8 10 10 4
 877943 3 10 3 10 6 10 5 1 4 4
 888169 3 2 2 1 4 3 2 1 1 2
 888523 4 4 4 2 2 3 2 1 1 2
 896404 2 1 1 1 2 1 3 1 1 2
 897172 2 1 1 1 2 1 2 1 1 2

95719 6 10 10 10 8 10 7 10 7 4
 160296 5 8 8 10 5 10 8 10 3 4
 342245 1 1 3 1 2 1 1 1 1 2
 428598 1 1 3 1 1 1 2 1 1 2
 492561 4 3 2 1 3 1 2 1 1 2
 493452 1 1 3 1 2 1 1 1 1 2
 493452 4 1 2 1 2 1 2 1 1 2
 521441 5 1 1 2 2 1 2 1 1 2
 560680 3 1 2 1 2 1 2 1 1 2
 636437 1 1 1 1 2 1 1 1 1 2
 640712 1 1 1 1 2 1 2 1 1 2
 654244 1 1 1 1 1 1 2 1 1 2
 657753 3 1 1 4 3 1 2 2 1 2
 685977 5 3 4 1 4 1 3 1 1 2
 805448 1 1 1 1 2 1 1 1 1 2
 846423 10 6 3 6 4 10 7 8 4 4
 1002504 3 2 2 2 2 1 3 2 1 2
 1022257 2 1 1 1 2 1 1 1 1 2
 1026122 2 1 1 1 2 1 1 1 1 2
 1071084 3 3 2 2 3 1 1 2 3 2
 1080233 7 6 6 3 2 10 7 1 1 4
 1114570 5 3 3 2 3 1 3 1 1 2
 1114570 2 1 1 1 2 1 2 2 1 2
 1116715 5 1 1 1 3 2 2 2 1 2
 1131411 1 1 1 2 2 1 2 1 1 2
 1151734 10 8 7 4 3 10 7 9 1 4
 1156017 3 1 1 1 2 1 2 1 1 2
 1158247 1 1 1 1 1 1 1 1 1 2
 1158405 1 2 3 1 2 1 2 1 1 2
 1168278 3 1 1 1 2 1 2 1 1 2
 1176187 3 1 1 1 2 1 3 1 1 2
 1196263 4 1 1 1 2 1 1 1 1 2
 1196475 3 2 1 1 2 1 2 2 1 2
 1206314 1 2 3 1 2 1 1 1 1 2
 1211265 3 10 8 7 6 9 9 3 8 4
 1213784 3 1 1 1 2 1 1 1 1 2
 1223003 5 3 3 1 2 1 2 1 1 2
 1223306 3 1 1 1 2 4 1 1 1 2
 1223543 1 2 1 3 2 1 1 2 1 2
 1229929 1 1 1 1 2 1 2 1 1 2
 1231853 4 2 2 1 2 1 2 1 1 2
 1234554 1 1 1 1 2 1 2 1 1 2
 1236837 2 3 2 2 2 2 3 1 1 2
 1237674 3 1 2 1 2 1 2 1 1 2
 1238021 1 1 1 1 2 1 2 1 1 2
 1238633 10 10 10 6 8 4 8 5 1 4
 1238915 5 1 2 1 2 1 3 1 1 2
 1238948 8 5 6 2 3 10 6 6 1 4
 1239232 3 3 2 6 3 3 3 5 1 2
 1239347 8 7 8 5 10 10 7 2 1 4
 1239967 1 1 1 1 2 1 2 1 1 2
 1240337 5 2 2 2 2 2 3 2 2 2
 1253505 2 3 1 1 5 1 1 1 1 2
 1255384 3 2 2 3 2 3 3 1 1 2
 1257200 10 10 10 7 10 10 8 2 1 4
 1257648 4 3 3 1 2 1 3 3 1 2
 1257815 5 1 3 1 2 1 2 1 1 2
 1257938 3 1 1 1 2 1 1 1 1 2
 1258549 9 10 10 10 10 10 10 1 4
 1258556 5 3 6 1 2 1 1 1 1 2

1266154 8 7 8 2 4 2 5 10 1 4
 1272039 1 1 1 1 2 1 2 1 1 2
 1276091 2 1 1 1 2 1 2 1 1 2
 1276091 1 3 1 1 2 1 2 2 1 2
 1276091 5 1 1 3 4 1 3 2 1 2
 1277629 5 1 1 1 2 1 2 2 1 2
 1293439 3 2 2 3 2 1 1 1 1 2
 1293439 6 9 7 5 5 8 4 2 1 2
 1294562 10 8 10 1 3 10 5 1 1 4
 1295186 10 10 10 1 6 1 2 8 1 4
 527337 4 1 1 1 2 1 1 1 1 2
 558538 4 1 3 3 2 1 1 1 1 2
 566509 5 1 1 1 2 1 1 1 1 2
 608157 10 4 3 10 4 10 10 1 1 4
 677910 5 2 2 4 2 4 1 1 1 2
 734111 1 1 1 3 2 3 1 1 1 2
 734111 1 1 1 1 2 2 1 1 1 2
 780555 5 1 1 6 3 1 2 1 1 2
 827627 2 1 1 1 2 1 1 1 1 2
 1049837 1 1 1 1 2 1 1 1 1 2
 1058849 5 1 1 1 2 1 1 1 1 2
 1182404 1 1 1 1 1 1 1 1 1 2
 1193544 5 7 9 8 6 10 8 10 1 4
 1201870 4 1 1 3 1 1 2 1 1 2
 1202253 5 1 1 1 2 1 1 1 1 2
 1227081 3 1 1 3 2 1 1 1 1 2
 1230994 4 5 5 8 6 10 10 7 1 4
 1238410 2 3 1 1 3 1 1 1 1 2
 1246562 10 2 2 1 2 6 1 1 2 4
 1257470 10 6 5 8 5 10 8 6 1 4
 1259008 8 8 9 6 6 3 10 10 1 4
 1266124 5 1 2 1 2 1 1 1 1 2
 1267898 5 1 3 1 2 1 1 1 1 2
 1268313 5 1 1 3 2 1 1 1 1 2
 1268804 3 1 1 1 2 5 1 1 1 2
 1276091 6 1 1 3 2 1 1 1 1 2
 1280258 4 1 1 1 2 1 1 2 1 2
 1293966 4 1 1 1 2 1 1 1 1 2
 1296572 10 9 8 7 6 4 7 10 3 4
 1298416 10 6 6 2 4 10 9 7 1 4
 1299596 6 6 6 5 4 10 7 6 2 4
 1105524 4 1 1 1 2 1 1 1 1 2
 1181685 1 1 2 1 2 1 2 1 1 2
 1211594 3 1 1 1 1 1 2 1 1 2
 1238777 6 1 1 3 2 1 1 1 1 2
 1257608 6 1 1 1 1 1 1 1 1 2
 1269574 4 1 1 1 2 1 1 1 1 2
 1277145 5 1 1 1 2 1 1 1 1 2
 1287282 3 1 1 1 2 1 1 1 1 2
 1296025 4 1 2 1 2 1 1 1 1 2
 1296263 4 1 1 1 2 1 1 1 1 2
 1296593 5 2 1 1 2 1 1 1 1 2
 1299161 4 8 7 10 4 10 7 5 1 4
 1301945 5 1 1 1 1 1 1 1 1 2
 1302428 5 3 2 4 2 1 1 1 1 2
 1318169 9 10 10 10 10 5 10 10 4
 474162 8 7 8 5 5 10 9 10 1 4
 787451 5 1 2 1 2 1 1 1 1 2
 1002025 1 1 1 3 1 3 1 1 1 2
 1070522 3 1 1 1 1 1 2 1 1 2

