

**MESLEKİ BEL AĞRISI RİSKİNİN DESTEK VEKTÖR
MAKİNELERİYLE SINIFLANDIRILMASI**

Mehmet ERDEM

**YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

Aralık 2012

ANKARA

Mehmet ERDEM tarafından hazırlanan MESLEKİ BEL AĞRISI RİSKİNİN DESTEK VEKTÖR MAKİNELERİYLE SINIFLANDIRILMASI adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

Doç. Dr. Diyar AKAY

.....

Tez Danışmanı, Endüstri Müh. Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Endüstri Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Yrd. Doç. Dr. Ramazan ŞAHİN

.....

Endüstri Müh. Anabilim Dalı, Gazi Üni.

Doç. Dr. Diyar AKAY

.....

Endüstri Müh. Anabilim Dalı, Gazi Üni.

Yrd. Doç. Dr. Selçuk Kürşat İŞLEYEN

.....

Endüstri Müh. Anabilim Dalı, Gazi Üni.

Tarih: 20/12/2012

Bu tez ile G.Ü. Fen Bilimleri Enstitüsü Yönetim Kurulu Yüksek Lisans derecesini onamıştır.

Prof. Dr. Şeref SAĞIROĞLU

.....

Fen Bilimleri Enstitüsü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Mehmet ERDEM

**MESLEKİ BEL AĞRISI RİSKİNİN DESTEK VEKTÖR MAKİNELERİYLE
SINIFLANDIRILMASI
(Yüksek Lisans Tezi)**

Mehmet ERDEM

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
Aralık 2012**

ÖZET

Endüstrileşme sonucu gelişen teknolojiye rağmen elle malzeme kaldırma (EMK) işleri hala yoğun olarak yapılmaktadır. Yapılan araştırmalar, EMK işlerinin mesleki bel ağrısı (MBA) rahatsızlığına yol açan başlıca sebep olduğunu ortaya koymuştur. Literatürde, MBA riskine yol açan gövde hareket değişkenleri ve iş ile ilgili değişkenler belirlenmiştir. Bu değişkenler 235 farklı iş için ölçülmüş, yaralanma ve medikal kayıtlar dikkate alınarak MBA riski düşük ve yüksek olarak iki gruba ayrılmıştır. Bu çalışmada, MBA riski destek vektör makineleri (DVM) ile sınıflandırılmıştır. DVM ile elde edilen sınıflandırma sonucu aynı veriyi kullanan literatürdeki diğer çalışmaların sonuçlarıyla karşılaştırılmıştır. Çalışmadan elde edilen sonuçlar, DVM'nin literatürdeki yöntemlere göre MBA riskini sınıflandırmada daha iyi bir sınıflandırıcı olduğunu göstermiştir.

Bilim Kodu : 906.1.039

Anahtar Kelimeler : Mesleki Bel Ağrısı Rahatsızlığı, Destek Vektör Makineleri

Sayfa Adedi : 75

Tez Yöneticisi : Doç. Dr. Diyar AKAY

CLASSIFICATION OF RISKS OF LOW BACK DISORDERS WITH SUPPORT VECTOR MACHINES

(M.Sc. Thesis)

Mehmet ERDEM

**GAZI UNIVERSITY
INSTITUTE OF SCIENCE AND TECHNOLOGY**

December 2012

ABSTRACT

In spite of the advanced technology, manual material handling (MMH) tasks are still done frequently. According to the surveys, MMH tasks are the leading cause of occupational low back disorders (LBDs). In the literature, the trunk motion variables and the workplace variables related to the risk of LBDs were determined. These variables were sampled for 235 MMH tasks in different manufacturing industries and were divided into high and low risk groups of LBD based on their injury and medical records. In this study, occupational LBD risks were classified with support vector machines (SVM). The results were compared with the results of studies using the same experimental data. The results obtained in this study indicate that SVM is a better classifier than the proposed methods in the literature to classify the LBD risks.

Science Code : 906.1.039

Key Words : Occupational Low Back Disorder, Support Vector Machines

Page Number: 75

Adviser : Assoc. Prof. Dr. Diyar AKAY

TEŞEKKÜR

Bu çalışmanın oluşmasında çok değerli yardım ve katkılarıyla beni yönlendiren Hocam Doç. Dr. Diyar Akay'a, çalışmamın bazı aşamalarında yardımını esirgemeyen Araş. Gör. Fatih Emre Boran'a ve manevi destekleriyle beni hiçbir zaman yalnız bırakmayan değerli aileme teşekkürü bir borç bilirim.

Gazi Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından desteklenmiştir.

Proje Kodu: 06/2010-21

İÇİNDEKİLER

Sayfa

ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	x
ŞEKİLLERİN LİSTESİ	iv
SİMGELER VE KISALTMALAR.....	v
1. GİRİŞ	1
2. MESLEKİ BEL AĞRISI	3
2.1. Mesleki Bel Ağrısı.....	3
2.2. Mesleki Risk Faktörleri	5
2.2.1. Ağır fiziksel işler	6
2.2.2. Statik çalışma duruşu	7
2.2.3. Tekrarlı bükme ve döndürme hareketi.....	7
2.2.4. Kaldırma, itme ve çekme	8
2.2.5. Tekrarlı işler.....	8
2.2.6. Titreşim.....	9
2.2.7. Psikolojik ve psikososyal çalışma faktörleri.....	9
2.3. Literatür Taraması	10
3. DESTEK VEKTÖR MAKİNELERİ	19
3.1. Doğrusal Ayrılabilen DVM.....	20
3.2. Doğrusal Ayrılamayan DVM	27

Sayfa

3.3. Doğrusal Olmayan DVM	31
4. MBA RİSKİNİNİN DVM İLE SINIFLANDIRILMASI	36
4.1. MBA-DVM Modelinin Parametreleri	36
4.1.1. Kernel ve kernel parametrelerinin seçimi	37
4.1.2. Optimal parametre seçimi	39
4.2. Sınıflandırıcı Performansının Değerlendirilmesi	40
4.2.1. Doğru sınıflandırma yüzdesi (DSY)	41
4.2.2. Hata oranı	41
4.2.3. Kesinlik	42
4.2.4. Doğru pozitif oranı	42
4.2.5. F1 skoru	42
4.2.6. Alıcı işletim karakteristiği (AİK) grafiği	43
4.2.7. Yakınlık katsayısı	44
4.2.8. AİK eğrisi altında kalan alan	44
4.3. MBA-DVM Modellerinin Değişkenleri	45
4.4. MBA-DVM Model Performanslarının Karşılaştırılması	47
4.4.1. Doğrusal kernel DVM modeli	47
4.4.2. Polinom kernel DVM modeli	49
4.4.3. RBF kernel DVM modeli	50
4.5. MBA Riskini Sınıflandıracak DVM Modelinin Belirlenmesi	52
5. SONUÇ	57
KAYNAKLAR	59

Sayfa

EKLER.....	66
EK-1 VC boyutu	67
EK-2 Yapısal risk minimizasyonu	68
EK-3 Lagrange çarpanlarının anlamı	70
EK-4 Sonsal olasılık değerinin hesaplanması	73
EK-5 Katmanlı örneklem için Matlab kodu.....	74
ÖZGEÇMİŞ	75

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Kernel ve kernelin kullandığı parametreler	39
Çizelge 4.2. Karşılaştırma matrisi	41
Çizelge 4.3. Kerneller ve kernellerin kullandıkları parametreler	47
Çizelge 4.4. Doğrusal kernel DVM modellerinin sonuçları	48
Çizelge 4.5. Doğrusal kernel DVM modeline ait karşılaştırma matrisi	49
Çizelge 4.6. Polinom kernel DVM modellerinin sonuçları	50
Çizelge 4.7. Polinom kernel DVM modeline ait karşılaştırma matrisi	50
Çizelge 4.8. RBF kernel DVM modellerinin sonuçları	51
Çizelge 4.9. RBF kernel DVM modeline ait karşılaştırma matrisi	51
Çizelge 4.10. Kernel performanslarının karşılaştırılması	52
Çizelge 4.11. Marras vd. verisini kullanan çalışmaların sonuçlarının	53
Çizelge 4.12. Marras vd. verisini kullanan çalışmaların farklı performans	54
Çizelge 4.13. Marras vd. verisini kullanarak yapılan çalışmaların karşılaştırılması-2	55

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. MBA'ya yol açan faktörler	6
Şekil 3.1. İki sınıflı veri	20
Şekil 3.2. İki sınıflı verinin doğrusal sınıflandırılması	21
Şekil 3.3. İki sınıflı verinin sınıflandırılması	23
Şekil 3.4. Optimal ayırıcı hiperdüzlem	23
Şekil 3.5. İki boyutlu uzayda doğrusal olarak ayıramayan durum.....	28
Şekil 3.6. Tek boyutlu verinin ayrılması.....	31
Şekil 3.7. Girdi uzayındaki verinin özellik uzayına haritalanması	32
Şekil 4.1. AİK grafiğinde önemli noktalar	44
Şekil 4.2. Farklı modeller için AİK eğrileri	45
Şekil 4.3. Modelin parametreleri.....	46
Şekil 4.4. Doğrusal kernel DVM modelleri	48

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklama

x

Giriş Verileri

b

Bias Terimi

ξ

Aylak Değişkenler

α

Lagrange Çarpanı

Kısaltmalar

Açıklama

AİK

Alıcı işletim karakteristiği

DSY

Doğru sınıflandırma yüzdesi

DVM

Destek vektör makineleri

EMK

Elle malzeme kaldırma

KİSR

Kas-iskelet sistemi rahatsızlıkları

MBA

Mesleki bel ağrısı

1. GİRİŞ

Endüstrileşme sonucu gelişen teknolojiye rağmen fiziksel işgücü hala yoğun olarak kullanılmaktadır. Bu işlerde çalışanlarda, uygun olmayan iş istasyonu tasarımlarından kaynaklanan fiziksel zorlanma ve yanlış çalışma duruşu gibi nedenlerden dolayı, kas ve iskelet sistemlerinde çeşitli rahatsızlıklara rastlanmaktadır. Bu rahatsızlıklar en çok elle malzeme kaldırma (EMK) işlerinde çalışanlarda sıklıkla kendini göstermektedir. EMK işlerinde çalışan işçilerin en büyük sorunu olan bel ağrısı ve kas-iskelet sistemi rahatsızlıklarını (KİSR) tespit etme ve önleme yöntemleri günümüzde ergonomi bilim dalının en önemli konularından biri olmaya devam etmektedir.

Ergonomide EMK çalışmaları; elle malzeme taşımaya neden olan rahatsızlık, yaralanma, fiziksel zorlanma koşulların belirlenmesi, yönetsel (doğru personel seçimi, doğru biçimde elle kaldırma teknikleri ile ilgili eğitimler ve iş gören rotasyonu vb.) ve mühendislik kontrollerinin (iş iyileştirmesi, mekanik yardımlar vb.) uygulanmasıyla sağlık sorunlarının en aza indirilmesi konularını kapsar.

Bu tez çalışmasında EMK işlerinden kaynaklanan mesleki bel ağrısı (MBA) riskinin destek vektör makineleri (DVM) ile sınıflandırılması amaçlanmıştır. Bu amacı gerçekleştirebilmek için tez çalışması şu şekilde yapılandırılmıştır:

İkinci bölümde EMK işlerinin tanımı yapılmış, MBA'ya yol açan EMK işlerinden bahsedilmiştir. Daha sonra MBA'ya yol açan faktörler ve EMK işlerine ait risk seviyelerinin belirlenmesi için literatürde yapılmış olan çalışmalar incelenmiştir. Marras vd. 1993 yılında, MBA'ya yol açan faktörleri farklı endüstri kollarında incelemiş, iş ile ilgili değişkenleri ve gövde hareket değişkenlerini belirlemişlerdir [Marras vd., 1993].

Marras vd.'nin toplamış olduğu verilerin girdi değişkenleri şunlardır: kaldırma sıklığı (sıklık/saat) ve sagittal eksenindeki maksimum moment (Nm) iş ile ilgili değişkenleri; gövdenin maksimum kaldırma sırasında bükülme hızı (derece/saniye), yana eğilme

sırasında gövde ile sagital eksen arasındaki açının en yüksek değeri (derece) ve öne doğru eğilme sırasında gövdenin maksimum hızı (derece/saniye) ise vücut hareket değişkenleridir. Farklı endüstri kollarındaki işler (235 EMK işi), yaralanma ve medikal kayıtlar dikkate alınarak iki kategoriye ayrılmıştır. 3 yıllık zaman zarfı boyunca medikal rahatsızlık yaşanmamış ise işi, MBA düşük riskli iş, EMK işlerinden 200,000 saatte en az 12 medikal rahatsızlık yaşanmış ise MBA yüksek riskli iş olarak gruplandırılmıştır [Marras vd., 1993].

Üçüncü bölümde MBA riskini sınıflandırmak için kullanılacak olan DVM'den bahsedilmiştir. Vapnik tarafından geliştirilen DVM, istatistiksel öğrenme teorisi alanında ortaya çıkmış bir öğrenme metodudur [Burges, 1998]. DVM ikili sınıflandırma problemlerinin çözümünde kullanılır. DVM ile sınıflandırmada, veri ile sınıflandırma için gerekli fonksiyon belirlenmekte ve veri sınıflara ayrılmaktadır. DVM'de amaç, veriyi sınıflandıracak optimal ayırıcı hiperdüzlemin bulunmasıdır [Abe, 2005]. İlk olarak verinin girdi uzayında doğrusal olarak ayrılabilirdiği doğrusal ayrılabilen DVM'den, daha sonra verinin doğrusal olarak ayrılamadığı doğrusal ayrılamayan DVM'den ve veri doğrusal olmadığı için veriyi girdi uzayının yüksek boyutlu özellik uzayına dönüştürüldükten sonra, özellik uzayında doğrusal olarak ayrılabilirdiği doğrusal olmayan DVM'den bahsedilmiştir.

Dördüncü bölümde, MBA riski DVM ile sınıflandırılmıştır. İlk önce DVM kernelleri için optimal parametre tespiti yapılmıştır. Daha sonra MBA-DVM modelleri için model performansları karşılaştırılmıştır. Farklı parametre kombinasyonları altında en iyi performansa sahip MBA-DVM modeli seçilmiş ve literatürdeki yapılan çalışmalarla karşılaştırılmıştır.

2. MESLEKİ BEL AĞRISI

2.1. Mesleki Bel Ağrısı

Ekonomik kalkınma ve üretim faaliyetleri, operasyonların otomatik olarak makineler tarafından gerçekleştirilmesine imkan sağlamıştır. Ancak yine de günlük hayattaki birçok iş ve faaliyet, EMK işlerini yapmamızı gerektirmektedir. EMK, itme çekme, tutma ve taşıma, kaldırma gibi elle yapılan aktivitelerden oluşmaktadır. EMK, yazma, birleştirme, temizleme, sıralama, el araçlarını kullanma, makine ve teçhizat kullanma, paketleme gibi tekrar eden görevleri de içerir [Code of practice, 2000; Jung ve Jung, 2010; Lavender vd., 2006].

Endüstride çoğu iş EMK işlerinden oluştuğu için, çalışanlar bu tür işlerden dolayı risk altındadırlar. Yapılan çalışmalar, EMK işlerinden kaynaklanan sorunların yüksek maliyetlere yol açtığını ve çok sık rastlandığını göstermektedir [Jung ve Jung, 2010]. Bu çalışmalar, EMK işlerinin kas-iskelet sistemi bozukluklarına yol açtığını ispatlamaktadır. EMK işlerinden kaynaklanan risk faktörleri üzerinde birçok çalışma yapılmıştır [Code of practice, 2000; Jung ve Jung, 2010; Lavender vd., 2006].

EMK işleri gelişen teknolojiye rağmen günlük çalışma hayatının bir parçasıdır. Bazı sektörlerde EMK işleri hala vazgeçilmezdir. Makineleşme EMK işlerinin azaltamamış, tam tersine bazı sektörlerde artırmıştır. Dağıtım sektöründe yapılan bir çalışmada, EMK işlerinin bir vardiyanın ortalama %74'ünde yapıldığı, bir vardiyada bir çalışanın ortalama 200 EMK işi yapmakta olduğu ve toplamda ortalama 2000 kg ağırlık kaldırdığı tespit edilmiştir. Amerika'da perakende sektöründe 31.000'den fazla depo çalışanı üzerinde yapılan epidemiyolojik çalışmalar, EMK işlerinin MBA'yı artırdığını kanıtlamıştır [St-Vincent vd., 2005; Marras vd., 2010].

MBA son derece yaygındır. Aşağıdaki istatistikler MBA'nın yaygınlığı ile ilgili bilgiler içermektedir. Bu detaylar bize MBA'nın önemini anlamada yardımcı olmaktadır [Marras, 2008].

- MBA her yıl 100 milyon iş günü kaybına yol açmaktadır.
- MBA rahatsızlığı yaşayanların sağlık harcamaları, sağlıklı insanlara göre %60 fazladır.
- MBA raporu alan çalışanların %21'i, 4-5 gün, %14,3'ü 6-10 gün, %29,6'sı 3 ve daha fazla hafta işten uzak kalmıştır.
- MBA rahatsızlıklarının endüstriye getirdiği yıllık direkt ve dolaylı maliyetlerin toplamı Birleşik Krallık'ta 10 milyar dolara ve ABD'de 50 milyar dolara ulaşmıştır.
- Ülkemizde hekim, hemşire ve sağlık teknisyenlerinden oluşan bir grupta yapılan çalışmada, araştırmaya katılanların %73,8'inin yaşamlarının herhangi bir döneminde bel ağrısı rahatsızlığı yaşadıkları kaydedilmiştir [Saygun, 2012].

ABD'de her yıl ortalama 650.000 iş gören fiziksel strese neden olacak işleri, sürekli tekrarlayarak yapmaktan kaynaklanan ciddi sakatlanmalara ve hastalıklara maruz kalmaktadır. Bu tür sakatlanmalar ABD endüstrisinde, yıllık 15 ile 20 milyar dolarlık bir zarara yol açmaktadır. MBA rahatsızlığı en çok 30-45 yaş aralığındaki çalışanları etkilemektedir. Son yirmi yılda Amerika'da çalışanların bel ağrısı sonucu geçirdikleri cerrahi operasyonlar önemli ölçüde artmıştır [Karwowski ve Marras, 2003].

MBA hakkında yapılan çalışmalara rağmen hala tanımı, sınıflandırılması ve tanısı konularında metodolojik sorunlar bulunmaktadır. MBA konusunda objektif bulgular ve çalışanlarla ilgili veriler eksiktir. MBA, insanları bazı dönemlerde etkilemektedir. Bu yaygın bir şekilde çalışma yapılmasını zorlaştırmıştır. Bu zorluklara rağmen yapılan çalışmalar ise yasal ve sosyo-ekonomik faktörlerden etkilenip eksik kalmıştır. İnsanların çalışma ortamında maruz kaldıkları etkilerin araştırılması üzerine yapılan metodolojik çalışmaların etiyolojik önemi vardır [Marras, 1998; Karwowski ve Marras, 2003].

Genel olarak, MBA hakkında bilgi resmi sağlık kayıtlarından ya da nüfusun bazı kesimlerini içeren geçmişe dönük anketlerden elde edilebilir. Bu tür veriler sorunun

büyükliğini belirlemede yararlıdır. Bu veriler yorumlanırken dikkatli olunmalıdır; çünkü yukarıda belirtildiği gibi verinin sınıflandırılması ve tanısı üzerinde hiçbir fikir birliği yoktur ve bu sigorta ve hastane kayıtlarına güvenilmesini zorlaştırmaktadır. Tazminat talebinde bulunan çalışanlardan da veri toplanması uygun değildir; çünkü çalışanların tamamı bu çalışmaya katılmayabilmekte, veriler tam olarak kesinlik taşımamakta ve MBA rahatsızlığı için her çalışanın dosyası bulunmamaktadır [Karwowski ve Marras, 2003].


İş yeri ortamında bel ağrısı riskinin kontrolü için, risk faktörlerinin doğru bir şekilde tanımlanarak elimine edilmesi gerekir. Risklerin anlaşılması için tüm fiziksel ve fiziksel olmayan faktörlerin doğru bir şekilde tespit edilmesi ve birbirleriyle olan etkileşimlerinin araştırılması gerekir. Kontrol, risk faktörlerinin azami maruz kalma sınırını anlamakla mümkündür [Marras, 2008].

Çeşitli epidemiyolojik çalışmalar sonucu belirli bireysel risk faktörleri tanımlanmış ve bu faktörlerin çalışma hayatında MBA riskini artırdığı kanıtlanmıştır [Marras, 2008].

2.2. Mesleki Risk Faktörleri

Mesleki faktörlerle MBA arasındaki ilişkiyi belirlemek çoğu zaman zor ve bazen imkânsız olabilmektedir. Bunun nedeni risk faktörlerinin çalışanlar üzerindeki etkisinin ölçülmesinin zorluğudur. Yalnızca meslek gruplarına bakılarak MBA rahatsızlığının ortaya çıkıp çıkmayacağı belirlenmemektedir. Bir meslekte, sağlıklı çalışan kendini rahat hissederken, bel ağrısı çeken çalışan ise bu mesleği bırakıp daha az güç gerektiren bir işe geçebilir. Sonuçta ağır işten daha hafif çalışma koşullu işe kayma olmaktadır. Başka bir problem ise ağır ve hafif işin ne olduğu konusundadır. Ağır fiziksel işin yüksek enerji gerektiren iş, hafif işin ise daha az fiziksel enerji gerektiren iş olduğu şeklinde bir kanı vardır. Çoğu az enerji gerektiren işler statik işlerdir ve bu işlerde MBA için risk faktörü olabilmektedir [Karwowski ve Marras, 2003].

Yapılan arařtırmalarda, MBA'ya yol açtıęı tespit edilmiř en sık rastlanan faktörler Şekil 2.1'de gösterilmiřtir. Ağır fiziksel işler, statik çalışma duruşu, tekrarlı bükme ve döndürme hareketleri, titreřim, tekrarlı işler, kaldırma itme ve çekme fiziksel risk faktörü olup omurilik doku incinmeleriyle ilgilidir. Diğer bir faktör ise psikolojik ve psikososyal çalışma faktörüdür [Karwowski ve Marras, 2003]. MBA'ya yol açan risk faktörleri bu bölümde kısaca açıklanamıřtır.



Şekil 2.1. MBA'ya yol açan faktörler

2.2.1. Ağır fiziksel işler

Yapılan arařtırmalarda fiziksel olarak çalışma şartları aęırlařtıķça MBA rahatsızlıęının arttıęı gözlemlenmiřtir. Bu çalışmaların bazılarında bu bölümde bahsedilecektir. Magora, yapılan iş ile bel ağrısı arasında kuvvetli ilişki olduęunu tespit etmiřtir [Magora, 1970]. Uyttendaele vd. üniversite ve hastane çalışanlarında araştırma yapmıřlar ve fiziksel stres gerektiren işlerin MBA ile kuvvetli ilişkisi olduęu tespit etmiřlerdir [Uyttendaele vd., 1981]. Svensson ve Andersson ağır

fiziksel işler ile MBA arasında kuvvetli ilişki olduğu sonucuna ulaşmışlardır. Ayrıca genellikle erkeklerde ağır fiziksel işlerin, kadınlarda ise psikolojik faktörlerin (iş tatminsizliği, yorgunluk, kaygı vs.) etkili olduğu çalışmanın sonucunda ortaya çıkmıştır [Svensson ve Andersson, 1983].

Behrens yaptığı çalışmada, ağır sanayide ve ağır fiziksel işlerde çalışanlarda yüksek oranda bel kaslarında gerilme/gerginlik tespit etmiştir [Behrens, 1994]. Lloyd yaptığı çalışmada ise madende çalışanlarda ofis çalışanlarına göre (yaşam boyu ve üç aylık periyotta) bel ağrısı görülme sıklığının fazla olduğunu gözlemlemiştir [Lloyd, 1986]. Herrin, KİSR'i 6900 çalışan ve 55 iş kolunda, 3000 farklı EMK işi için analiz etmiştir. EMK işleri sonucu ortaya çıkan stresler medikal verilerden toplanmış ve lumbosakral disk üzerine binen sıkıştırma kuvveti 6800 N'u aştığında, kas iskelet sistemi problemlerinin 2 kat arttığı gözlemlenmiştir. Ağır fiziksel performans gerektiren işlerde sırt ağrısı problemlerinin normal çalışanlara göre 2,5 kat fazla olduğu tespit edilmiştir [Herrin, 1986].

2.2.2. Statik çalışma duruşu

Çalışanların bir pozisyonda sürekli durması, uzun süreli oturma gibi, MBA riskini artırmaktadır. Kelsey ve Hardy yaptıkları çalışmada erkek çalışanların çalışma süresinin yarısını araba içerisinde geçirdiğinde disk fıtığı riskinin üç kat arttığını tespit etmişlerdir. Bu sonucun ortaya çıkması araba içerisinde oturmadan ve araçtan kaynaklanan titreşimden de meydana geldiğinden bu birleşik bir faktör olarak da nitelendirilebilir. Ayrıca çalışanların gün boyu süreyi oturarak veya ayakta durarak geçirmeleri sonucu MBA riskinin arttığı tespit edilmiştir [Kelsey ve Hardy, 1975].

2.2.3. Tekrarlı bükme ve döndürme hareketi

Bel ağrısı semptomlarıyla tekrarlı bükme ve döndürme işlerini birbirinden ayırmak zordur; çünkü bu iş içerisinde kaldırma hareketi de olmaktadır. Yapılan birçok çalışma bu gibi hareketlerin bel ağrısıyla bağlantılı olduğuna değinmektedir. Magora, bükme ve döndürme hareketi üzerine çalışma yapmış ve MBA ile EMK işleri

arasında bağlantı kurmuştur [Magora, 1973]. Keyserling vd. otomobil montaj hattında yaptıkları çalışmada asimetrik duruş ile bel ağrısının bağlantılı olduğu sonucuna ulaşmışlardır [Keyserling vd., 1988]. Riihimaki, tekrarlı bükme ve döndürme hareketleri ve duruş pozisyonunun MBA'ya yol açtığını ağır fiziksel işlerde çalışanlarda ve ofis çalışanlarında gözlemlemiştir [Riihimaki, 1989].

2.2.4. Kaldırma, itme ve çekme

Yapılan çalışmalarda açıkça görülmüştür ki bel ağrısını kaldırma hareketi tetiklemektedir. Kaldırma sıklığı ise birçok çalışmada bel ağrısının başlıca sebebidir. Ani ve beklenmedik bir zamanda yüksek enerji gerektiren bir iş yapılmasının kaslara ve eklemlere zararlı etkilerinin olduğu birçok çalışmada gözlemlenmiştir. Ağır kaldırma işlerinde çalışanların normal işlerde çalışanlara göre sekiz kat daha fazla bel sakatlanmalarına maruz kaldığı tespit edilmiştir. Amerikan Ulusal Mesleki Güvenlik ve Sağlık Enstitüsü (NIOSH, National Institute of Occupational Safety and Health) 1981'de her üç çalışandan birisinin makul dereceden fazla yük kaldırdığını ve bu kaldırma faaliyetlerinin bel ağrısının ana sebebi olduğunu belirtmektedir. NIOSH, sakatlanma şiddetinin objenin ağırlığına, hacmine, taşıma mesafesine ve kaldırma sıklığına bağlı olduğu sonucunu belirtmektedir. Tekrarlı kaldırma işlerinin MBA'ya ve HNP'ye yol açtığı bir çok çalışmada açıkça ortaya konmuştur. Sonuçta risk, ağır kaldırma işlerinde ve tekrarlı faaliyetlerde artmakta ve bu faaliyetlere döndürme hareketleri de eklendiğinde ise risk daha da artmaktadır [Karwowski ve Marras, 2003].

2.2.5. Tekrarlı işler

Genellikle tekrarlı işler arttıkça MBA rahatsızlığı da artmaktadır. Yapılan araştırmalarda montaj hattında çalışanların, tekrarlı işlerden dolayı, ofiste çalışanlara göre daha yüksek oranda bel ağrısına yakalandıkları ortaya çıkmıştır. Çalışma süresinin bel ağrısı ile bağlantılı olabileceği tartışılmış fakat sağlıklı çalışanlarda bunun tespitinin zor olduğu görülmüştür. Gıda ve kâğıt endüstrisinde 391 erkek

alışan zerindeki arařtırmada, bel ağrısı ile alışma süresi arasında doğrudan bir ilişki olduğunu tespit edilmiştir [Karwowski ve Marras, 2003].

2.2.6. Titreřim

Kelsey ve Hardy MBA riskinin belirlenmesi için farklı araçları kullanan sürücüler üzerinde alışmalar yapmışlardır. Bu alışmalarda titreřimin kamyon sürücülerinde disk fıtığı riskini 4 kat, traktör sürücülerinde ve araba ile seyahat edenlerde (günde 33 km ve fazlası) 2 kat arttığı sonucuna ulařılmıştır [Kelsey ve Hardy, 1975]. Daha sonraki alışmalarda ise HNP riskinin aracın tipiyle ilgili olduğu ve araç modelleri farklılařtıka risk seviyesinin de farklılařtığı görölmüřtür [Kelsey vd., 1984]. Bel ağrısı ve vücut titreřimi arasındaki ilişkiyi arařtırmak için helikopter pilotları, traktör sürücülerini, yapı makineleri operatörleri ve ulařtırma alışanları arasında arařtırma yapılmış, titreřimin MBA için olası bir risk olduğu sonucuna ulařılmıştır. Titreřim üzerinde yapılan diğeri arařtırmalarda řu istatistiki sonuçlara ulařılmıştır: 10 yıllık periyotta (1961-1971) traktör sürücülerinin sırt ağrısı %47-58 oranında artmıştır; 352 yapı makinesi operatörünün %70'inin MBA'ya yakalandığını tespit edilmiştir [Karwowski ve Marras, 2003].