1073960 10 10 10 10 6 10 8 1 5 4	1240603 2 1 1 1 1 1 1 1 1 2
1076352 3 6 4 10 3 3 3 4 1 4	1240603 3 1 1 1 1 1 1 1 1 2
1084139 6 3 2 1 3 4 4 1 1 4	1241035 7 8 3 7 4 5 7 8 2 4
1115293 1 1 1 1 2 1 1 1 1 2	1287971 3 1 1 1 2 1 2 1 1 2
1119189 5 8 9 4 3 10 7 1 1 4	1289391 1 1 1 1 2 1 3 1 1 2
1133991 4 1 1 1 1 1 2 1 1 2	1299924 3 2 2 2 2 1 4 2 1 2
1142706 5 10 10 10 6 10 6 5 2 4	1306339 4 4 2 1 2 5 2 1 2 2
1155967 5 1 2 10 4 5 2 1 1 2	1313658 3 1 1 1 2 1 1 1 1 2
1170945 3 1 1 1 1 1 2 1 1 2	1313982 4 3 1 1 2 1 4 8 1 2
1181567 1 1 1 1 1 1 1 1 1 2	1321264 5 2 2 2 1 1 2 1 1 2
1182404 4 2 1 1 2 1 1 1 1 2	1321321 5 1 1 3 2 1 1 1 1 2
1204558 4 1 1 1 2 1 2 1 1 2	1321348 2 1 1 1 2 1 2 1 1 2
1217952 4 1 1 1 2 1 2 1 1 2	1321931 5 1 1 1 2 1 2 1 1 2
1224565 6 1 1 1 2 1 3 1 1 2	1321942 5 1 1 1 2 1 3 1 1 2
1238186 4 1 1 1 2 1 2 1 1 2	1321942 5 1 1 1 2 1 3 1 1 2
1253917 4 1 1 2 2 1 2 1 1 2	1328331 1 1 1 1 2 1 3 1 1 2
1265899 4 1 1 1 2 1 3 1 1 2	1328755 3 1 1 1 2 1 2 1 1 2
1268766 1 1 1 1 2 1 1 1 1 2	1331405 4 1 1 1 2 1 3 2 1 2
1277268 3 3 1 1 2 1 1 1 1 2	1331412 5 7 10 10 5 10 10 10 1 4
1286943 8 10 10 10 7 5 4 8 7 4	1333104 3 1 2 1 2 1 3 1 1 2
1295508 1 1 1 1 2 4 1 1 1 2	1334071 4 1 1 1 2 3 2 1 1 2
1297327 5 1 1 1 2 1 1 1 1 2	1343068 8 4 4 1 6 10 2 5 2 4
1297522 2 1 1 1 2 1 1 1 1 2	1343374 10 10 8 10 6 5 10 3 1 4
1298360 1 1 1 1 2 1 1 1 1 2	1344121 8 10 4 4 8 10 8 2 1 4
1299924 5 1 1 1 2 1 2 1 1 2	142932 7 6 10 5 3 10 9 10 2 4
1299994 5 1 1 1 2 1 1 1 1 2	183936 3 1 1 1 2 1 2 1 1 2
1304595 3 1 1 1 1 1 2 1 1 2	324382 1 1 1 1 2 1 2 1 1 2
1306282 6 6 7 10 3 10 8 10 2 4	378275 10 9 7 3 4 2 7 7 1 4
1313325 4 10 4 7 3 10 9 10 1 4	385103 5 1 2 1 2 1 3 1 1 2
1320077 1 1 1 1 1 1 1 1 1 2	690557 5 1 1 1 2 1 2 1 1 2
1320077 1 1 1 1 1 1 2 1 1 2	695091 1 1 1 1 2 1 2 1 1 2
1320304 3 1 2 2 2 1 1 1 1 2	695219 1 1 1 1 2 1 2 1 1 2
1330439 4 7 8 3 4 10 9 1 1 4	824249 1 1 1 1 2 1 3 1 1 2
333093 1 1 1 1 3 1 1 1 1 2	871549 5 1 2 1 2 1 2 1 1 2
369565 4 1 1 1 3 1 1 1 1 2	878358 5 7 10 6 5 10 7 5 1 4
412300 10 4 5 4 3 5 7 3 1 4	1107684 6 10 5 5 4 10 6 10 1 4
672113 7 5 6 10 4 10 5 3 1 4	1115762 3 1 1 1 2 1 1 1 1 2
749653 3 1 1 1 2 1 2 1 1 2	1217717 5 1 1 6 3 1 1 1 1 2
769612 3 1 1 2 2 1 1 1 1 2	1239420 1 1 1 1 2 1 1 1 1 2
769612 4 1 1 1 2 1 1 1 1 2	1254538 8 10 10 10 6 10 10 10 1 4
798429 4 1 1 1 2 1 3 1 1 2	1261751 5 1 1 1 2 1 2 2 1 2
807657 6 1 3 2 2 1 1 1 1 2	1268275 9 8 8 9 6 3 4 1 1 4
8233704 4 1 1 1 1 1 2 1 1 2	1272166 5 1 1 1 2 1 1 1 1 2
837480 7 4 4 3 4 10 6 9 1 4	1294261 4 10 8 5 4 1 10 1 1 4
867392 4 2 2 1 2 1 2 1 1 2	1295529 2 5 7 6 4 10 7 6 1 4
869828 1 1 1 1 1 1 3 1 1 2	1298484 10 3 4 5 3 10 4 1 1 4
1043068 3 1 1 1 2 1 2 1 1 2	1311875 5 1 2 1 2 1 1 1 1 2
1056171 2 1 1 1 2 1 2 1 1 2	1315506 4 8 6 3 4 10 7 1 1 4
1061990 1 1 3 2 2 1 3 1 1 2	1320141 5 1 1 1 2 1 2 1 1 2
1113061 5 1 1 1 2 1 3 1 1 2	1325309 4 1 2 1 2 1 2 1 1 2
1116192 5 1 2 1 2 1 3 1 1 2	1333063 5 1 3 1 2 1 3 1 1 2
1135090 4 1 1 1 2 1 2 1 1 2	1333495 3 1 1 1 2 1 2 1 1 2
1145420 6 1 1 1 2 1 2 1 1 2	1334659 5 2 4 1 1 1 1 1 1 2
1158157 5 1 1 1 2 2 2 1 1 2	1336798 3 1 1 1 2 1 2 1 1 2
1171578 3 1 1 1 2 1 1 1 1 2	1344449 1 1 1 1 1 1 2 1 1 2
1174841 5 3 1 1 2 1 1 1 1 2	1350568 4 1 1 1 2 1 2 1 1 2
1184586 4 1 1 1 2 1 2 1 1 2	1352663 5 4 6 8 4 1 8 10 1 4
1186936 2 1 3 2 2 1 2 1 1 2	188336 5 3 2 8 5 10 8 1 2 4
1197527 5 1 1 1 2 1 2 1 1 2	352431 10 5 10 3 5 8 7 8 3 4
1222464 6 10 10 10 4 10 7 10 1 4	353098 4 1 1 2 2 1 1 1 1 2