2.2.7. Psikolojik ve psikososyal alışma faktörleri

Üzerinde arařtırma yapılan ve MBA'ya yol açan diğeri bir etken de psikolojik ve psikososyal alışma faktörleridir. Monotonluk, iş tatminsizliği, alışanlarla düşük iletişim düzeyi gibi birçok psikososyal alışma faktörünün bel ağrısından kaynaklanan řikâyetleri ve maliyetleri artırdığı çoğı arařtırmada ortaya konulmuřtur. Monotonluk bel ağrısı ile doğrudan ilişkilidir; çünkü daha az konsantrasyon gerektiren monoton işlerde alışanların, diğeri alışanlara göre daha uzun süre bel ağrısı rahatsızlığı geçirdiğı kaydedilmiştir. Azalan iş tatminsizliğinin MBA riskini artırdığı ve ağır fiziksel koşullarda alışan orta yařtaki kişilerin iş tatminsizliğinin, MBA riskinin ortaya ıkması ile bağlantılı olduğu birçok alışmada ifade edilmiştir [Westrin, 1970; Magora, 1973; Svensson vd., 1983; Bergenudd ve Nilsson, 1988]. Gelecekte psikolojik faktörlerin, bel ağrısı risk göstergeleri olarak fiziksel iş

faktörlerinden daha önemli olacağı sonucu yapılan araştırmalarda öngörülmüştür [Bigos vd., 1986].

2.3. Literatür Taraması

EMK işleri son 40 yılda ergonomi, biyomekanik ve ilgili diğer bilim alanlarının en önemli konulardan biri olmuştur. Bunun nedeni ise elle malzeme taşıma ve kaldırma işlerinin çalışanlarda görülen sırt, bel ağrıları ve sakatlanmalarının en başta gelen sebebi olmasıdır [Chung ve Dohyung, 2000].

EMK, hem dolaşım sisteminde hem de kas-iskelet sisteminde zorlanma oluşturur. Dolaşım sisteminde yer alan zorlanma, ilgili kaslara daha çok oksijen ve kimyasal enerji gönderebilmek ve atık maddeleri (karbondioksit ve su) vücuttan atmak için artan oksijen tüketimi ve kalp atışı sebebiyle oluşur. Böyle bir sorun genelde kritik değildir ve dinlenmeyle giderilebilir. Buna karşılık kas-iskelet sisteminde oluşacak bir gerginlik ki bu inciticidir, daha ciddi bir sorundur. En travmatik EMK yaralanmaları sırt ve bele etkiyen, özellikle L5/S1 (Lumbar 5/Sakral 1) bölgesinde olan incinmelerden kaynaklanmaktadır ki birçok çalışmada en çok söz konusu olan bu bölgedir [Tayyari ve Smith, 1997].

Literatürde EMK işlerinin tasarımı, EMK işleri için maksimum kaldırma limit değerlerinin tespiti ve EMK işlerine ait tehlike risklerinin derecelendirilmesi ile ilgili analiz yöntemleri ve bunların uygulamalarıyla ilgili yapılmış çalışmalar aşağıda verilmiştir.

Ayoub vd., EMK işlerinde iş talepleri ile çalışanın kapasitesi arasındaki ilişkinin matematiksel modelini kurarak bel rahatsızlıklarına karşı işlerin riskini tespit edecek JSI (İş Tehlike İndeksi) yöntemini geliştirmişlerdir. JSI değerinin 0 ile 1.5 arasında çıkması durumunda işleri tehlikesiz, 1.5’den büyük çıkması durumunda tehlikeli olarak sınıflandırmışlardır [Ayoub vd., 1978].

Jiang vd., 12 öğrenci üzerinde yaptıkları araştırma sonucunda yerden diz yüksekliğine (YDY) kaldırma, dizden omuz yüksekliğine (DOY) kaldırma, diz yüksekliğinden yere bırakma (DYB) ve bu aktivitelerin kombinasyonu YDT+Taşıma (T), YDY+T+DOY, YDY+T+DYB işler için kaldırma limitlerini 3 farklı kaldırma sıklığı (dakikada 1, dakikada 6, vardiya boyunca 1 kez olmak üzere) için belirlemiştir. Limit değerlerin bulunmasında kişisel kaldırma kapasitesi, dinamik güç ölçümü ve bulanık küme teorisinden faydalanarak üç farklı model geliştirilmiştir. Bu üç farklı modele göre farklı kaldırma sıklığı ve yükseklik parametre değerlerine göre EMK işlerinin kombinasyonunu gerektiren işler için maksimum yük limit değerlerini tespit etmişlerdir [Jiang vd., 1986].

Karwowski ve Mital, bulanık küme teorisinden faydalanarak kaldırma işlerinin tehlikesinin ölçülmesinde biomekanik ve fizyolojik streslerin bütünleşik etkisini dikkate alacak İş Güvenlik İndeksi (Job safety index, JSI) geliştirmişlerdir [Karwowski ve Mital, 1986].

Karwowski vd., EMK işlerinin değerlendirilmesi için LIFTAN adlı bir uzman sistem geliştirmişlerdir. LISP (programlama dili) ile geliştirdikleri LIFTAN, 159 tane temel kuraldan oluşmuştur. Geliştirilen uzman sistem sayesinde, EMK riskinin ölçülmesi için ekipman kullanımının mümkün olmaması veya çok maliyetli olması, EMK işlerinin risklerini belirleyecek uzman sayısının az olması veya bu uzmanların aynı işin risk seviyesi hakkında farklı düşüncelere sahip olması gibi dezavantajları ortadan kaldırmışlardır [Karwowski vd., 1986].

Luczak ve Shuangsheng, bulanık küme teorisinden faydalanarak EMK işlerinde kaldırılan ağırlık ile göreceli hissedilen ağırlık arasındaki ilişkiyi incelemiştir. Gerçek ağırlık az olmasına rağmen, kaldırılan cismin boyutları büyük ise, hissedilen ağırlığın gerçek ağırlıktan çok daha fazla olduğu sonucuna ulaşmışlardır [Luczak ve Shuangsheng, 1989].

Snook ve Vincent, oksijen tüketimi, kalp atım hızı, antropometrik karakteristikler ve cinsiyeti dikkate alarak laboratuvar ortamında kaldırma, indirme, itme, çekme,

taşıma ve bunların kombinasyonunu içeren işler için farklı kaldırma sıklıkları (her 5, 9, 14 saniyede bir, her 1, 2, 5, 30 dakikada bir ve her 8 saatte bir kaldırma), farklı yükseklik seviyeleri (yerden diz yüksekliğine, diz yüksekliğinden omuza, omuzda elin omuz üstünde ulaşabildiği en üst noktaya kaldırma veya indirme), farklı cisim genişlikleri (34, 49, 75 cm için), farklı popülasyon (% 10, 25, 50, 75, 90) dilimleri için, farklı itme ve çekme mesafeleri (2,1, 7,6, 15,2, 30,5, 45,7, 61 metre için) ve farklı taşıma mesafeleri (2,1, 4,3 ve 8,5 metre için) gibi parametreler altında maksimum kaldıracabilecek ağırlık limitlerini belirlemiş ve bu limit değerlerini Snook Tabloları adı altında sunmuşlardır [Snook ve Vincent, 1991].

Jung ve Freivalds, literatürde EMK riskini tespit etmek üzere geliştirilmiş 3 yöntemden (ILO limitleri, Snook tabloları ve JSI) farklı iş parametreleri altında hangi yöntemin önerdiği limitin baz alınması gerektiği konusunda karar vermek için geliştirdikleri modelde AHP ve uzman sistemlerden faydalanmışlardır [Jung ve Freivalds, 1991].

McCauley ve Badiru, çalışanın kişisel karakteristiği, iş yeri şartlarını ve çevresel faktörleri girdi değişkeni olarak EMK işlerinin riskini belirlemek üzere bir uzman sistem geliştirmişlerdir. Girdi değişkenlerini bulanık dilsel değişkenlerden faydalanarak oluşturmuşlardır [McCauley ve Badiru, 1992].

Huang vd., kaydedilen çalışma duruşlarını görüntü işleme yöntemi ile analiz etmişlerdir. Bu görüntü analizi ve kaldırılan yükün ağırlığı verisini kullanarak L5/S1 diskindeki baskı kuvveti değerini bularak, bu değeri literatürde önerilen limit değeri ile karşılaştırmışlar ve bel incinmelerine karşı duruşların risklerini belirleyen bir model geliştirmişlerdir [Huang vd., 1996].

Waters vd., biyomekanik, fizyolojik ve psikofiziksel 3 kriteri dikkate alan NIOSH kaldırma denklemini geliştirmişlerdir. Bu yöntem günümüzde kullanılabilirliği ve geçerliliği en yüksek olan metotlardan biridir [Waters vd., 1994]. Patvin, NIOSH kaldırma eşitliğindeki H ve V değerlerinden faydalanarak simetrik kaldırma işlerinde L5/S1 diskindeki baskı kuvvetinin bulunmasına yönelik bir regresyon modeli

geliştirmiştir [Patvin, 1997]. Jager ve Luttmann, Revize edilmiş NIOSH kaldırma metodunda belirlenmiş olan 3,4 kN'luk L5/S1 bölgesindeki baskı kuvveti limit değerinin epidemiyolojik ve biomekanik kriterleri tam olarak sağlamadığını göstermişlerdir. 3,4 kN'luk limit değerinin çalışanın kişisel özelliklerine bağlı olarak düzenlenmesi durumunda büyük oranda olası risklerin daha doğru tahmin edeceğini belirtmişlerdir [Jager ve Luttmann, 1999]. Ciriello ve Snook, Revize edilmiş NIOSH denklemini kullanarak ABD'deki 2442 endüstriyel işletmedeki EMK işinin analizini yapmışlardır. İşlere ait medyan değerler kullanılarak hesaplanan LI değerini kaldırma işleri için 1,9, indirme işleri için ise 1,8 olarak bulmuşlardır. Çalışmalarında teknolojinin gelişmesine rağmen günümüzde hala EMK işlerinin önemli bir sorun olduğunu ve bu konuda acil olarak ergonomik düzenlemelere gidilmesi gerektiğini vurgulamışlardır [Ciriello ve Snook, 1999]. Mital ve Ramakrishan, demiryolu endüstrisinde yapmış oldukları çalışmada NIOSH, Revize NIOSH ve Mital tarafından geliştirilen 3 yöntemi kullanarak çok-işli EMK işlerini ergonomik açıdan incelemişlerdir. Çalışmalarının sonuçlarında, NIOSH ve Revize NIOSH yöntemlerinin çok işli EMK işlerinde, Mital tarafından geliştirilen yöntemle göre daha düşük kaldırma limitleri önerdiğini ortaya çıkarmışlardır [Mital ve Ramakrishan, 1999].

Chung ve Dohyoung, tuğla üreten bir fabrikada EMK işlerinin analizinde Revize Edilmiş NIOSH kaldırma denklemini kullanmışlardır. Her bir iş için LI değerinin 1,0 aşması durumunda ergonomik öneriler getirilmiş ve iş istasyonları LI değeri 1,0 altında olacak şekilde yeniden tasarlanmıştır [Chung ve Dohyoung, 2000]. Temple ve Adams, montaj hattının sonundan alınan parçaların paketlenmesi sırasındaki çok-işli EMK işlerini Revize Edilmiş NIOSH kaldırma denklemiyle analiz etmişler ve Kompozit Kaldırma İndeksi (CLI) değerinin düşürülmesine yönelik öneriler sunmuşlardır [Temple ve Adams, 2000].

Genaidy vd., çalışmalarında 22 uzman ile 22 kalifiye, yetenekli çalışana, farklı EMK işlerini, farklı iş parametreleri altında risklerini 1-7 arasındaki bir skalaya göre değerlendirtmişlerdir. Verilen sonuçlar doğrultusunda kurulan lojistik regresyon modeli ile her iki grubun verdiği sonuçlar arasında anlamlı farklılık olmadığı

sonucuna ulaşmışlardır. Böylece işyerinde uzman kişilerinin olmaması durumunda kalifiye çalışanların da riskleri doğru olarak tahmin edebileceklerini ispatlamışlardır [Genaidy vd., 1999/2000].

Carnahan vd. 1998 ve 2000 yıllarında, EMK işi yapılan iş istasyonlarındaki yaralanma, kazalar ve incinmeleri önlemenin bir yolu olan iş rotasyonunu kullanarak, iş güvenliği kriterlerini (bel rahatsızlıklarının önüne geçilmesi) sağlayacak iş rotasyonu çizelgeleri oluşturma yöntemleri üzerinde çalışmışlardır. İş rotasyonu çizelgesinin tamsayılı programla modelinin amaç fonksiyonunda JSI indeksi kullanılmıştır. Modelin çözümünde ise genetik algorithmadan faydalanarak alternatif ergonomik iş çizelgeleri oluşturmuşlardır. Ayrıca modelin verimlilik, çalışma saatleri gibi kısıtlar eklenerek genişletilebileceğine değinilmiştir [Carnahan vd., 1998, 2000].

Neuman vd., EMK işleri yapılırken çalışma duruşlarının gözlemlenmesi ve sonucunda bel rahatsızlıklarına yol açabilecek kötü duruşların tespitine yönelik bir araştırma yapmışlardır. Endüstride 104 işçi üzerinde yapılan çalışmada uygun olmayan çalışma duruşları tespit edilmiş ve uygun olmayan çalışma duruşlarının ortadan kaldırılması ile çalışan şikâyetleri, spinal baskı kuvvetleri, maksimum fleksiyon değerlerinde eski çalışma şekline göre önemli ölçüde azalma sağlandığı gözlemlenmiştir [Neuman vd., 2001].

Schaefer vd., itme ve çekme işlerinde riskin belirlenmesine yönelik bir çalışma yapmışlardır. EMK işleri yapan kişilerin özellikleri (yaş, cinsiyet ve boy), iş gereksinimleri (çalışma yüksekliği, iş yapılma sıklığı ve hareket mesafesi) ile ISO (2004) ve CEN (2004) standartları dikkate alınarak, limitlerin itme ve çekme işlerinde çalışanlara göre belirlenmesinin uygun olacağı sonucuna varılmıştır. Sonuçta, limitlerin kişilere adapte edilebildiğini ve daha güvenilir koruma seviyesi sağladığı belirtilmiştir [Schaefer vd., 2007].

Jung ve Jung, elle kaldırma işlerinde kullanılan farklı boyutlardaki ve farklı tutma pozisyonlarındaki kutular için optimum kavrama pozisyonunu bulmak için bir deney yapmışlardır. Bu deney çalışmasına 20 öğrenci katılmıştır ve elle kaldırma durumuna

göre tutma ve taşıma pozisyonunun değişmesi gerektiği sonucuna ulaşmışlardır [Jung ve Jung, 2010].

Waters ve Garg, genç nüfus üzerinde (3-21 yaş) yaptıkları araştırmada, EMK işleri yapılırken gereken güç tahmini için iki boyutlu bir biomekanik model geliştirmişlerdir. Modelin girdi parametreleri: yaş, cinsiyet, EMK işi sırasındaki duruş ve kaldırılan cismin ağırlığı ve çıktıları ise işin yapılabilmesi için gerekli tahmini güç ve omuriliğine binen yük/kuvvet değeridir [Waters ve Garg, 2010].

Marras vd., farklı endüstrilerde 235 tane EMK işi seçmiş ve bu işler için literatürde bel rahatsızlığına yol açtığı düşünülen 5 faktörü tanımlamışlardır. Bu faktörler, kaldırma sıklığı (sıklık/saat), gövdenin maksimum kaldırma sırasında bükülme hızı (derece/saniye), sagittal eksenindeki maksimum moment (Nm), yana eğilme sırasında gövde ile sagittal eksen arasındaki açının en yüksek değeri (derece), öne doğru eğilme sırasında gövdenin maksimum hızıdır (derece/saniye). Bu 235 işe ait 3 yıllık sürede bel rahatsızlığı ile ilgili yaralanmalar ve medikal kayıtlar dikkate alınmıştır. Bu zaman zarfı boyunca EMK'den kaynaklanan bir medikal rahatsızlık yaşanmamış ise işi MBA riski düşük riskli iş, en az 12 medikal rahatsızlık yaşanmış ise işi MBA riski yüksek riskli iş olarak sınıflandırmışlardır [Marras vd., 1993]. Zurada vd., Marras vd. tarafından yapılan çalışmadaki veriyi kullanarak MBA riskini belirlemede yapay sinir ağlarından faydalanmışlardır. Bu 235 işe ait 5 faktörün değerini girdi değişkeni ve işin tehlike seviyesini (yüksek, düşük) çıktı değişkeni alan fonksiyonu bulmaya çalışmışlardır. Böylece bulunan fonksiyon sayesinde 5 girdi değişkeninin değeri bilindiğinde işleri EMK riskine göre sınıflandırmak mümkün olmuştur. Yapılan çalışma sonucunda doğru sınıflandırma yüzdesi (DSY) %74,7 olarak bulunmuştur [Zurada vd., 1997]. Marras vd., Marras vd. tarafından yapılan çalışmadan hareketle MBA riskinin belirlenmesinin pratik sonuçlarını görmek için bir saha çalışması yapmışlardır. 16 farklı işyerinde, 36 farklı EMK işi seçilmiş ve ergonomik düzenleme öncesi ve sonrası işlerin tehlike seviyelerini, kurdukları regresyon modeli ile hesaplamışlardır. Yapılan çalışma, 32 işte doğru sonuç vermiş ve riskin azaldığı görülmüştür [Marras vd., 2000].

Chen-Luang vd., Marras vd. tarafından yapılan çalışmadan hareketle bir yapay sinir ağı modeli kurmuşlardır. Bu modelde tavlama benzetimi ve eşlenik gradyan yaklaşımını yapay sinir ağlarının eğitiminde kullanmışlardır. Marras vd.'nin yaptıkları çalışmaya göre daha iyi sonuç elde etmişlerdir. DSY %79,3 olarak bulunmuştur [Chen-Luang vd., 2000]. Chen-Luang, Kaber ve Dempsey aynı veriyi kullanarak yeni bir yapay sinir ağı (ileri seçim tabanlı) modeli kurmuşlar ve yapmış oldukları önceki çalışmalarını geliştirmişlerdir. Bu çalışma ile Zurada vd.'nin 1997 yılındaki çalışmasına benzer sınıflandırma yüzdesine ulaşmışlardır [Chen-Luang vd., 2004].

Zurada vd., Marras vd. tarafından literatüre kazandırılmış olan araştırmadaki eğitim ve test kümesini kullanmamış, veriyi katmanlı örneklem ile düşük ve yüksek MBA risk oranını (sırasıyla %47,2 ve %52,8) dikkate alarak eğitim (%40), geçerlilik (%30) ve test (%30) kümesi rassal olarak üçe ayırmıştır. Verinin kümelerle ayrılması gözlem sayısını azalttığından bilgi kaybının oluşmaması, ekstra gözlemin yeni bir değişkenliğe yol açmaması ve sonuçların güvenilirliği için 10'lu çapraz geçerlilik testi uygulanmıştır. 10'lu çapraz geçerlilik ile 10 farklı rassal oluşturulmuş eğitim, geçerlilik ve test kümesi için elde edilen sonuçların ortalaması alınmıştır. Zurada vd. MBA'ya yol açan riskleri veri madenciliği teknikleri ile sınıflandırmışlardır. Bu teknikler yapay sinir ağları, lojistik regresyon, karar ağaçları, olay temelli çıkarım ve topluluk modelidir. Bu modellerin MBA riskini sınıflandırma yüzdeleri sırasıyla ortalama %73,9, %70,6, %73,0, %75,6 ve %74,3 bulunmuştur [Zurada vd., 2004].

Akay vd., MBA riskinin sınıflandırılması konusunda benzer bir çalışma yapmışlar; Marras vd.'nin çalışmasındaki veri kullanılarak EMK işi için literatürde bel rahatsızlığına yol açtığı düşünülen 5 faktörün MBA riskini, sinirsel bulanık ağları ile sınıflandırmışlar ve Zurada vd.'nin 1997 yılında yapmış olduğu sonuçtan daha iyi bir sonuç elde etmişlerdir. Zurada vd.'nin kullandıkları benzer eğitim ve test kümesini kullanmışlardır. Test kümesinin DSY'si %78,16 olarak bulunmuştur. Yapılan çalışmada MBA'ya yol açan girdi değişkenler ile çıktı arasında kural çıkarımları yapmışlardır [Akay vd., 2008].

Akay ve Toksarı, MBA riskinin sınıflandırılması alanında karınca kolonisi optimizasyon tekniğini kullanmışlar ve MBA riskini doğru tahmin etmede Zurada vd.'nin 1997 yılındaki ve Chen-Luang vd.'nin 2004 yılındaki çalışmalarından daha iyi sonuç elde etmişlerdir. Zurada vd.'nin kullandığı benzer eğitim ve test kümesini kullanmışlardır. Test kümesinin DSY'si %81,6 olarak bulunmuştur [Akay ve Toksarı, 2009].

Akay, 2011 yılında yapmış olduğu çalışmasında aynı veri kümesini kullanarak gri ilişkisel analiz ile MBA riskini sınıflandırmıştır. Gri ilişkisel analiz örnek temelli öğrenme yaklaşımı olup, farklı örnekler arasındaki benzerlik ve farklılık ilişkisini ölçer. Gri ilişkisel analizle MBA riski %91,95 gibi yüksek bir oranda doğru tahmin edilmiştir. Akay, aynı zamanda, Zurada vd.'nin 2004'te önerdiği yöntem olan katmanlı örneklem ile veriyi eğitim ve test kümelerine ayırmıştır. Verinin kümelere ayrılması gözlem sayısını azalttığından, bilgi kaybının oluşmaması ve sonuçların güvenilirliği için 10'lu çapraz geçerlilik testi kullanılmıştır. Veri eğitim (%70) ve test (%30) kümesine rasgele ayrılırken, yüksek ve düşük MBA risk oranı (sırasıyla %47,2 ve %52,8) dikkate alınmıştır. Akay, gri ilişkisel analizle 10 farklı veri kümesini 10 kez çapraz geçerlilik testine tabi tutarak MBA riskini ortalama %91,7 oranında doğru sınıflandırmıştır [Akay, 2011].

Zurada, Marras vd. verisini kullanarak MBA riskini sınıflandıran literatür çalışmalarını incelemiş, bu çalışmaların sonuçlarıyla ilgili bazı eleştirilerde bulunmuştur. MBA riskini tahmin etmek için kurmuş olduğu modeller lojistik regresyon, sinir ağları, RBF sinir ağları, DVM, en yakın komşu (k-NN) algoritması, karar ağaçları, rasgele ağaçlardır (DSY değerleri sırasıyla ortalama %73,8, %72,6, %71,0, %74,1, %74,2, %71,7 ve %70,3 bulunmuştur). Zurada yaptığı çalışmada, tek bir eğitim ve test kümesi ile model kurulmasının gerçekçi olmadığını vurgulamıştır. 2004 yılında yaptığı çalışmasında veriyi kümelere ayırmada katmanlı örneklem kullanmanın daha doğru olduğunu savunurken, 2012 yılında yapmış olduğu çalışmasında katmanlı örneklem kullanmayarak veriyi rasgele eğitim, geçerlilik ve test kümesine ayırmanın daha anlamlı olacağını öngörmüştür [Zurada, 2012]. MBA riskini sınıflandırmada kullandığı modellerin iyi sonuçlar vermemesindeki

sebeplerden bazıları, verinin eğitim ve test kümelerine ayırmada kullandığı yöntem ve model/modellerin eksik eğitimidir.

3. DESTEK VEKTÖR MAKİNELERİ

Sınıflandırma probleminde objeler kategorilere ayrılarak sınıflandırılır. Her sınıflandırma problemi için değişik algoritmalar geliştirilmiştir ve bu algoritmalar makul düzeyde doğru sınıflama yapmaktadırlar. Sınıflandırıcı, veri kümesindeki elemanları ait oldukları farklı sınıflara doğru şekilde sınıflandırmaktadır. Destek vektör makineleri (DVM) literatürde kullanılan sınıflandırıcılardandır. DVM ile sınıflandırmada veri kümesi ile sınıflandırma için gerekli fonksiyon belirlenmekte ve veri sınıflara ayrılmaktadır [Abe, 2005].

DVM algoritması doğrusal olmayan bir algoritma olup altmışlarda Vapnik, Lerner ve Chervonenkis tarafından ortaya atılmıştır. İstatistiksel öğrenme teorisi veya Vapnik Chervonenkis (VC) teorisi doksanların sonlarına doğru Vapnik ve Chervonenkis tarafından geliştirilmiştir. VC teorisi kısaca öğrenme makinelerinin temeli olup verileri genelleştirmemize olanak sağlamaktadır. Doksanlardaki gelişmelerle DVM endüstriyel alan başta olmak üzere ve her türlü alanda uygulanabilir duruma gelmiştir. İlk çalışmalar optik karakter tanıma üzerine olmuştur. DVM el yazısından karakter tanıma, obje tanıma, ses tanıma, fotoğraftan yüz saptama ve metin kategorileme alanlarına uygulanmıştır [Smola ve Schölkopf, 2003]. DVM'nin diğer sınıflandırıcılarla rekabet edebilir olması DVM'yi popüler kılmış ve üzerine birçok çalışma yapılmıştır. Destek vektör öğrenmesi gelişme gösteren alanlardandır ve değişik metotlar geliştirilmiştir [Smola ve Schölkopf, 2003].

Sınıflandırıcının eğitiminde, eğitim verisi için sınıflandırıcı performansının maksimum olması istenilir. Eğer sınıflandırıcı eğitim verisine fazla uyum göstermekteyse, genelleştirme kabiliyeti düşük olur. Bu durum, aşırı uyum olarak tanımlanmaktadır. Genelleştirme kabiliyeti ile veriye uyum arasında bir denge vardır ve bu dengenin iyi sağlanması gerekir [Abe, 2005]. Yapısal risk minimizasyonu ve VC boyutu ile ilgili bilgi ekte daha detaylı olarak sunulmuştur (EK-1-2).


İki sınıflı bir problemde, bir destek vektör makinesi karar fonksiyonunun genelleştirme kabiliyetini artırmak için kullanılır. Açıklamak gerekirse, m boyutlu

giriş uzayı x , l boyutlu ($l \geq m$) özellik uzayı z 'ye aktarılır veya haritalandırılır. Sonra z 'de, kuadratik programlama problemi ile optimal ayırıcı düzlem tarafından iki sınıfa ayrılır [Abe, 2005].

Bu bölümde iki sınıflı DVM'den bahsedilecektir. İlk olarak verinin girdi uzayında doğrusal olarak ayrılabilirdiği doğrusal ayrılabilen DVM, daha sonra verinin doğrusal olarak ayrılamadığı doğrusal ayrılamayan DVM ve veri doğrusal olmadığı için veriyi girdi uzayının yüksek boyutlu özellik uzayına dönüştürüldükten sonra, özellik uzayında doğrusal olarak ayrılabilirdiği doğrusal olmayan DVM'den bahsedilecektir.

3.1. Doğrusal Ayrılabilen DVM


Doğrusal ayrılabilen DVM'nin matematiksel ifadesinden bahsetmeden önce iki sınıflı verinin nasıl sınıflandırıldığını incelemek daha iyi olacaktır. Şekil 3.1'deki gibi iki sınıflı veri olsun.



Şekil 3.1. İki sınıflı veri [Abe, 2005]

İki sınıflı veri doğrusal olarak Şekil 3.2'deki gibi sınıflandırılır. Şekil 3.2'de solda bir, sağda ise birden fazla ayırıcı ile veri sınıflandırılmıştır. İki sınıflı veriyi doğrusal sınıflandırmak için birden fazla ayırıcı düzlem olduğu aşikârdır. Bunlardan

hangisinin daha iyi olduğunu bulmak yerine bu doğruların dâhil olduğu hiperdüzlemin formülünü bulmak daha kolaydır.



Şekil 3.2. İki sınıflı verinin doğrusal sınıflandırılması [Abe, 2005]

Sınıf 1 veya Sınıf 2'ye ait m boyutlu eğitim verisi x_i ($i = 1, \dots, M$) olsun ve etiketler $y_i = 1$ ise Sınıf 1 ve $y_i = -1$ ise Sınıf 2'yi gösterebilir. Eğer bu veriler doğrusal olarak ayrılabilirse, karar fonksiyonu şu şekildedir [Abe, 2005]:

$$D(x) = w^T x + b \quad (3.1)$$

w , m boyutlu vektör (normal), b bias (yanlılık/eğilim) katsayısı, $i = 1, \dots, M$ için

$$w^T x_i + b \begin{cases} > 0, & y_i = +1 \\ < 0, & y_i = -1 \end{cases} \quad (3.2)$$

Veri doğrusal ayrılabilir olduğundan, hiçbir elemanı $w^T x_i + b = 0$ durumunu sağlamayacaktır. Bu durumda, ayrılabilirliği kontrol etmek için Eş. 3.2 yerine aşağıdaki (Eş. 3.3) eşitsizlik kullanılabilir.

$$w^T x_i + b \begin{cases} \geq +1, & y_i = +1 \\ \leq -1, & y_i = -1 \end{cases} \quad (3.3)$$

Burada, 1 ve -1 olan sağ taraf değerleri $a (> 0)$ ve $-a$ gibi bir sabit de olabilir. Eş. 3.3, Eş 3.4 ile de ifade edilebilir [Abe, 2005]


$$y_i(w^T x_i + b) \geq 1 \quad , \quad i = 1, \dots, M \quad (3.4)$$

Hiperdüzlem


$$D(x) = w^T x + b = c \quad , \quad -1 < c < 1 \quad (3.5)$$

x_i ($i = 1, \dots, M$) ayırıcı bir hiperdüzlemi oluşturmaktadır. $c = 0$ olduğunda ayırıcı hiperdüzlem, iki hiperdüzlemin ($c = 1$ ve $c = -1$) ortasındaki düzlemdir. Ayırıcı hiperdüzlem ile hiperdüzleme en yakın eğitim verisi arasındaki mesafe marj veya sınır olarak tanımlanmaktadır. $D(x) = 1$ ve -1 hiperdüzlemleri en az bir eğitim verisi içerdiği varsayılırsa, hiperdüzlem $D(x) = 0$ en büyük sınıra $-1 < c < 1$ arasında sahip olacaktır. Bu bölge $\{x | -1 \leq D(x) \leq 1\}$ karar fonksiyonu için genelleştirilmiş bölgedir [Abe, 2005].