411453 1 1 1 1 2 1 1 1 1 2
 557583 5 10 10 10 10 10 10 1 1 4
 636375 5 1 1 1 2 1 1 1 1 2
 736150 10 4 3 10 3 10 7 1 2 4
 803531 5 10 10 10 5 2 8 5 1 4
 822829 8 10 10 10 6 10 10 10 10 4
 1016634 2 3 1 1 2 1 2 1 1 2
 1031608 2 1 1 1 1 1 2 1 1 2
 1041043 4 1 3 1 2 1 2 1 1 2
 1042252 3 1 1 1 2 1 2 1 1 2
 1061990 4 1 1 1 2 1 2 1 1 2
 1073836 5 1 1 1 2 1 2 1 1 2
 1083817 3 1 1 1 2 1 2 1 1 2
 1096352 6 3 3 3 3 2 6 1 1 2
 1140597 7 1 2 3 2 1 2 1 1 2
 1149548 1 1 1 1 2 1 1 1 1 2
 1174009 5 1 1 2 1 1 2 1 1 2
 1183596 3 1 3 1 3 4 1 1 1 2
 1190386 4 6 6 5 7 6 7 7 3 4
 1190546 2 1 1 1 2 5 1 1 1 2
 1213273 2 1 1 1 2 1 1 1 1 2
 1218982 4 1 1 1 2 1 1 1 1 2
 1225382 6 2 3 1 2 1 1 1 1 2
 1235807 5 1 1 1 2 1 2 1 1 2
 1238777 1 1 1 1 2 1 1 1 1 2
 1253955 8 7 4 4 5 3 5 10 1 4
 1257366 3 1 1 1 2 1 1 1 1 2
 1260659 3 1 4 1 2 1 1 1 1 2
 1268952 10 10 7 8 7 1 10 10 3 4
 1275807 4 2 4 3 2 2 2 1 1 2
 1277792 4 1 1 1 2 1 1 1 1 2
 1277792 5 1 1 3 2 1 1 1 1 2
 1285722 4 1 1 3 2 1 1 1 1 2
 1288608 3 1 1 1 2 1 2 1 1 2
 1290203 3 1 1 1 2 1 2 1 1 2
 1294413 1 1 1 1 2 1 1 1 1 2
 1299596 2 1 1 1 2 1 1 1 1 2
 1303489 3 1 1 1 2 1 2 1 1 2
 1311033 1 2 2 1 2 1 1 1 1 2
 1311108 1 1 1 3 2 1 1 1 1 2
 1315807 5 10 10 10 10 2 10 10 10 4
 1318671 3 1 1 1 2 1 2 1 1 2
 1319609 3 1 1 2 3 4 1 1 1 2
 1323477 1 2 1 3 2 1 2 1 1 2
 1324572 5 1 1 1 2 1 2 2 1 2
 1324681 4 1 1 1 2 1 2 1 1 2
 1325159 3 1 1 1 2 1 3 1 1 2
 1326892 3 1 1 1 2 1 2 1 1 2
 1330361 5 1 1 1 2 1 2 1 1 2
 1333877 5 4 5 1 8 1 3 6 1 2
 1334015 7 8 8 7 3 10 7 2 3 4
 1334667 1 1 1 1 2 1 1 1 1 2
 1339781 1 1 1 1 2 1 2 1 1 2
 1339781 4 1 1 1 2 1 3 1 1 2
 13454352 1 1 3 1 2 1 2 1 1 2
 1345452 1 1 3 1 2 1 2 1 1 2
 1345593 3 1 1 3 2 1 2 1 1 2
 1347749 1 1 1 1 2 1 1 1 1 2
 1347943 5 2 2 2 2 1 1 1 2 2
 1348851 3 1 1 1 2 1 3 1 1 2

1350319 5 7 4 1 6 1 7 10 3 4
 1350423 5 10 10 8 5 5 7 10 1 4
 1352848 3 10 7 8 5 8 7 4 1 4
 1353092 3 2 1 2 2 1 3 1 1 2
 1354840 2 1 1 1 2 1 3 1 1 2
 1354840 5 3 2 1 3 1 1 1 1 2
 1355260 1 1 1 1 2 1 2 1 1 2
 1365075 4 1 4 1 2 1 1 1 1 2
 1365328 1 1 2 1 2 1 2 1 1 2
 1368267 5 1 1 1 2 1 1 1 1 2
 1368273 1 1 1 1 2 1 1 1 1 2
 1368882 2 1 1 1 2 1 1 1 1 2
 1369821 10 10 10 10 5 10 10 10 7 4
 1371026 5 10 10 10 4 10 5 6 3 4
 1371920 5 1 1 1 2 1 3 2 1 2
 466906 1 1 1 1 2 1 1 1 1 2
 466906 1 1 1 1 2 1 1 1 1 2
 534555 1 1 1 1 2 1 1 1 1 2
 536708 1 1 1 1 2 1 1 1 1 2
 566346 3 1 1 1 2 1 2 3 1 2
 603148 4 1 1 1 2 1 1 1 1 2
 654546 1 1 1 1 2 1 1 1 8 2
 654546 1 1 1 3 2 1 1 1 1 2
 695091 5 10 10 5 4 5 4 4 1 4
 714039 3 1 1 1 2 1 1 1 1 2
 763235 3 1 1 1 2 1 2 1 2 2
 776715 3 1 1 1 3 2 1 1 1 2
 841769 2 1 1 1 2 1 1 1 1 2
 888820 5 10 10 3 7 3 8 10 2 4
 897471 4 8 6 4 3 4 10 6 1 4
 897471 4 8 8 5 4 5 10 4 1 4