Yukarıda belirtildiği gibi sonsuz sayıda karar fonksiyonu vardır. Bu karar fonksiyonları ayırıcı hiperdüzlem olarak adlandırılır. Genelleştirme kabiliyeti ayırıcı hiperdüzleme bağlıdır. En geniş sınırlı hiperdüzlem optimal ayırıcı hiperdüzlem olarak tanımlanmaktadır. Optimal ayırıcı hiperdüzlemi seçmek önemlidir; çünkü hatayı minimize eder, yanlış sınıflandırma ihtimalini azaltır ve sezgisel olarak güvenilir bölgede çalışmamızı sağlar [Abe, 2005]. Şekil 3.3'te solda dar sınırlı daha az kabul edilebilir ve Şekil 3.3'te sağda geniş sınırlı iyi bir ayırıcı gösterilmektedir.



Şekil 3.3. İki sınıflı verinin sınıflandırılması [Abe, 2005]



Şekil 3.4. Optimal ayırıcı hiperdüzlem [Abe, 2005]

Optimal hiperdüzlemin sınırı şu şekilde belirlenir: x^+ , Sınıf 1’de, x^- Sınıf 2’de ve bu iki nokta birbirlerine en yakın nokta olsun. x^- ’ten x^+ ’e ulaşmak için w (normal) yönündeki hareket etmek gerekir, bu durum Eş. 3.6’daki gibi matematiksel olarak ifade edilir (Bkz. Şekil 3.4) [Abe, 2005].

$$x^+ = x^- + \mu w \quad (3.6)$$

İki sınıf arasındaki mesafe, bu iki nokta arasındaki farka eşittir (Eş. 3.7).

$$|x^+ - x^-| = m \quad (3.7)$$

Buradan hareketle Eş. 3.6'daki x^+ , $w x^+ + b = 1$ formülünde yerine yazılırsa,

$$w(x^- + \mu w) + b = 1$$

$$w.x^- + \mu.w.w + b = 1$$

$$w x^- + b + \mu.w.w = 1$$

$$w.x^- + b = -1$$

$$-1 + \mu.w.w = 1$$

$$\mu.w.w = 2$$

$$\mu = \frac{2}{w.w} \quad (3.8)$$

Eş. 3.6'daki eşitlikte, μw ifadesi Eş. 3.7'de yerine yazılırsa,

$$m = |x^+ - x^-| = |\mu.w| = \mu|w| = \mu\sqrt{w.w}$$

μ yerine de Eş. 3.8'de bulunan değeri yazılırsa,

$$= \frac{2\sqrt{w.w}}{w.w} = \frac{2}{\sqrt{w.w}}$$

$\|w\| = \sqrt{w.w}$ ifadesi vektör normudur.

$$m = \frac{2}{\|w\|} \quad (3.9)$$

ifadesi sınırı verecektir.

Geniş sınırın daha iyi sonuç vereceği belirtilmişti, geniş sınırlı optimal ayırıcı hiperdüzlemi bulmak için, w 'nın normunu minimize etmemiz gerekmektedir.

$\|w\|^2 = \langle w, w \rangle$ burada $\langle ., . \rangle$ nokta çarpımdır [Smola ve Schölkopf, 2003].

$$\text{Min } Q(w) = \frac{\|w\|^2}{2} \quad (3.10)$$

k.a.

$$y_i(w^T x_i + b) \geq 1, \quad i = 1, \dots, M \quad (3.11)$$

Problem eşitsizlik kısıtlı klasik bir doğrusal olmayan optimizasyon problemidir. Optimizasyon probleminin lagrange fonksiyonunun eyer noktasındaki çözümü bulunabilmektedir. Lagrange kullanmaktaki ilk neden Eş. 3.11'deki kısıtların, uğraşılması daha kolay olan lagrange çarpanlarının üzerindeki kısıtlarla yer değiştirecek olmasıdır. İkinci neden ise, problemin formülasyonunda, verinin sadece vektörler arasındaki nokta çarpım formunda görülecek olmasıdır. Yukarıdaki denklemlerle verilen ifadelerin çözümü zor olacağından bu problemi uygun bir dual forma çevirmek iyi olacaktır. Bunu yapmak için ilk önce kısıtlı problem, kısıtsız probleme dönüştürülür [Abe, 2005; Burges, 1998; Smola ve Schölkopf, 2003]. Lagrange çarpanlarının anlamıyla ilgili bilgi ekte daha detaylı olarak sunulmuştur (EK-3).

$$Q(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^M \alpha_i \{y_i (w^T x_i + b) - 1\} \quad (3.12)$$

$\alpha (\alpha_1, \dots, \alpha_M)^T$ negatif olmayan lagrange çarpanlarıdır. Eş. 3.12'deki eşitliği w ve b 'ye göre türevi alınırsa

$$\frac{\partial Q(w, b, \alpha)}{\partial w} = 0 \quad (3.13)$$

$$\frac{\partial Q(w, b, \alpha)}{\partial b} = 0 \quad (3.14)$$

$$\alpha_i \{y_i (w^T x_i + b) - 1\} = 0, \quad i = 1, \dots, M \quad (3.15)$$

$$\alpha_i \geq 0, \quad i = 1, \dots, M \quad (3.18)$$

Eşitsizlik kısıtlarıyla, lagrange çarpanları arasındaki (Eş. 3.15) ilişki Karush-Kuhn-Tucker (KKT) koşulları tarafından sağlanmaktadır. Eş. 3.15'ten $\alpha_i = 0$ veya $\alpha_i \neq 0$ ve $y_i (w^T x_i + b) = 1$ eşitlikleri sağlanmalıdır. Mevcut veri x_i ve $\alpha_i \neq 0$ destek vektörler olarak tanımlanır. Eş. 3.12-3.14 ifadelerinden

$$w = \sum_{i=1}^M \alpha_i y_i x_i \quad (3.17)$$

ve

$$\sum_{i=1}^M \alpha_i y_i = 0 \quad (3.18)$$

Eş. 3.17 ve Eş. 3.18, Eş. 3.12'de yerine yazılırsa dual model elde edilir.

$$\text{Maks } Q(\alpha) = \sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i,j=1}^M \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (3.19)$$

k.a.

$$\sum_{i=1}^M y_i \alpha_i = 0, \quad \alpha_i \geq 0, \quad i = 1, \dots, M \quad (3.20)$$

Eğer çözüm varsa ve sınıflandırma problemi doğrusal olarak ayrılır durumda ise, global optimum çözüm α_i ($i = 1, \dots, M$) vardır [Abe, 2005].


3.2. Doğrusal Ayrılamayan DVM

Doğrusal ayrılabilen DVM’de verinin doğrusal ayrılabilir olduğu varsayılmıştı. Veri doğrusal ayrılamadığı durumda, mümkün çözüm yoktur ve doğrusal ayrılabilir DVM çözümsüzdür. Bu bölümde DVM’nin doğrusal ayrılamayan veri için uygulanan yöntemi incelenecektir [Abe, 2005].

Verinin ayrılabilmesi için, negatif olmayan aylak değişkenler tanımlanmıştır $\xi_i (\geq 0)$.

$$y_i (w^T x_i + b) \geq 1 - \xi_i, \quad i = 1, \dots, M \quad (3.21)$$

Aylak değişkenler (ξ_i) sayesinde, mümkün çözüm bulunabilir. x_i için, eğer $0 < \xi_i < 1$ ise veri maksimum marjine sahip değildir ama doğru sınıflandırılmaktadır. Eğer $\xi_i \geq 1$ ise optimal hiperdüzlem veriyi yanlış sınıflandırmıştır (Şekil 3.5) [Abe, 2005].



Şekil 3.5. İki boyutlu uzayda doğrusal olarak ayrılamayan durum [Abe, 2005]

$$\text{Min } Q(w, b, \xi) = \frac{\|w\|^2}{2} + C \sum_{i=1}^M \xi_i \quad (3.22)$$

k.a.

$$y_i (w_i^T x_i + b) \geq 1 - \xi_i \quad (3.23)$$

$$\xi_i > 0, \quad i = 1, \dots, M \quad (3.24)$$

$\xi = (\xi_1, \dots, \xi_M)^T$ ve C (ceza parametresi), marjini maksimize etme ile sınıflandırma hatasını minimize etmek için kullanılacak olan marjin parametreleridir. Doğrusal ayrılabilir durumdaki gibi, lagrange çarpanları $\alpha (\alpha_1, \dots, \alpha_M)^T$ ve $\beta (\beta_1, \dots, \beta_M)^T$ tanımlanmıştır [Abe, 2005].

$$Q(w, b, \xi, \alpha, \beta) = \frac{\|w\|^2}{2} + C \sum_{i=1}^M \xi_i - \sum_{i=1}^M \alpha_i \{y_i (w^T x_i + b) - 1 + \xi_i\} - \sum_{i=1}^M \beta_i \xi_i \quad (3.25)$$

$$\frac{\partial Q(w, b, \xi, \alpha, \beta)}{\partial w} = 0 \quad (3.26)$$

$$\frac{\partial Q(w, b, \xi, \alpha, \beta)}{\partial b} = 0 \quad (3.27)$$

$$\frac{\partial Q(w, b, \xi, \alpha, \beta)}{\partial \xi} = 0 \quad (3.28)$$

$$\alpha_i (y_i (w^T x_i + b) - 1 + \xi_i) = 0, \quad i = 1, \dots, M \quad (3.29)$$

$$\beta_i \xi_i = 0, \quad i = 1, \dots, M \quad (3.30)$$

$$\alpha_i \geq 0, \quad \beta_i \geq 0, \quad \xi_i \geq 0, \quad i = 1, \dots, M \quad (3.31)$$

Eş. 3.26-3.28'den Eş. 3.32-3.34 elde edilir.

$$w = \sum_{i=1}^M \alpha_i y_i x_i \quad (3.32)$$

$$\sum_{i=1}^M \alpha_i y_i = 0 \quad (3.33)$$

$$\alpha_i + \beta_i = C, \quad i = 1, \dots, M \quad (3.34)$$

Eş. 3.32 ve Eş. 3.33, Eş. 3.25'te yerine yazılırsa dual model elde edilir.

$$\text{Maks } Q(\alpha) = \sum_{i=1}^M \alpha_i + \frac{1}{2} \sum_{i,j=1}^M \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (3.35)$$

k.a.

$$\sum_{i=1}^M y_i \alpha_i = 0, \quad 0 \leq \alpha_i \leq C, \quad i = 1, \dots, M \quad (3.36)$$

Doğrusal ayrılamayan durum ile doğrusal ayrılabilir durum arasındaki tek fark α_i nın C 'i geçemeyeceğidir. Eş. 3.29 ve Eş. 3.30 KKT koşulları olarak tanımlanır. Bunlardan ve Eş. 3.34'ten α_i için çıkaracağımız 3 durum vardır [Abe, 2005].

1. $\alpha_i = 0$ ve $\xi_i = 0$ ise x_i doğru sınıflandırılmıştır.
2. $0 < \alpha_i < C$ ise $y_i(w^T x_i + b) - 1 + \xi_i = 0$ ve $\xi_i = 0$ 'dır. $y_i(w^T x_i + b) = 1$ ve x_i destek vektörlerdir. Özellikle $C > \alpha_i > 0$ durumunda destek vektörler, sınırsız destek vektör olarak ifade edilir.
3. $\alpha_i = C$ ise $y_i(w^T x_i + b) - 1 + \xi_i = 0$ ve $\xi_i \geq 0$ 'dır. x_i destek vektördür. $\alpha_i = C$ durumunda, destek vektör sınırlı destek vektör olarak ifade edilir. Eğer $0 \leq \xi_i \leq 1$ ise x_i doğru şekilde sınıflandırılmıştır ve eğer $\xi_i \geq 1$ ise x_i yanlış sınıflandırılmıştır.

Karar fonksiyonu doğrusal ayrılabilen ve doğrusal ayrılamayan durumda aşağıdaki gibidir.

$$D(x) = \sum_{i \in S} \alpha_i y_i x_i^T + b \quad (3.37)$$

S destek vektör indis seti sayısıdır. α_i destek vektörler için sıfırdan farklı olduğundan, Eş. 3.37'ye yalnızca destek vektörler için eklenir. Sınırsız α_i için

$$b = y_i - w^T x_i \quad (3.38)$$


sağlanır. Kesin hesaplama, sınırsız destek vektörler için hesaplanan değerlerin ortalaması alınarak b bulunur.

$$b = \frac{1}{|U|} \sum_{i \in U} (y_i - w^T x_i) \quad (3.39)$$

U sınırsız destek vektör indis seti sayısıdır [Abe, 2005].


3.3. Doğrusal Olmayan DVM

Doğrusal olmayan DVM'nin matematiksel ifadesinden bahsetmeden önce niçin doğrusal olmayan DVM'ye gereksinim duyulduğunu görsel olarak ifade etmek daha açıklayıcı olacaktır. Doğrusal ayrılabilen (tek boyutlu) veri için sınıflandırma işlemi Şekil 3.6'daki gibi yapılmaktadır. Fakat, Şekil 3.7'de soldaki verinin sınıflandırma işlemi doğrusal olarak (tek bir ayırıcı hiperdüzlem ile) yapılamamaktadır.



Şekil 3.6. Tek boyutlu verinin ayrılması

Veriyi sınıflandırmak için, (Şekil 3.7) $f(x) = x^2$ dönüştürme fonksiyonu kullanılarak (x, x^2) dönüştürmesi yapılmış ve veri doğrusal olarak ayrılmıştır. Belirli dönüşümler ile verinin doğrusal sınıflandırma işlemi ve dönüştürme fonksiyonları bu bölümde sırasıyla incelenecektir [Abe, 2005; Awm, 2010].



Şekil 3.7. Girdi uzayındaki verinin özellik uzayına haritalanması

DVM’de optimal ayırıcı düzlem genelleştirme kabiliyeti maksimize edilerek bulunur. Eğer veri doğrusal ayrılamıyorsa, hiperdüzlem optimal olarak belirlenmesine rağmen sınıflandırıcının yüksek genelleştirme kabiliyeti olmayabilir. Bu sebepten doğrusal ayrılabilirliği artırmak için, giriş uzayı yüksek boyutlu nokta çarpım (özellik) uzayına haritalanır. Bu yaklaşımda dönüştürme veya haritalandırma işlemi yapılabilir gözükse de, üst dereceli polinom ve yüksek boyutlu farklı özellik uzaylarından dönüşüm matematiksel olarak mümkün olmamaktadır. Fakat bu yaklaşımın çözümsüzlüğü daha basit olarak çözüm bulma zorunluluğunu ortaya açıkça koymuştur. Bu basit çözüm nokta çarpım esasına dayanmaktadır, nokta çarpım kullanarak çözümsüzlük ortadan kaldırılmıştır [Abe, 2005; Awm, 2010; Smola ve Schölkopf, 2003].

g kuadratik özellik uzayından $R^2 \rightarrow R^3$ haritalanırsa $g(x_1, x_2) = (x_1^2, \sqrt{2}x_1x_2, x_2^2)$ ($x \in R^2$) doğrusal DVM’den kuadratik fonksiyona dönüşür. Bunun yerine

$$\langle x, x' \rangle^2 = \left\langle \begin{pmatrix} x_1^2 \\ \sqrt{2}x_1x_2 \\ x_2^2 \end{pmatrix}, \begin{pmatrix} x_1'^2 \\ \sqrt{2}x_1'x_2' \\ x_2'^2 \end{pmatrix} \right\rangle \quad (3.40)$$

nokta çarpım kullanılır.

Önceden de belirtildiği üzere, DVM algoritması sadece veri örnekleri x_i arasındaki nokta çarpımına dayanmaktadır. Bundan dolayı g yerine $K(x, x') = \langle g(x), g(x') \rangle$ sağlaması yeterlidir [Smola ve Schölkopf, 2003].

Doğrusal olmayan vektör fonksiyonları kullanarak $g(x) = (g_1(x), \dots, g_l(x))^T$, m boyutlu girdi vektörü x 'i, l boyutlu özellik uzayına haritalanır. Özellik uzayında kullanılan karar fonksiyonu:

$$D(x) = w^T g(x) + b \quad (3.41)$$

w , l boyutlu vektör, b bias katsayısıdır.

Dönüşüm yapmak için kullanılan doğrusal olmayan vektör fonksiyonlarına literatürde kernel fonksiyonları denilmektedir. Kernel kullanmanın avantajı, yüksek boyutlu özellik uzayını açık olarak kullanmamıza gerek olmamasıdır. Bu işlem uğraştırıcı bir işlem değildir. $K(x, x')$ 'i kullanarak $(K(x, x') = g^T(x)g(x'))$, $g(x)$ kullanmaya gerek kalmamaktadır [Abe, 2005].

Kernel kullanarak, özellik uzayında dual problem aşağıdaki gibidir.

$$\text{Maks} \quad Q(\alpha) = \sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i,j=1}^M \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (3.42)$$

k.a.

$$\sum_{i=1}^M y_i \alpha_i = 0, \quad 0 \leq \alpha_i \leq C, \quad i = 1, \dots, M \quad (3.43)$$

$K(x, x')$ kerneldir ve optimizasyon problemi konkav kuadratik programlama problemidir. $\alpha = 0$ mümkün çözümdür ve problemin global optimal çözümü vardır. KKT koşulları aşağıdaki gibidir [Abe, 2005].

$$\alpha_i \left(y_i \left(\sum_{j=1}^M y_j \alpha_j K(x_i, x_j) + b \right) - 1 + \xi_i \right) = 0, \quad i = 1, \dots, M \quad (3.44)$$

$$(C - \alpha_i) \xi_i = 0, \quad i = 1, \dots, M \quad (3.45)$$

$$\alpha_i \geq 0, \quad \xi_i \geq 0, \quad i = 1, \dots, M \quad (3.46)$$

Karar fonksiyonu ve b aşağıdaki gibidir.

$$D(x) = \sum_{i \in S} \alpha_i y_i K(x_i, x_j) + b \quad (3.47)$$

$$b = y_j - \sum_{i \in S} \alpha_i y_i K(x_i, x_j) \quad (3.48)$$

En çok kullanılan kernel fonksiyonları şunlardır [Hsu vd., 2010]:

$$K(x_i, x_j) = x_i^T x_j \quad (\text{Doğrusal kernel}) \quad (3.49)$$

$$K(x_i, x_j) = (\lambda x_i^T x_j + r)^d, \quad \lambda > 0 \quad (\text{Polinom kernel}) \quad (3.50)$$

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \quad \gamma > 0 \quad (\text{RBF kernel}) \quad (3.51)$$

Kernellerin kullandıkları parametreler sırasıyla açıklamak gerekirse, doğrusal kernel, sadece ceza parametresini (C) kullanmaktadır (Bkz. Eş. 3.43, Eş. 3.49). C hiperdüzlemin sınırını genişletmede ve sınıflandırma hatasını azaltmada

kullanılmaktadır. RBF kernel, C ve gamayı (γ) kullanmaktadır (Bkz. Eş. 3.43, Eş. 3.50). γ , RBF kernelin yarıçap genişliğini belirleyen değerdir. Polinom kernel parametre olarak, C , lamdayı (λ), r katsayısını ve polinomun üssünü (d) kullanmaktadır (Bkz. Eş. 3.43, Eş. 3.51).

4. MBA RİSKİNİN DVM İLE SINIFLANDIRILMASI

EMK işleri son yıllarda ergonomi, biyomekanik ve ilgili diğer bilim alanlarının en önemli konulardan biri olmuştur. Bunun nedeni ise elle malzeme taşıma ve kaldırma işlerinin çalışanlarda görülen MBA'nın en başta gelen sebebi olmasıdır [Chung ve Dohyung, 2000].

İkinci bölümde EMK işlerinin MBA'ya yol açtığı faktörlerden bahsedilmiştir. MBA hakkında bir çok araştırma yapılmıştır. Bu çalışmalardan en önemlisi ve literatürde en çok göz önüne alınan Marras vd. tarafından yapılan çalışmadır. Bu çalışmayı diğer çalışmalardan ayıran önemli bir nokta çalışanın gövde hareket değişkenlerini ve iş ile ilgili değişkenleri dikkate alarak MBA riskini farklı işkollarında ve geniş bir zaman zarfında kaydetmesidir. Modelin çıktısı düşük ve yüksek MBA riskli işler [Marras vd., 1993].

Sınıflandırma işleminde veri, eğitim ve test kümesi olarak iki gruba ayrılır, eğitim kümesi ile yapılan eğitim sonucu karar fonksiyonu bulunur. Sınıflandırma performansının değerlendirilmesi için test kümesi kullanılır [Abe, 2005]. (Sınıflandırıcıların kullandığı sonsal olasılık hesabı için EK-4).

Marras vd. tarafından toplanan veri, eğitim ve test kümesi olarak iki gruba ayrılmıştır [Marras vd., 1993]. Çalışmada benzer veri kümeleri kullanılacaktır. DVM ile sınıflandırma işleminden önce veri üzerinde min-maks normalizasyon işlemi yapılmıştır. Normalizasyon işlemi, büyük sayısal değişkenlerin küçük sayısal değişkenleri domine etmesini önlemek için yapılmaktadır [Hsu vd., 2010].

4.1. MBA-DVM Modelinin Parametreleri

Bu bölümde MBA-DVM modelinde kullanılan parametrelere değinilmiştir. Modellerde kullanılacak olan her bir parametre bu bölümde açıklanacaktır.

4.1.1. Kernel ve kernel parametrelerinin seçimi

Optimal parametre seçimi, DVM modelinin karmaşıklığını doğrudan etkilemektedir. DVM'nin genelleştirme performansı, optimal parametre seçimine bağlıdır. İyi bir sınıflandırma performansı sağlanması için kernel ve kernel parametresinin seçimi bu bakımdan önemlidir [Hsu vd., 2010]. Bu bölümde sırasıyla DVM'nin kullandığı doğrusal, polinom ve RBF kernellerden ve kernellerin kullandıkları parametrelerden bahsedilecektir.

Doğrusal kernel

Doğrusal kernel kullanmak genellikle iyi performans vermez; fakat veri kümesi büyük olduğu durumda bu durum değişebilir. Eğer veri kümesi büyük ise, verinin yüksek boyutlu uzaya haritalanması gerekmeyebilir. Bu durumda doğrusal kernel kullanmak bize gereken performansı verebilir ve bu durumda sadece ceza parametresi (C) araştırılır [Hsu vd., 2010]. Doğrusal kernel Eş. 4.1'deki gibi ifade edilir.

$$K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j \quad (4.1)$$

C, daha önce de bahsedildiği gibi, sınır (marjin) genişliğini artırma ile eğitim hatasını azaltma arasındaki ödünleşmeyi düzenleyen parametredir. C'nin artması eğitim kümesi için sınıflandırma yüzdesini artıracaktır; fakat bu durum verinin aşırı uyumuna yol açabilir. Verinin aşırı uyuma yol açmadan test kümesinin en doğru biçimde sınıflandırılmasını sağlayacak en uygun parametre seçimi önemlidir.

Polinom kernel

Polinom kernel, diğer kerneller göre daha fazla parametreye sahiptir ve fazla parametreye sahip olması parametrelerin seçimi konusunda dezavantaj yaratabilir. Polinom kernel Eş. 4.2'deki gibi ifade edilir.

$$K(x_i, x_j) = (\lambda x_i^T x_j + r)^d, \quad \lambda > 0 \quad (4.2)$$

Polinom kernelin kullandığı parametreler: C, lamda (λ), polinomun katsayısı (r) ve polinomun derecesi (d)'dir. λ 'nın artması eğitim kümesi için sınıflandırma yüzdesini artıracaktır; fakat bu durum verinin aşırı uyumuna yol açabilir. d'yi belirlemek önemlidir; çünkü fonksiyonun değeri üstel olarak artabilir [Hsu vd., 2010].

RBF kernel

RBF (Radial basis function) kernel fonksiyonu literatürde genellikle ilk tercihtir. Bu kernel, doğrusal olmayan örnekleri yüksek boyutlu uzaya haritalamaktadır. RBF kernel Eş. 4.3'te tanımlanmıştır.

$$K(x_i, x_j) = \exp\left(-\gamma \|x_i - x_j\|^2\right), \quad \gamma > 0 \quad (4.3)$$

RBF kernel, bağımlı değişkenlerle açıklayıcı değişkenler arasında doğrusal olmayan ilişki kurmayı sağlamaktadır. Doğrusal kernel RBF kernelin özel bir durumudur; çünkü doğrusal kernel ceza parametresini kullanırken, RBF kernel C ve gama (γ) parametrelerini kullanarak benzer performans göstermektedir [Hsu vd., 2010]. γ , RBF kernelin yarıçap genişliğini belirleyen değerdir.

RBF kullanmadaki ikinci neden ise, bu kernelin kullandığı parametre sayısıdır. Bilindiği üzere parametre sayısı arttıkça model karmaşıklığı artmaktadır. RBF kernel, polinom kernele göre daha az parametreye sahip olduğundan daha az karmaşıklığa sahiptir. RBF kernel fonksiyonunun değeri sıfır ve bir arasında değer alırken, polinom kernel fonksiyonun değeri bir ihtimal de olsa sıfır veya sonsuz değeri alabilmektedir. Ama düşük bir ihtimal de olsa, RBF kernel kullanmak bazı durumlarda uygun olmayabilir, bu duruma örnek veri kümesinin aşırı büyük olması durumudur [Hsu vd., 2010]. RBF kernel C ve γ 'yı kullanmaktadır. γ 'nın artması

eğitim kümesi için sınıflandırma yüzdesini artıracaktır; fakat bu durum verinin aşırı uyumuna yol açabilir.

Çizelge 4.1’de yukarıda bahsi geçen kernellerin kullandıkları parametreler görülmektedir. Bu çizelge hangi kernelin, hangi parametreleri kullandığını anlamada yardımcıdır.

Çizelge 4.1. Kernel ve kernelin kullandığı parametreler

Kernel Tipi	Kullanılan Parametreler				
	C	γ	λ	r	d
Doğrusal Kernel	√				
Polinom Kernel	√		√	√	√
RBF Kernel	√	√			

4.1.2. Optimal parametre seçimi

DVM’nin kullandığı kernellerin ve kernel parametrelerinin seçimi konusunda birçok araştırma yapılmıştır. Bu çalışmalar eğitim verisinin aşırı uyuma düşmeden sınıflandırma performansının artırılmasına ve eğitim süresinin azaltılmasına yöneliktir.

Doğrusal kernel C, RBF kernel C ve γ , polinom kernel ise C, λ , r ve d parametrelerini kullanmaktadır. Her parametrenin seçimi, sınıflandırma performansının belirlenmesinde çok önemli rol oynamaktadır. Uygun olmayan parametre seçimi çalışmayı verimsiz kılabilir. Önceden hangi parametre kombinasyonunun en yüksek veya en iyi performans göstereceğini bilmek imkânsızdır. Bunun için bazı parametre seçim işlemleri yapmak gerekmektedir. Parametre seçiminin asıl hedefi optimal parametreleri bulmak ve test kümesi veya daha önce eğitim kümesinin karşılaşmadığı veriler üzerinde iyi bir sınıflandırma performansı sağlamaktır [Hsu vd., 2010].

Genelleştirme performansı iyi bir modele ulaşmak için şu aşamalar izlenecektir [Ismael vd., 2008]:

1. Her bir parametre için uygun değer aralığı belirle,
2. Her bir parametre kombinasyonu için modeli çalıştır (eğitim kümesi),
3. En performansa sahip parametreleri seç,
4. En iyi model parametreleriyle sınıflandırma modeli kur,
5. Test kümesi üzerinde genelleştirme performansını ölç.

Sınıflandırıcı model kurulduktan sonra, kurulan modellerin performanslarının ölçülmesi ve diğer modellerle karşılaştırılması gerekmektedir. Model kurulduktan sonra test kümesi veya modelin daha önce karşılaşmadığı veri karşısındaki modelin performansını ölçmek diğer bir aşamadır. Literatürde model performansını ölçmek üzere ortaya atılmış birçok yöntem bulunmaktadır. Bir sonraki bölümde bu yöntemlerden bahsedilecektir.

4.2. Sınıflandırıcı Performansının Değerlendirilmesi

Sınıflandırıcı performansının belirlenmesinde en iyi yol olan “veriyi doğru olarak tahmin ediyor olmasıdır” düşüncesi aslında doğru değildir. Birçok sınıflandırıcı algoritma vardır ve bu algoritmalar birbirlerinden farklıdır. Bazıları diğerlerinden fazla işleme ve belleğe gereksinim duyabilmektedir. Bazı algoritmalar ise güvenilir sonuçlar için fazla sayıda veriye gereksinim duyar. Belirtildiği üzere verinin doğru tahmin edilmesi bize güvenilir sonuçlar vermeyebilir [Bramer, 2007; Tan, 2006].

Sınıflandırıcı performansı, model tarafından tahmin edilen doğru ve yanlış sayısı hesaplanarak bulunur. Bu hesaplar aşağıda karşılaştırma matrisi olarak adlandırılan Çizelge 4.2’de gösterilir.