Ek 6 Erythemato-Squamous Problemi İçin Veritabanı

(www.ics.uci.edu/pub/ml-repos/machine-learning-databases/dermatology)

```

3 3 3 2 1 0 0 0 1 1 1 0 0 1 0 1 2 0 2 2 2 2 2 1 0 0 0 0 0 0 0 1 0 8 0.1 0.1 0.1
1 1 2 2 2 0 2 0 1 2 0 0 0 1 0 0 2 1 2 3 3 3 2 2 0 0 0 0 0 0 0 2 0 5 5 0.1 0.1 0.1
2 3 3 3 3 0 0 0 2 1 0 0 0 0 0 2 2 1 3 3 3 3 0 0 0 0 0 0 0 0 0 2 0 3 0 0.1 0.1 0.1
3 2 2 2 2 0 0 0 0 3 0 0 0 2 0 0 3 1 3 3 3 2 0 1 0 0 0 0 0 0 0 2 0 2 9 0.1 0.1 0.1
3 3 3 3 2 0 0 0 0 0 0 0 0 1 0 0 2 1 1 1 2 1 1 2 0 0 0 0 0 0 0 2 0 3 2 0.1 0.1 0.1
1 1 1 1 1 0 0 0 2 2 0 0 0 2 0 0 2 1 1 2 2 1 0 2 0 0 0 0 0 0 0 2 0 0 0.1 0.1 0.1
3 2 2 0 0 0 0 0 2 2 1 0 0 2 0 0 3 2 1 2 2 2 1 1 0 0 0 0 0 0 0 2 0 5 5 0.1 0.1 0.1
2 3 2 0 1 0 0 0 2 3 0 0 0 2 0 0 2 3 1 2 2 2 1 1 0 0 0 0 0 0 0 1 0 2 0 0.1 0.1 0.1
2 3 2 0 1 0 0 0 0 1 0 0 0 0 0 2 0 2 3 2 0 2 0 2 0 0 0 0 0 2 0 4 3 0.1 0.1 0.1
3 2 2 0 0 0 0 0 0 1 1 0 0 0 0 0 3 0 2 2 3 2 0 1 0 2 0 0 0 0 0 2 0 5 0 0.1 0.1 0.1
3 1 2 1 0 0 0 0 2 3 0 0 0 0 0 0 2 0 2 3 2 2 0 3 0 2 0 0 0 0 0 2 0 1 7 0.1 0.1 0.1
2 2 2 0 1 0 0 0 2 1 0 0 0 0 0 0 3 1 1 3 2 2 0 2 0 0 0 0 0 0 0 2 0 2 4 0.1 0.1 0.1
2 2 2 1 0 0 0 0 2 2 0 0 0 0 0 0 2 0 2 2 3 2 0 0 0 2 0 0 0 0 0 2 0 3 6 0.1 0.1 0.1
2 2 2 0 1 0 0 0 2 2 0 0 0 0 0 0 2 1 2 3 2 3 1 2 0 2 0 0 0 0 0 2 0 4 7 0.1 0.1 0.1
1 2 2 2 0 0 0 0 2 2 0 0 0 1 0 0 2 1 3 3 3 2 0 2 0 2 0 0 0 0 0 2 0 2 5 0.1 0.1 0.1
2 2 2 3 2 0 0 0 2 3 1 0 0 1 0 0 2 2 2 2 2 2 0 2 0 3 0 0 0 0 0 2 0 9 0.1 0.1 0.1
2 2 3 0 0 0 0 0 2 2 0 0 0 1 0 0 2 0 2 3 2 3 0 2 0 2 0 0 0 0 0 2 0 3 3 0.1 0.1 0.1
3 2 2 3 2 0 0 0 2 3 0 0 0 0 0 0 3 0 2 2 3 2 0 3 0 2 0 0 0 0 0 1 0 5 5 0.1 0.1 0.1
3 2 2 0 0 0 0 0 3 3 0 0 0 1 0 0 2 0 2 3 2 3 0 2 0 2 0 0 0 0 0 3 0 3 5 0.1 0.1 0.1
2 2 3 1 0 0 0 0 2 1 0 0 0 0 0 0 2 2 3 3 3 2 0 1 0 2 0 0 0 0 0 2 0 5 1 0.1 0.1 0.1
3 2 2 0 0 0 0 0 2 2 0 0 0 0 0 0 3 0 3 2 3 3 0 2 0 3 0 0 0 0 0 3 0 5 8 0.1 0.1 0.1
2 2 3 0 0 0 0 0 3 0 0 0 0 0 0 0 3 2 2 2 3 2 0 0 0 1 0 0 0 0 0 2 0 2 7 0.1 0.1 0.1
2 3 3 0 0 0 0 0 1 0 1 0 0 1 0 0 2 2 2 2 2 2 2 0 1 0 0 0 0 0 2 0 6 2 0.1 0.1 0.1
2 1 1 0 1 0 0 0 2 0 0 0 0 0 0 0 2 2 2 2 2 2 1 2 0 2 0 0 0 0 0 2 0 3 3 0.1 0.1 0.1
2 2 1 0 0 0 0 0 2 2 0 0 0 1 0 0 2 1 1 1 2 2 1 2 0 0 0 0 0 0 0 1 0 4 1 0.1 0.1 0.1
3 1 1 1 1 0 0 0 0 1 1 0 0 0 0 0 1 0 2 2 2 3 0 3 0 0 0 0 0 0 0 2 0 4 8 0.1 0.1 0.1
3 2 1 2 0 0 0 0 1 2 0 0 0 1 0 0 2 0 3 2 2 2 1 2 0 2 0 0 0 0 0 1 0 5 0 0.1 0.1 0.1
3 3 2 1 1 0 0 0 2 2 1 0 0 0 0 0 3 2 3 2 2 2 1 1 0 0 0 0 0 0 0 1 0 4 2 0.1 0.1 0.1
2 2 3 0 1 0 0 0 3 0 0 0 0 2 0 0 1 1 2 2 2 3 0 2 0 1 0 0 0 0 0 2 0 5 3 0.1 0.1 0.1
2 2 2 2 2 0 0 0 0 2 0 0 0 0 0 0 2 0 2 2 3 3 2 2 0 2 0 0 0 0 0 2 0 4 6 0.1 0.1 0.1
2 1 2 0 0 0 0 0 2 0 0 0 0 1 0 0 2 1 2 3 2 3 0 0 0 3 0 0 0 0 0 0 0 3 3 0.1 0.1 0.1
3 2 2 0 0 0 0 0 2 2 0 0 0 0 0 0 3 0 3 2 3 2 0 1 0 2 0 0 0 0 0 1 0 5 6 0.1 0.1 0.1
2 3 2 1 0 0 0 0 2 2 0 0 0 0 0 0 2 0 2 2 3 2 1 0 0 2 0 0 0 0 0 2 0 6 0 0.1 0.1 0.1
3 2 2 0 2 0 0 0 3 2 0 0 0 3 0 0 3 2 2 2 2 2 1 0 0 0 0 0 0 0 0 2 0 6 0 0.1 0.1 0.1
2 3 2 0 0 0 0 0 2 3 0 0 0 2 0 0 2 2 2 2 2 3 2 1 0 0 0 0 0 0 0 2 0 3 3 0.1 0.1 0.1
2 3 2 0 0 0 0 0 3 2 0 0 0 2 0 0 3 2 3 2 2 3 2 1 0 0 0 0 0 0 0 2 0 2 7 0.1 0.1 0.1
3 2 2 0 0 0 0 0 2 2 0 0 0 2 0 0 3 1 2 3 3 2 3 0 0 0 0 0 0 0 0 2 0 5 0 0.1 0.1 0.1
2 3 2 0 0 0 0 0 3 2 0 0 0 2 0 0 2 1 2 3 3 2 2 0 0 0 0 0 0 0 0 1 0 7 0 0.1 0.1 0.1
0 1 2 1 1 0 1 0 2 3 0 0 0 1 0 0 3 1 2 3 3 3 1 1 0 0 0 0 0 0 0 2 0 2 2 0.1 0.1 0.1
2 1 2 2 2 0 0 0 0 0 0 0 1 2 0 2 2 2 2 2 1 1 1 0 0 0 0 0 0 0 3 0 6 2 0.1 0.1 0.1
2 2 2 3 2 0 0 0 1 1 0 0 0 1 0 0 1 1 1 1 1 1 1 1 0 2 0 0 0 0 0 3 0 4 0 0.1 0.1 0.1
1 1 1 1 1 0 1 0 2 3 0 0 0 1 0 0 2 1 2 2 2 2 2 0 0 0 0 0 0 0 3 0 2 5 0.1 0.1 0.1
2 2 2 0 0 0 0 0 3 2 0 0 0 3 0 0 2 0 3 2 2 2 2 0 0 3 0 0 0 0 0 3 0 4 0 0.1 0.1 0.1
2 3 2 3 2 0 0 0 3 2 0 0 0 1 0 0 3 2 3 2 2 2 0 3 0 3 0 0 0 0 0 0 3 6 0.1 0.1 0.1
2 2 2 2 2 0 0 0 3 0 1 0 0 0 0 0 2 2 2 2 3 3 0 2 0 3 0 0 0 0 0 0 7 5 0.1 0.1 0.1
2 2 2 0 1 0 0 0 0 1 0 0 0 1 0 0 2 0 2 3 2 3 2 1 0 1 0 0 0 0 0 2 0 4 5 0.1 0.1 0.1
2 3 2 1 0 0 0 0 2 2 0 0 0 1 0 0 2 0 2 2 2 2 0 2 0 2 0 0 0 0 0 3 0 2 4 0.1 0.1 0.1
2 1 1 0 0 0 0 0 1 1 1 0 0 1 0 0 2 2 2 2 2 2 0 1 0 1 0 0 0 0 0 1 0 4 0 0.1 0.1 0.1
3 2 1 2 2 0 0 0 2 2 0 0 0 1 0 0 2 3 2 2 2 3 0 3 0 0 0 0 0 0 0 3 1 3 6 0.1 0.1 0.1
2 2 2 3 2 0 0 0 3 3 0 0 0 1 0 0 2 0 2 2 2 2 2 2 0 1 0 0 0 0 0 2 0 4 1 0.1 0.1 0.1
2 3 2 1 0 0 0 0 1 2 1 0 0 1 0 2 1 0 1 2 2 1 1 0 0 0 0 0 0 0 0 2 0 2 7 0.1 0.1 0.1
3 3 2 2 0 0 0 0 2 0 0 0 0 1 0 2 1 0 2 1 1 1 1 0 0 0 0 0 0 0 0 2 0 4 6 0.1 0.1 0.1
2 2 2 0 0 0 0 0 1 0 0 0 0 2 0 1 3 0 1 2 2 1 0 0 0 0 0 0 0 0 0 1 0 5 2 0.1 0.1 0.1
3 3 2 1 1 0 0 0 2 2 1 0 0 0 0 0 3 2 3 2 2 2 1 1 0 0 0 0 0 0 0 1 0 2 0 0.1 0.1 0.1
2 3 3 0 0 0 0 0 1 1 1 0 0 1 0 0 2 1 2 1 2 3 0 2 0 0 0 0 0 0 0 2 0 1 0 0.1 0.1 0.1
3 3 3 0 0 0 0 0 3 3 1 0 0 2 0 0 2 0 2 3 3 3 2 3 0 3 0 0 0 0 0 2 0 3 8 0.1 0.1 0.1