Çizelge 4.2. Karşılaştırma matrisi

		Tahmini Sınıf		Toplam Örnek
		+	-	
Gerçek Sınıf	+	DP	YN	P= DP+YN
	-	YP	DN	N= YP+DN

Karşılaştırma matrisi 4 hücreden oluşmaktadır ve hücrelerin anlamları aşağıdaki gibidir. DP, pozitif sınıf olarak sınıflandırılan pozitif örnek sayısı; YP, pozitif sınıf olarak sınıflandırılan negatif örnek sayısı; YN, negatif sınıf olarak sınıflandırılan pozitif örnek sayısı; DN, negatif sınıf olarak sınıflandırılan negatif örnek sayısı; P pozitif toplam ve N negatif toplam örnek sayısıdır.

Karşılaştırma matrisi model sonuçlarını özetlese de matrisin sonuçlarını tek bir sonuca dönüştürerek performans karşılaştırması yapmak daha uygun olacaktır. Model performanslarının karşılaştırılmasında şu ölçütleri kullanılmıştır: DSY, Hata oranı, Doğru pozitif oranı, Kesinlik değeri, F1 skoru, Yakınlık katsayısı ve AİK eğrisi altında kalan alan.

4.2.1. Doğru sınıflandırma yüzdesi (DSY)

DSY, Eş. 4.4 kullanılarak hesaplanır [Bramer, 2007; Tan vd., 2006]:

$$DSY = \frac{\text{Toplam doğru tahmin sayısı}}{\text{Toplam tahmin sayısı}} = \frac{DP+DN}{P+N} \quad (4.4)$$

4.2.2. Hata oranı

Hata oranı, Eş. 4.5 kullanılarak hesaplanır [Tan vd., 2006]:

$$\text{Hata oranı} = \frac{\text{Toplam yanlış tahmin sayısı}}{\text{Toplam tahmin sayısı}} = \frac{YP+YN}{P+N} \quad (4.5)$$

DSY'nin yüksek, Hata oranının düşük olduğu model daha iyi performans göstermektedir.

4.2.3. Kesinlik

Kesinlik, gerçek sınıfı pozitif (DP) olarak sınıflandırılan örneklerin, tahmini tüm pozitif (DP+YP) sınıfların toplamına oranıdır. Kesinlik değerinin yüksek olması istenir; çünkü bu sayede karşılaştırma matrisinin YP hücresi düşük değer alarak sınıflandırma hatası düşük olacaktır. Kesinlik ölçütü Eş. 4.6'da tanımlanmıştır [Bramer, 2007; Tan vd., 2006].

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (4.6)$$

4.2.4. Doğru pozitif oranı

Doğru pozitif (DP) oranı, gerçek sınıfı DP olarak sınıflandırılan örneklerin, gerçek tüm pozitif (P) sınıfların toplamına oranıdır. Yüksek DP oranı iyidir; çünkü gerçekte pozitif sınıfta yer alması gereken örneklerin yanlış sınıflandırılması önlenecektir. DP oranı Eş. 4.7 kullanılarak hesaplanır [Bramer, 2007; Tan vd., 2006]:

$$\text{DP oranı} = \frac{DP}{DP+YN} = \frac{DP}{P} \quad (4.7)$$

4.2.5. F1 skoru

Performansı değerlendirilecek model veya modellerin yüksek DP oranına sahip olduğunda düşük Kesinlik değerine sahip olabilir veya bu durumun tam tersi de söz konusu olabilir. Bu durumu ortadan kaldırmak için DP oranı ve Kesinlik ölçütlerini birleştirip tek bir sayısal değer kullanmak gerekir. F1 skoru bu iki ölçütü birleştirmiştir. Sonuçta bu iki ölçütün birleşmesinden oluşan F1 skorunun yüksek çıkması için iki ölçütün de yüksek çıkması gerekmektedir. F1 skorunun yüksek

çıkması modelin daha iyi performans gösterdiğini bize ifade etmektedir. F1 skoru, DP oranı ve Kesinlik değerinin harmonik ortalamasıdır ve Eş. 4.8 kullanılarak hesaplanır [Bramer, 2007; Tan vd., 2006]:


$$F1 \text{ skoru} = \frac{2 \times \text{Kesinlik} \times \text{DP oran}}{\text{Kesinlik} + \text{DP oran}} \quad (4.8)$$

4.2.6. Alıcı işletim karakteristiği (AİK) grafiği

Alıcı İşletim Karakteristiği (AİK) grafiği farklı sınıflandırıcı performanslarını karşılaştırmak için geliştirilen yöntemlerdendir. AİK grafiğinde, DP oranı (Bkz. Eş. 4.7) dikey eksen ve yanlış pozitif (YP) oranı (Eş. 4.9) yatay eksen üzerinde gösterilir.

$$YP \text{ oranı} = \frac{YP}{DN+YP} \quad (4.9)$$

AİK grafiğinde gösterilen her bir (x, y) noktası sırasıyla YP oranını ve DP oranını göstermektedir. AİK grafiği üzerindeki noktalar (0, 1), (1, 0), (1, 1) ve (0, 0) Şekil 4.1’de gösterilmiştir. Bu noktalar dört özel duruma (A, B, C ve D) karşılık gelmektedir. A, mükemmel sınıflandırıcı olarak tanımlanmaktadır ve grafik üzerinde, sol üst köşe, en iyi noktaya karşılık gelmektedir. B, en kötü olası sınıflandırıcı olarak tanımlanmaktadır ve grafik üzerinde sağ alt köşede yer almaktadır. C, ultra-liberal sınıflandırıcı olarak tanımlanmaktadır, anlamı sınıflandırıcının nesneleri her zaman pozitif sınıfa ayırması durumudur; D, ultra-muhafazakar sınıflandırıcı olarak tanımlanmaktadır, anlamı ise sınıflandırıcının nesneleri her zaman negatif sınıfa ayırması durumudur. Sonuçta, sol üst köşeye yakın olan grafik daha iyi sınıflandırıcı performansına sahiptir [Bramer, 2007].



Şekil 4.1. AİK grafiğinde önemli noktalar [Bramer, 2007]

4.2.7. Yakınlık katsayısı


DP ve YP oranı dikkate alarak bir diğer model performansı karşılaştırma ölçütü ise Yakınlık katsayısıdır (YK). Daha önce belirtildiği gibi AİK grafiğinde en iyi nokta sol üst köşe noktasıdır (Bkz. Şekil 4.1). YK, DP ve YP oranı kullanarak AİK grafiği üzerinde, en iyi nokta olan sol üst köşe noktasıyla karşılaştırarak, öklit mesafesini hesaplar. YK ne kadar büyükse o model daha iyidir. YK, Eş. 4.10'da tanımlanmıştır [Akay, 2011].

$$YK = \frac{\sqrt{(1-YP \text{ oranı})^2 + (DP \text{ oranı})^2}}{\sqrt{(YP \text{ oranı})^2 + (1-DP \text{ oranı})^2} + \sqrt{(1-YP \text{ oranı})^2 + (DP \text{ oranı})^2}} \quad (4.10)$$

4.2.8. AİK eğrisi altında kalan alan

AİK grafiği sınıflandırıcı performansını görsel olarak yansıtmada iyidir; fakat sayısal olarak modellerin karşılaştırılması da gerekmektedir. AİK eğrisi altında kalan alanın hesaplanması ile sınıflandırıcı modellerin performansının karşılaştırılması daha uygun olmaktadır. Eğri altında kalan alan bire yakın ise o modelin performansı daha iyidir. AİK eğrisi altında kalan alan en fazla 1 değerini almaktadır, bu mükemmel

sınıflandırıcı anlamına gelmektedir. Şekil 4.2’de iki farklı modele ait AİK eğrileri bulunmaktadır. Şekilde görüldüğü üzere M_1 modeli daha iyi performansa sahiptir. M_1 modelinin AİK eğrisi altında kalan alan, diğer modelin (M_2) AİK eğrisi altında kalan alandan büyüktür [Tan vd., 2006; Kurtcephe, 2010].



Şekil 4.2.Farklı modeller için AİK eğrileri [Tan vd., 2006]

Bu bölümde anlatılan performans ölçüm yöntemleri, MBA-DVM modellerinin ve literatürdeki diğer modellerin performanslarının karşılaştırılmasında kullanılacaktır.


4.3. MBA-DVM Modellerinin Değişkenleri

MBA riskinin sınıflandırılmasında DVM modellerinin kullandığı girdi değişkenleri ve çıktılarından bu bölümde bahsedilecektir.


Modelin girdi ve çıktı değişkenleri Şekil 4.4’te gösterilmiştir. Marras vd. tarafından toplanmış olan verilerin girdi değişkenleri şunlardır: kaldırma sıklığı (sıklık/saat) ve sagittal eksendeki maksimum moment (Nm) iş ile ilgili değişkenleri; gövdenin maksimum kaldırma sırasında bükülme hızı (derece/saniye), yana eğilme sırasında gövde ile sagittal eksen arasındaki açının en yüksek değeri (derece) ve öne doğru

eğilme sırasında gövdenin maksimum hızı (derece/saniye) ise vücut hareket değişkenleridir [Marras vd., 1993].

Resim 4.1’de anatomik düzlemler görülmektedir. Sagital eksen, vücudu önden arkaya doğru ikiye ayıran düzlemdir. Lateral, ise vücudun yana doğru hareketini tanımlamaktadır.



Şekil 4.3. Modelin parametreleri



Resim 4.1. Anatomik düzlemler [Marras, 2008]

Farklı endüstri kollarında toplanan 235 iş, medikal kayıtlar ve rahatsızlanma kayıtları dikkate alınarak yüksek ve düşük MBA riskli olarak iki sınıfa ayrılmıştır. Bu sınıflar modelin çıktı değişkenlerini oluşturmaktadır. EMK işlerinden 3 yıllık zaman zarfı boyunca medikal rahatsızlık yaşanmamış ise, düşük MBA riskli iş; EMK işlerinden 200,000 saatte en az 12 medikal rahatsızlık yaşanmış ise, yüksek MBA riskli iş olarak gruplandırılmıştır. Bu sonuçlar dikkate alınarak 124 iş düşük riskli iş, 111 iş ise yüksek riskli iş olarak kaydedilmiştir. Farklı endüstri kollarında toplanan 235 işin 148'i (74'ü düşük riskli iş, 74'ü yüksek riskli iş) modelin eğitimi için ayrılmıştır. Geriye kalan 87 iş ise (50'si düşük riskli iş, 37'si yüksek riskli iş) model performansını test etmek için ayrılmıştır [Marras vd., 1993].

4.4. MBA-DVM Model Performanslarının Karşılaştırılması

Bu bölümde MBA riskini sınıflandırmak için kullanılan DVM modellerinden bahsedilecektir. Bu modeller sırasıyla doğrusal kernel DVM modeli, polinom kernel DVM modeli ve RBF kernel DVM modelidir. Her bir kernel için en iyi performansa sahip model seçilecektir. Modellerden bahsetmeden önce, kernellerde kullanılan parametreler için değer aralıkları belirlenmiştir. C için [1, 500], λ için [0,1, 5], r için [0, 5,5], γ için [0,01, 5] ve d için [1, 5] değer aralıklarındaki sayılar kullanılacaktır (Çizelge 4.3).

Çizelge 4.3. Kerneller ve kernellerin kullandıkları parametreler

Kernel Tipi	Kullanılan Parametreler				
	C	γ	λ	r	d
Doğrusal	[1, 500]	-	-	-	-
Polinom	[1, 500]	-	[0,1, 5]	[0, 5,5]	[1, 5]
RBF	[1, 500]	[0,01, 5]	-	-	-

4.4.1. Doğrusal kernel DVM modeli


MBA riski, doğrusal kernel DVM modeliyle sınıflandırılmıştır. C [1, 500] değer aralığı için model çalıştırılmıştır. Bu aralıkta en yüksek DSY'ye sahip 6 model

seçilmiştir. Bu modellere ait sonuçlar Çizelge 4.4'teki gibidir. Modeller test kümesinin sınıflandırma yüzdelere göre sıralanmıştır.

Çizelge 4.4. Doğrusal kernel DVM modellerinin sonuçları

Kullanılan Parametre	DSY (%)	
	Eğitim kümesi	Test kümesi
C		
10	79,05	75,86
20	79,05	74,71
5	78,38	74,71
40	77,70	74,71
60	77,70	74,71
120	77,70	74,71

En iyi sonuca sahip model seçilmeden önce, tüm doğrusal kernel DVM modellerinin eğitim ve test kümesi için sınıflandırma yüzdelere sonuçlarını grafik üzerinden görmek verinin aşırı uyumunu anlamada yararlı olacaktır (Şekil 4.5).



Şekil 4.4. Doğrusal kernel DVM modelleri

Doğrusal kernel DVM modellerinin bazı C değerlerine göre eğitim ve test kümesi sonuçları Şekil 4.5'teki gibi görülmektedir. Burada dikkat edilecek husus, C'nin artması eğitim kümesinin sınıflandırma yüzdesini artırmaktadır ama bu artma test kümesi üzerinde belirli bir noktadan sonra olumsuz bir etki yapmaktadır. C, 10

değerinin üzerinde ise modeller aşırı uyuma düşmektedir ve bu bahsedildiği gibi istenmeyen durumdur.

Doğrusal kernel ile sınıflandırma sonucunda elde edilen en iyi sonucun karşılaştırma matrisi Çizelge 4.5'tedir. Çizelge incelenirse MBA riski doğrusal kernel DVM modeliyle %75,86 doğrulukla sınıflandırdığı anlaşılmaktadır.

Çizelge 4.5. Doğrusal kernel DVM modeline ait karşılaştırma matrisi

	MBA riski yüksek	MBA riski düşük
MBA riski yüksek	23	14
MBA riski düşük	7	43
		DSY: %75,86

En yüksek DSY'ye sahip model için performans ölçütleri hesaplanmıştır. En iyi parametreye sahip doğrusal kernel DVM sonucuna göre DP oranı 0,6216, Hata oranı 0,2414, Kesinlik değeri 0,7667, F1 skoru 0,6866, YK 0,7245 ve AİK eğrisi altında kalan alan 0,82 olarak hesaplanmıştır.

4.4.2. Polinom kernel DVM modeli

MBA riski polinom kernel DVM modeliyle sınıflandırılmıştır. Diğer kernellere göre daha fazla parametre kullanan polinom kernel parametrelerinin değer aralıkları şu şekilde belirlenmişti: $C=[1, 500]$, $\lambda=[0,1, 5]$, $r=[0, 5,5]$ ve $d=[1, 5]$. Bu parametrelerin kombinasyonları için model çalıştırılmıştır. İyi sonuca sahip modellerin aldıkları parametreler Çizelge 4.6'daki gibi gösterilmiştir. Bu uygulamada C (20, 80, 120, 160 ve 250), λ (0,25 ve 2,45), r (1, 5) ve d (3, 4) parametre kombinasyonlarını kullanan modeller daha iyi sonuç göstermiştir.