```

22210000000000002212000000000300020250.10.10.9
 3221000010100103201000000000300030160.10.10.9
 22210000000000002210000000000200020700.10.10.9
 32200000000000002210000000000200030220.10.10.9
 23210000000000000320000000000300030450.10.10.9
 22020000000001102202000000000300020470.10.10.9
 3201000001002203202000000000200030300.10.10.9
 2303000002002202303000000000200020420.10.10.9
 3202000002002202202000000000100020550.10.10.9
 22120000000000103201000000000300020350.10.10.9
 22110000100011022110101010000200010200.10.10.9
 22120000000000102202000000000200020270.10.10.9
 33220000000000000202010000000300020330.10.10.9
 2212000000000110220100010000300020220.10.10.9
 3220000000000110110200010000200020500.10.10.9
 22200000000001202001000000000200010330.10.10.9
 32100000000001102002000000000200010440.10.10.9
 22030000000000203300000000000200020400.10.10.9
 23020000000000000330000000000200010550.10.10.9
 22110000000000102302000000000200010230.10.10.9
 32020000000000102201000000000200000200.10.10.9
 21120000000000002100000000000200030610.10.10.9
 22120000000000002100000000000200010330.10.10.9
 32210000000000001200000000000300020470.10.10.9
 32030000000001103201000000000300020520.10.10.9
 22122000000000101201000000000200020200.10.10.9
 23020000000000000320000000000200010450.10.10.9
 12030000000000000220000000000200020340.10.10.9
 23120000000001003202020000000200010200.10.10.9
 12210000000002002301010000000100020340.10.10.9
 2323330200030003203000000302220022410.10.90.1
 201002010003000222200000103020022600.10.90.1
 311222000002000210100000102030023320.10.90.1
 213333002003000320100000302030023230.10.90.1
 212313030001000120200000202320023260.10.90.1
 222322020003200021100000303020023440.10.90.1
 232222020001000120000000223230023450.10.90.1
 223333020002000230000000022320033570.10.90.1
 223233030002000230200000302220022400.10.90.1
 111222020002000220100000202020033470.10.90.1
 223213020002000230000000203020023440.10.90.1
 222322020003000320100000203230033180.10.90.1
 3222320200022003300000000303030023280.10.90.1
 2131230200020003200000000302010023500.10.90.1
 223303020002000111100000203030013650.10.90.1
 112322030002000221200000303031023500.10.90.1
 212321020000000222100000201030023260.10.90.1
 211112010002000321100000202020033480.10.90.1
 322202010002000111100000202020013600.10.90.1
 211303010001000220100000103010022290.10.90.1
 223222030002002220100000203320022520.10.90.1
 211322020000002302000003020220032270.10.90.1
 112323030002000220200000203230023360.10.90.1
 223312020001000330200000302120023400.10.90.1
 332203020002000220200000202330023320.10.90.1
 222232030003000320100000203030033440.10.90.1
 322133030003000320300000203330022340.10.90.1
 211102020002000220200000102220033400.10.90.1
 111110010002000310100000202020023520.10.90.1
 000000030001000311100000203330033520.10.90.1
 212110020002000220200000303030033480.10.90.1

2113220200020002201000000203020033220.10.90.1
 3222020200020002202000000201110022220.10.90.1
 2233120200020003202000000202000023510.10.90.1
 2233130200030002302000000203220033220.10.90.1
 1123120200010001301000000102230023450.10.90.1
 2110100000000002201000000010200010350.90.10.1
 32110000000001003211000000010100020250.90.10.1
 12201000000000102221000000010200010600.90.10.1
 222010000000000221100000000200020220.90.10.1
 12201000000000003221000000010200020350.90.10.1
 2221000000000000222200000000100020360.90.10.1
 3210200000000000220000000000300020450.90.10.1
 2210100000000000320000000000300020350.90.10.1
 3110100000000000220000000000200030300.90.10.1
 2221200000000000320000000000300020420.90.10.1
 21010000000000102101000000010300020180.90.10.1
 22202000000000002101000000010200010200.90.10.1
 21022000000000003111000000010200010180.90.10.1
 1101100000000000200100000000200020600.90.10.1
 1110200000000010110100000000200010310.90.10.1
 2122100000000000200100000000200010170.90.10.1
 2120200000000000220100000000200010350.90.10.1
 2102200000000000211100000000200010160.90.10.1
 2202100000000000200200000000300030700.90.10.1
 2220200000000000220200000000200010300.90.10.1
 2202200000000000300200000000300020250.90.10.1
 11100000000000001101000000010100010250.90.10.1
 2113300000000000221100000000100020460.90.10.1
 2210200000000000210100000000200020220.90.10.1
 210200000000000312100200000000001080.90.10.9
 2113001000000020200030000000000020190.90.10.9
 1122000010001030320020000000000000360.90.10.9
 210300000000000302000000000000000010700.90.10.9
 221300000000000302100300000000000020520.90.10.9
 33320000000000032222020000000000030400.90.10.9
 01020000000000031210010000000000030510.90.10.9
 010300000000000202200000000000000010300.90.10.9
 21020000000000031300020000000000020180.90.10.9
 1103000000000003032203000000100020170.90.10.9
 2202000000000001131202100000101020420.90.10.9
 20030000000000022200030000000000020220.90.10.9
 1223000000000001121103000000100030170.90.10.9
 11010000000000021302020000000000010330.90.10.9
 22120000000000021111000000000000010270.90.10.9
 11110000000000011112010000000000020480.90.10.9
 11230000000000031111000000000000010550.90.10.9
 111300100000002131102000000100020300.90.10.9
 11100000000000030200030000000000010600.90.10.9
 11030000000001020301020000000000010270.90.10.9
 22100000000000020300020000000000030290.90.10.9
 32200000000000010200010000000000020340.90.10.9
 10120000000000030310020000000000010280.90.10.9
 11000000000000020300020000000000010170.90.10.9
 22200010101000022100000000010322090.90.90.1
 221000202000000320100000000202310160.90.90.1
 220100202000000220000000000102220220.90.90.1
 322000301010000131100000000203220100.90.90.1
 22100020200000032010000000030222070.90.90.1
 21120030120001001220101000000121080.90.90.1
 1101003010000100111000000100102210100.90.90.1
 2111002032000101111000000000000111120.90.90.1

22110010111000012111100000010111080.90.90.1
 212000303000000221200000000003300130.90.90.1

2. Alt Küme:

233330003300000032233313000000010340.10.10.1
 332000002210010022322102000000010460.10.10.1
 321100002100000021111101000000010150.10.10.1
 222000000100000120213201000000010190.10.10.1
 222000002200010020233313030000030360.10.10.1
 33301000200000011222200000000020210.10.10.1
 322220000000010021112111000000020400.10.10.1
 222010001100000021233202010000020420.10.10.1
 232010003210010030223300020000020270.10.10.1
 223100002200000031332221030000020500.10.10.1
 213010000200000030223300020000020340.10.10.1
 333220002200010010111111020000030430.10.10.1
 22233000020012011111112000000020300.10.10.1
 332210000100220121112121000000020420.10.10.1
 231210000000020010021220000000020190.10.10.1
 322320000200020221233331000000030610.10.10.1
 322310001110020020223211000000010550.10.10.1
 232210002200020020333222000000020670.10.10.1
 232000002200020020232130020000020550.10.10.1
 323000003000030010122020030000010560.10.10.1
 333000002000020020223030020000020180.10.10.1
 222000003200020020223230020000030300.10.10.1
 323000002200020030222330020000020330.10.10.1
 232000002000030030222020000000020270.10.10.1
 322000000000020020102200000000020560.10.10.1
 131000000000020020203300000000030600.10.10.1
 222000000000030030303300000000020200.10.10.1
 222000003000020020222020020000020230.10.10.1
 222000002210020020332221020000020180.10.10.1
 322000003310030030232320030000020350.10.10.1
 33333000331001002122222010000020420.10.10.1
 222220002100000202222211000000010280.10.10.1
 111110001100020012111203000000020380.10.10.1
 222220002210010021222102001000010390.10.10.1
 222110002010020121222211010000020600.10.10.1
 323010001200020212111111020000020650.10.10.1
 222100000110010212221200010000020470.10.10.1
 323200000210000213222200030000030350.10.10.1
 221100000210000222212200020000020520.10.10.1
 222200000100000223221100020000010600.10.10.1
 222300002210010021233301020000010250.10.10.1
 32230000200002002222202020000010600.10.10.1
 222200002210010030322202020000020500.10.10.1
 212000003210020020232202030000020330.10.10.1
 333000002300010030333301030000030270.10.10.1
 222000002300020020232202020000020550.10.10.1
 22200000220002002022202020000020620.10.10.1
 322000000110020020112210020000020190.10.10.1
 332000002200000021223210010000020550.10.10.1
 233100002100000030222301020000020220.10.10.1
 332010002210000021333210010000020300.10.10.1
 223100003210000120333211020000030570.10.10.1
 122110002210010020233321020000020620.10.10.1
 223100001200010020233211020000020360.10.10.1
 322200002100010020323221020000030180.10.10.1
 322200000000030220300000000200010310.10.10.9
 211200000000020320200000000300030270.10.10.9

322100000000010210200000000200020100.10.10.9
 22020000000001032000000000300010300.10.10.9
 32030000000002022000000000200020190.10.10.9
 23020000000002033000000000200020520.10.10.9
 32020000001002022000000000300030550.10.10.9
 22210000000001012000000000200010340.10.10.9
 11120000000011031000000000200020220.10.10.9
 211000001000010110100000000200020350.10.10.9
 111000100000110211100000000300010510.10.10.9
 22000000000010032000000000200010400.10.10.9
 221100000000110221000000000300010250.10.10.9
 33030000000011031000000000300020330.10.10.9
 211100000000010321000020000200010150.10.10.9
 220300000000020310100000000200020360.10.10.9
 320200000000120211100010000000010100.10.10.9
 220300001000000320000000000300010550.10.10.9
 322000000000020221202120000300020510.10.10.9
 220300000000020220000010000300010210.10.10.9
 321300000010120320101000000300010500.10.10.9
 2102000000000110200000000000000020430.10.10.9
 331200000100020310100000000200010220.10.10.9
 321200000000020210200000000200020250.10.10.9
 222100000000020120300000000300000330.10.10.9
 2320000000000210220200010000200010410.10.10.9
 2213000000000202101000000000000010300.10.10.9
 322200000000020333200000000201120430.10.10.9
 121100000100000210100000000200002520.10.10.9
 3321000000000200230202000000200010370.10.10.9
 122203020002000320200000302220022420.10.90.1
 222202030003000330300000303330022360.10.90.1
 322202020002000230300000202320023400.10.90.1
 212312020002000130200000202030032500.10.90.1
 233303030002000210200000202030022380.10.90.1
 32220200002000320300000203020033250.10.90.1
 323312020003000220200000102020023520.10.90.1
 212223020002100320000000302020023510.10.90.1
 212322030002100220100000202120023370.10.90.1
 112323020002000210200000202020023490.10.90.1
 222312020002000220100000222130023280.10.90.1
 222213020002000320000000322220033300.10.90.1
 323222020003000230100000212210023530.10.90.1
 232332020002000320000000322120022270.10.90.1
 212102020002000220100000202020033400.10.90.1
 223103020003000330000000103230033280.10.90.1
 322102030002000221100000203120033360.10.90.1
 223212020002000230000000202220033270.10.90.1
 223312010002000022010000010202023250.10.90.1
 223323010002000320100000203030023260.10.90.1
 312322020002000220100000202020033160.10.90.1
 222323020002000220000000302020023320.10.90.1
 212332020003000310000000203020023510.10.90.1
 223223010002000330100000203030032560.10.90.1
 322202020003000320100000102030033360.10.90.1
 222312010002000220100000102030012500.10.90.1
 223222030003000230000000223220023500.10.90.1
 322333020002000230000000222220022420.10.90.1
 211222020002100321100000202230023500.10.90.1
 222233020002000231100000202320032400.10.90.1
 222212020002100321100000202230023620.10.90.1
 222212020003100221100000202320023360.10.90.1
 212203020002100321100000202320032270.10.90.1

312303000102100231200000103230022470.10.90.1
 212202000101100231200000202220022500.10.90.1
 2210100000000000320200000000200020300.90.10.1
 1101300000000000110100000000200020400.90.10.1
 211010000000000010110000000000100020250.90.10.1
 32101000000000002200000000010100020360.90.10.1
 111000000000000010110100000000200020620.90.10.1
 111020000000000010111100001000010010350.90.10.1
 1101300000000000110100000000200020210.90.10.1
 2120100000000000220100000000200020340.90.10.1
 2110100000000000310000000010300020220.90.10.1
 2121100000000000220100000010300020550.90.10.1
 2110100000000000320000000000200020120.90.10.1
 22201000000000002100000000010200020320.90.10.1
 21101000000001003201000000000100010270.90.10.1
 3110100000000000220000000000200020460.90.10.1
 11101000000000000120000000000200030220.90.10.1
 2220100000000000220100000020200020440.90.10.1
 2221100000000000210000000000200020350.90.10.1
 22210000000001000200000000010200020400.90.10.1
 3220000000000000321000000010200020350.90.10.1
 22101000000000002200000000010300020620.90.10.1
 2220000000000000310000000010200030480.90.10.1
 2210100000000000210100000000200020500.90.10.1
 1220100000000000210000000010200010550.90.10.1
 2210000000000000221100000000200020270.90.10.1
 11200000000000003020002000000000020390.90.10.9
 22230010000000031222020000000000010160.90.10.9
 22210020000000031322020000000000020460.90.10.9
 11200000000000030200020000000000010640.90.10.9
 11020010000000021210010000000000020180.90.10.9
 11010020000000012120020000000000020250.90.10.9
 22020010000000021210020000000000030520.90.10.9
 11010020000000022120010000000000010350.90.10.9
 2202001000000001122000000000000021400.90.10.9
 11130000000000021301020000000000020180.90.10.9
 2122000000000003030202000000200010250.90.10.9
 2133000000000002020202000000100010360.90.10.9
 21220000000000010101010000000000010400.90.10.9
 12110000000000020202020000000000020350.90.10.9
 11120000000000030202020000000000020190.90.10.9
 21200000000000020202020000000000010500.90.10.9
 10030000000001032300020000000000030360.90.10.9
 20130000000000022301030000000000030630.90.10.9
 2100000000000102230002000000100020420.90.10.9
 31010000000000012200020000000000020320.90.10.9
 11020000000000031201030000000000020680.90.10.9
 20120000000000022100020000000000020500.90.10.9
 1112000000000003220002000000100020450.90.10.9
 20120000000000031200020000000000020560.90.10.9
 112000303010000211110000000000222070.90.90.1
 22200020200000022220000000000222080.90.90.1
 221000202010000111100000000001110130.90.90.1
 2200002011100002201000000000101210100.90.90.1
 221000302010000221200000000020332070.90.90.1
 22210020221000012020000000020222070.90.90.1
 32000020220000021020000000010233080.90.90.1
 221100202010000111100000000201220100.90.90.1
 320100201010000121200000000301220120.90.90.1
 221100200000000011110000000020122080.90.90.1

Ek 7 Çıkarma Devresi İçin TSPICE Simülasyon Dosyası

```

*****
***** çıkarma devresi *****
VVss Vss 0 dc -3.3v
VVdd Vdd 0 dc 3.3v
IA 0 1 0.5mA
IB 0 4 0.1mA

M1 1 1 Vss Vss NMOD W=8U L=1.5U
M2 2 1 Vss Vss NMOD W=8U L=1.5U
M3 2 2 Vdd Vdd PMOD W=10U L=1.5U
M4 3 2 Vdd Vdd PMOD W=10U L=1.5U
M5 3 4 Vss Vss NMOD W=9.5U L=1.5U
M6 4 4 Vss Vss NMOD W=9.5U L=1.5U
M7 3 3 Vss Vss NMOD W=5.5U L=2.5U

.model NMOD nmos level=3 tox=230e-10 ld=0.125e-6 wd=0.6e-6 uo=570 vto=0.7
+theta=0.05 rs=75 rd=75 delta=0.4 nsub=1.2e16 xj=0.15e-6 vmax=2.3e5
+eta=0.0022 kappa=0.5 nfs=7e11 gamma= 0.46 phi=0.35

.model PMOD pmos level=3 tox=230e-10 ld=0.06e-6 wd=0.6e-6 uo=230 vto=-0.66
+theta=0.17 rs=120 rd=120 delta=0.4 nsub=1.2e16 xj=0.3e-6 vmax=0
+eta=0.016 kappa=0.06 nfs=1e12 gamma=0.48 phi=0.35
.OP
.tran 0.1u 1m
.dc IB 0 0.5mA 0.025mA
.probe
.END

```

Ek 8 Kare Alma/Bölme Devresi İçin TSPICE Simülasyon Dosyası

 ***** kare alma/bölme devresi*****

VVss Vss 0 dc -3.3v
 VVdd Vdd 0 dc 3.3v
 IH 0 1 0.5mA
 IX 0 9 0.3mA

M1 1 1 Vss Vss NMOS W=2.5U L=1.5U
 M2 2 1 Vss Vss NMOS W=2.5U L=1.5U
 M3 2 2 Vdd Vdd PMOS W=8U L=1.5U
 M4 3 2 Vdd Vdd PMOS W=8U L=1.5U
 M5 6 2 Vdd Vdd PMOS W=8U L=1.5U
 M6 3 3 4 Vss NMOS W=5.5U L=1.5U
 M7 4 4 Vss Vss NMOS W=5.5U L=1.5U
 M8 6 3 9 Vss NMOS W=6U L=4.5U
 M9 9 9 Vss Vss NMOS W=6U L=4.5U
 M10 6 9 Vss Vss NMOS W=6U L=4.5U
 M11 6 6 Vdd Vdd PMOS W=30U L=1.5U
 M12 7 6 Vdd Vdd PMOS W=95U L=1.5U
 M13 7 7 Vss Vss NMOS W=2.5U L=1.5U

.model NMOS nmos level=3 tox=230e-10 ld=0.125e-6 wd=0.6e-6 uo=570 vto=0.7
 +theta=0.05 rs=75 rd=75 delta=0.4 nsub=1.2e16 xj=0.15e-6 vmax=2.3e5
 +eta=0.0022 kappa=0.5 nfs=7e11 gamma=0.46 phi=0.35
 .model PMOS pmos level=3 tox=230e-10 ld=0.06e-6 wd=0.6e-6 uo=230 vto=-0.66
 +theta=0.17 rs=120 rd=120 delta=0.4 nsub=1.2e16 xj=0.3e-6 vmax=0
 +eta=0.016 kappa=0.06 nfs=1e12 gamma=0.48 phi=0.35
 .OP
 .tran 0.1u 1m
 .dc IX -0.5mA 0.5mA 0.025mA
 .probe
 .END

Ek 9 Üstel Fonksiyon Devresi İçin TSPICE Simülasyon Dosyası

 ***** üstel fonksiyon devresi *****

VVss Vss 0 dc -3.3v
 VVdd Vdd 0 dc 3.3v
 IH 0 1 1mA
 IX 0 9 0.3mA
 IA 0 7 1mA
 M1 1 1 Vss Vss NMOD W=2.5U L=1.5U
 M2 2 1 Vss Vss NMOD W=2.5U L=1.5U
 M3 2 2 Vdd Vdd PMOD W=7U L=1.5U
 M4 3 2 Vdd Vdd PMOD W=7U L=1.5U
 M5 6 2 Vdd Vdd PMOD W=7U L=1.5U
 M6 3 3 4 Vss NMOD W=25U L=1.5U
 M7 4 4 Vss Vss NMOD W=25U L=1.5U
 M8 6 3 9 Vss NMOD W=4.5U L=4.5U
 M9 9 9 Vss Vss NMOD W=4.5U L=4.5U
 M10 6 9 Vss Vss NMOD W=4.5U L=4.5U
 M11 6 6 Vdd Vdd PMOD W=8U L=1.5U
 M12 7 6 Vdd Vdd PMOD W=8U L=1.5U
 M13 7 9 Vss Vss NMOD W=4.5U L=4.5U
 M14 7 7 Vss Vss NMOD W=6U L=4.5U

.model NMOD nmos level=3 tox=230e-10 ld=0.125e-6 wd=0.6e-6 uo=570 vto=0.7
 +theta=0.05 rs=75 rd=75 delta=0.4 nsub=1.2e16 xj=0.15e-6 vmax=2.3e5
 +eta=0.0022 kappa=0.5 nfs=7e11 gamma=0.46 phi=0.35

.model PMOD pmos level=3 tox=230e-10 ld=0.06e-6 wd=0.6e-6 uo=230 vto=-0.66
 +theta=0.17 rs=120 rd=120 delta=0.4 nsub=1.2e16 xj=0.3e-6 vmax=0
 +eta=0.016 kappa=0.06 nfs=1e12 gamma=0.48 phi=0.35

.OP
 .tran 0.1u 1m
 .dc IX 0 1mA 0.025mA
 .probe
 .END

Ek 10 Çarpma/Bölme Devresi İçin TSPICE Simülasyon Dosyası

 ***** çarpma/bölme devresi*****

VVss Vss 0 dc -3.3v
 VVdd Vdd 0 dc 3.3v
 IE 0 1 2mA
 IX1 0 9 2.7mA
 IX2 0 19 0.9mA

M1 1 1 Vss Vss NMOD W=11U L=1.5U
 M2 2 1 Vss Vss NMOD W=11U L=1.5U
 M3 2 2 Vdd Vdd PMOD W=17U L=1.5U
 M4 3 2 Vdd Vdd PMOD W=17U L=1.5U
 M5 6 2 Vdd Vdd PMOD W=17U L=1.5U
 M6 3 3 4 Vss NMOD W=10.5U L=1.5U
 M7 4 4 Vss Vss NMOD W=10.5U L=1.5U
 M8 6 3 9 Vss NMOD W=16.5U L=4.5U
 M9 9 9 Vss Vss NMOD W=16.5U L=4.5U
 M10 6 9 Vss Vss NMOD W=16.5U L=4.5U
 M11 6 6 Vdd Vdd PMOD W=16U L=1.5U
 M12 7 6 Vdd Vdd PMOD W=16U L=1.5U
 M13 7 17 Vss Vss NMOD W=5U L=2.5U
 M14 16 2 Vdd Vdd PMOD W=17U L=1.5U
 M15 13 2 Vdd Vdd PMOD W=17U L=1.5U
 M16 13 13 14 Vss NMOD W=10.5U L=1.5U
 M17 14 14 Vss Vss NMOD W=10.5U L=1.5U
 M18 16 13 19 Vss NMOD W=16.5U L=4.5U
 M19 19 19 Vss Vss NMOD W=16.5U L=4.5U
 M20 16 19 Vss Vss NMOD W=16.5U L=4.5U
 M21 16 16 Vdd Vdd PMOD W=16U L=1.5U
 M22 17 16 Vdd Vdd PMOD W=16U L=1.5U
 M23 17 17 Vss Vss NMOD W=5U L=2.5U
 R 7 0 1K

.model NMOD nmos level=3 tox=230e-10 ld=0.125e-6 wd=0.6e-6 uo=570 vto=0.7
 +theta=0.05 rs=75 rd=75 delta=0.4 nsub=1.2e16 xj=0.15e-6 vmax=2.3e5
 +eta=0.0022 kappa=0.5 nfs=7e11 gamma= 0.46 phi=0.35

.model PMOD pmos level=3 tox=230e-10 ld=0.06e-6 wd=0.6e-6 uo=230 vto=-0.66
 +theta=0.17 rs=120 rd=120 delta=0.4 nsub=1.2e16 xj=0.3e-6 vmax=0
 +eta=0.016 kappa=0.06 nfs=1e12 gamma=0.48 phi=0.35

.OP
 .tran 0.1u 1m
 .dc IX1 0 2mA 0.025mA
 .probe
 .END

ÖZGEÇMİŞ

Doğum tarihi 4.8.1980

Doğum yeri İzmit

Lise 1991-1998 Kocaeli Anadolu Lisesi

Lisans 1998-2002 Yıldız Üniversitesi Mühendislik Fak.
Elektronik ve Haberleşme Mühendisliği Bölümü

Yüksek Lisans 2002-2004 Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü
Elektronik ve Haberleşme Müh. Anabilim Dalı
Elektronik Programı

Çalıştığı kurum

2002-Devam ediyor YTÜ Elektrik-Elektronik Fakültesi
Elektronik ve Haberleşme Mühendisliği Bölümü
Elektronik Anabilim Dalı Araştırma Görevlisi