Çizelge 4.6. Polinom kernel DVM modellerinin sonuçları

Kullanılan Parametreler				DSY (%)	
C	λ	r	d	Eğitim kümesi	Test kümesi
250	2,45	5	4	92,57	91,95
160	0,25	5	3	90,54	89,66
120	0,25	5	3	89,86	88,51
20	0,25	5	3	85,81	85,06
80	0,25	1	4	84,46	83,91

Çizelge 4.6’da yer alan polinom kernel DVM modelleri, test kümesinin DSY’sine göre sıralanmıştır. Polinom kernel ile sınıflandırma sonucunda elde edilen en iyi sonucun karşılaştırma matrisi Çizelge 4.7’dedir. Çizelgeden görüleceği gibi, MBA riski polinom kernel DVM modeliyle %91,95 doğrulukla sınıflandırılmıştır.

Çizelge 4.7. Polinom kernel DVM modeline ait karşılaştırma matrisi

	MBA riski yüksek	MBA riski düşük
MBA riski yüksek	30	7
MBA riski düşük	0	50
		DSY: %91,95

En iyi performans gösteren polinom MBA-DVM modelinin performans ölçütleri hesaplanmıştır. En iyi sonuç, polinom kernelin parametreleri $C=250$, $\lambda=2,45$, $r=5$, $d=4$ değerlerine sahip olduğunda elde edilmiştir. Polinom kernel kullanarak yapılan sınıflandırmada en iyi modelin, DP oranı 0,8108, Hata oranı 0,0805, Kesinlik değeri 1,0000, F1 skoru 0,8955, YK 0,8719 ve AİK eğrisi altında kalan alan 0,9960 olarak hesaplanmıştır.

4.4.3. RBF kernel DVM modeli

Bu bölümde ise DVM, RBF kernel kullanarak MBA riski sınıflandırılmıştır. Parametre kombinasyonları $C=[1, 500]$ ve $\gamma=[0,01, 5]$ için model çalıştırılmıştır; iyi sonuca sahip modeller ve parametreleri Çizelge 4.8’deki gibi gösterilmiştir. Bu uygulamada modeller, C (40, 120 ve 160) ve γ (1,2, 2 ve 4,19) parametre

kombinasyonları daha iyi sonuç göstermektedir. Çizelge 4.8’de yer alan en iyi sonuca sahip RBF kernel DVM modelleri test kümesinin sınıflandırma yüzdesine göre sıralanmıştır.

Çizelge 4.8. RBF kernel DVM modellerinin sonuçları

Kullanılan Parametreler		DSY (%)	
C	γ	Eğitim kümesi	Test kümesi
160	4,19	93,24	93,10
120	1,2	85,81	85,06
40	2,0	86,49	83,91
40	1,2	83,78	81,61
20	1,2	81,08	80,46

RBF kernelle sınıflandırma sonucunda elde edilen en iyi sonucun karşılaştırma matrisi Çizelge 4.9’dadır. RBF kernel kullanarak yapılan sınıflandırmada en iyi sonuç gösteren modelin parametreleri $C=160$ ve $\gamma=4,19$ ’dur. Bu model eğitim kümesini %93,24, test kümesini %93,1 oranında doğru sınıflandırmıştır.

Çizelge 4.9. RBF kernel DVM modeline ait karşılaştırma matrisi

	MBA riski yüksek	MBA riski düşük
MBA riski yüksek	33	4
MBA riski düşük	2	48
DSY: %93,10		

En iyi parametre kombinasyonundan elde edilen en yüksek DSY’ye sahip RBF kernel MBA-DVM modelinin performans ölçütleri hesaplanmıştır. RBF kernel kullanılarak yapılan sınıflandırmada en iyi modelin DP oranı 0,8919, Hata oranı 0,0690, Kesinlik değeri 0,9429, F1 skoru 0,9167, YK 0,9191 ve AİK eğrisi altında kalan alan ise 0,9830 olarak hesaplanmıştır.

4.5. MBA Riskini Sınıflandıracak DVM Modelinin Belirlenmesi

Tüm kernellerden elde edilen en iyi sonuçlar Çizelge 4.10'da gösterilmiştir. Bu çizelgeden kernellerin performansı karşılaştırmalı olarak görülebilmektedir.

Çizelge 4.10. Kernel performanslarının karşılaştırılması

Performans Ölçütleri	Kerneller		
	Doğrusal	Polinom	RBF
DSY (%)	75,86	91,95	93,10
DP oranı	0,6216	0,8108	0,8919
Hata oranı	0,2414	0,0805	0,0690
Kesinlik	0,7667	1,0000	0,9429
F1 Skoru	0,6866	0,8955	0,9167
AİK eğrisi altında kalan alan	0,8200	0,9960	0,9830
YK	0,7245	0,8719	0,9191

Çizelge 4.10 incelenirse, en iyi performansı RBF kernel gösterdiği görülmektedir. RBF kernel, polinom kernele göre %1,15, doğrusal kernele göre ise %17,24 oranında daha iyi sınıflandırma yapmaktadır. DP oranı ve Kesinlik değerlerinin harmonik ortalaması olan F1 skoru sonucu da RBF kernelin daha iyidir. RBF kernel ayrıca en az Hata oranına sahiptir. AİK eğrisi altında kalan alana göre karşılaştırıldığında polinom kernel, RBF kernele göre daha iyi olmasına rağmen RBF kernel AİK grafiğinde en iyi noktaya (sol üst köşe) daha yakındır (YK=0,9191). Sonuçta, RBF kernel daha iyi performansa sahip olduğundan, MBA riskinin sınıflandırılmasında tercih edilecektir.

Çizelge 4.11'de Marras vd.'nin çalışmasındaki veri kullanılarak, MBA riskinin sınıflandırıldığı çalışmaların sonuçları görülmektedir. MBA-DVM modeli, Zurada vd.'nin yapmış oldukları çalışmadan %18,4; Chen vd.'nin yapmış oldukları çalışmadan %13,8; Akay vd.'nin yapmış oldukları çalışmadan %14,94; Akay ve Toksarı'nın çalışmasından %11,5 ve Akay'ın yapmış olduğu çalışmadan %1,15 daha iyi sınıflandırma yapmaktadır.

Çizelge 4.11. Marras vd. verisini kullanan çalışmaların sonuçlarının karşılaştırması

Model	MBA Riski	
	Yüksek	Düşük
Zurada vd. (1997)		
MBA Riski Yüksek	29	8
MBA Riski Düşük	14	36
		DSY: %74,70
Chen vd. (2000-2004)		
MBA Riski Yüksek	31	6
MBA Riski Düşük	12	38
		DSY: %79,30
Akay vd. (2008)		
MBA Riski Yüksek	31	6
MBA Riski Düşük	13	37
		DSY: %78,16
Akay ve Toksarı (2009)		
MBA Riski Yüksek	35	2
MBA Riski Düşük	14	36
		DSY: %81,60
Akay (2011)		
MBA Riski Yüksek	30	7
MBA Riski Düşük	0	50
		DSY: %91,95
MBA-DVM		
MBA Riski Yüksek	33	4
MBA Riski Düşük	2	48
		DSY: %93,10

Performans ölçütü olarak sadece sınıflandırma yüzdesinin dikkate alınmaması, bunun yanında farklı performans ölçütlerinin de dikkate alınması gerektiği daha önce vurgulanmıştı. Çizelge 4.12’de, Çizelge 4.11’de yer alan modellere ilişkin hesaplanmış olan performans ölçütleri bulunmaktadır. Bu performans ölçütleri modellerin karşılaştırma matrislerinden hesaplanmıştır. Çizelge 4.12’de görüldüğü üzere en iyi performans ölçüt değerlerine sahip MBA-DVM modelidir. DP oranı, F1 skoru ve YK’sı diğer modellerden daha iyi olan MBA-DVM modeli ayrıca en az

Hata oranına sahiptir. Sonuçta, MBA-DVM modelinin daha iyi performansa sahip olduğu aşikârdır.

Çizelge 4.12. Marras vd. verisini kullanan çalışmaların farklı performans ölçütleriyle karşılaştırılması

Performans Ölçütleri	Modeller					
	Zurada vd. (1997)	Chen vd. (2000-2004)	Akay vd. (2008)	Akay ve Toksarı (2009)	Akay (2011)	MBA-DVM
DSY (%)	74,70	79,30	78,16	81,60	91,95	93,10
Hata oranı	0,2529	0,2069	0,2184	0,1839	0,0805	0,0690
Kesinlik	0,6744	0,7209	0,7045	0,7143	1,0000	0,9429
DP oranı	0,7838	0,8378	0,8378	0,9459	0,8108	0,8649
F1 Skoru	0,7250	0,7750	0,7654	0,8140	0,8955	0,9167
YK	0,7505	0,7961	0,7849	0,8065	0,8719	0,9191

Marras vd. tarafından literatüre kazandırılmış olan verideki benzer eğitim ve test kümesini kullanmak yerine katmanlı örnekleme veriyi farklı kümelerle ayıran çalışmaların sonuçları Çizelge 4.13'te yer almaktadır. Zurada vd. 2004 yılında yapmış olduğu çalışmada katmanlı örnekleme yöntemiyle, yüksek ve düşük risk oranını (sırasıyla %47,2 ve %52,8) dikkate alarak, eğitim (%40), geçerlilik (%30) ve test kümesine (%30) rassal ayırmış ve 10'lu çapraz geçerlilik ile kurduğu modelleri test etmiştir [Zurada vd., 2004]. Akay ise katmanlı örnekleme, yüksek ve düşük risk oranını (sırasıyla %47,2 ve %52,8) dikkate alarak, eğitim (%70) ve test (%30) kümesine rassal ayırmış ve 10'lu çapraz geçerlilik testi uygulamıştır [Akay, 2011].

MBA-DVM modeli, ayrıca bahsi geçen bu çalışmalardaki gibi, yüksek ve düşük risk oranı (sırasıyla %47,2 ve %52,8) dikkate alınarak, veri katmanlı örnekleme ile eğitim (%70) ve test (%30) kümesine ayrılmış 10'lu çapraz geçerlilik testine tabi tutulmuştur. Veriyi katmanlı örnekleme ile farklı kümelerle ayırma işlemi EK-5'teki Matlab kodu ile gerçekleştirilmiştir. Çizelge 4.13'te MBA-DVM modeli ve literatürde bahsi geçen bu çalışmaların sonuçları karşılaştırılmıştır.

Çizelge 4.13. Marras vd. verisini kullanarak yapılan çalışmaların karşılaştırılması-2

	Zurada vd. (2004)					Akay (2011)	MBA- DVM	
	Yapay sinir ağları	Lojistik regresyon	Karar ağaçları	Olay temelli çıkarım	Topluluk modeli			
Ortalama (sayı)								
Tüm riskler	51,7	49,4	51,1	52,9	52,0	64,2	64,3	
Yüksek risk	22,7	19,8	26,1	25,8	23,9	28,1	29,2	
Düşük risk	29,0	29,6	25,0	27,1	27,3	36,1	35,1	
En iyi sonuç								
Tüm riskler	56,0	57,0	55,0	59,0	59,0	68,0	67,0	
Yüksek risk	28,0	29,0	31,0	32,0	30,0	32,0	31,0	
Düşük risk	33,0	33,0	30,0	30,0	30,0	37,0	36,0	
En kötü sonuç								
Tüm riskler	47,0	46,0	47,0	46,0	46,0	62,0	59,0	
Yüksek risk	17,0	16,0	23,0	22,0	20,0	26,0	26,0	
Düşük risk	23,0	27,0	21,0	22,0	21,0	35,0	33,0	
Ortalama (%)								
Tüm riskler	73,9	70,6	73,0	75,6	74,3	91,7	91,9	
Yüksek risk	68,8	60,0	79,1	78,2	72,4	85,1	88,5	
Düşük risk	78,4	80,0	67,6	73,2	73,8	97,6	94,9	
En iyi sonuç								
Tüm riskler	80,0	81,4	78,6	84,3	84,3	97,1	95,7	
Yüksek risk	84,8	87,9	93,9	97,0	90,9	97,0	93,9	
Düşük risk	89,2	89,2	81,1	81,1	81,1	100,0	97,3	
En kötü sonuç								
Tüm riskler	67,1	65,7	65,7	65,7	65,7	88,6	84,3	
Yüksek risk	51,5	48,5	66,7	66,7	60,6	78,8	78,8	
Düşük risk	62,2	73,0	59,5	59,5	56,8	94,6	89,2	
Std. Sapma								
Tüm riskler	3,5	3,7		3,4	4,0	1,85	2,30	
Yüksek risk	3,6	3,9		3,2	3,2	1,81	1,79	
Düşük risk	2,9	1,8		2,8	2,9	0,57	2,54	

Zurada vd. MBA riskini sınıflandırdıkları farklı veri madenciliği teknikleri ve elde ettikleri sonuçlar sırasıyla şunlardır: yapay sinir ağları ortalama %73,9, lojistik regresyon ortalama %70,6, karar ağaçları ortalama. %73,0, olay temelli çıkarım ortalama %75,6 ve topluluk modeli ortalama %74,3'tür [Zurada vd., 2004].

Akay, gri ilişkisel analizle 33 yüksek riskli işin ortalama 28,1'ini, 37 düşük riskli işin ise ortalama 36,1'ini doğru sınıflandırarak, MBA riskini ortalama %91,7 oranda doğru sınıflandırmıştır [Akay, 2011]. MBA-DVM modeli ise 33 yüksek riskli işin ortalama 29,2'sini, 37 düşük riskli işin ise ortalama 35,1'ini doğru sınıflandırarak MBA riskini ortalama %91,9 oranla doğru sınıflandırılmıştır. Akay'ın gri ilişkisel analiz ile önerdiği yöntem ve MBA-DVM modeli MBA riskinin tahmininde benzer sınıflandırma yüzdesine ulaşmışlardır [Akay, 2011] (Bkz. Çizelge 4.13).

Zurada 2012 yılında yapmış olduğu çalışmasında katmanlı örneklem kullanmadan veriyi eğitim, geçerlilik ve test kümesi olarak 3 kümeye ayırdığından elde ettiği sonuçlar Çizelge 4.13'te yer almamıştır. Zurada, MBA riskini sınıflandırmış olduğu lojistik regresyon, sinir ağları, RBF sinir ağları, DVM (polinom kernel), en yakın komşu (k-NN) algoritması, karar ağaçları ve rasgele ağaçlar ile elde ettiği sınıflandırma yüzdeleri sırasıyla ortalama %73,8, %72,6, %71,0, %74,1, %74,2, %71,7 ve %70,3'tür [Zurada, 2012]. Zurada'nın vasat sonuçlara ulaşmasındaki başlıca etkenler; veriyi eğitim, test ve geçerlilik kümesine ayırmada kullandığı yöntem ve kurduğu DVM modelinde seçtiği polinom kerneldir. DVM'nin dezavantajı parametre seçimidir ve ayrıca polinom kernel, RBF kernelden fazla parametre kullanmayı gerektirir. Daha fazla parametre kullanımı ile Zurada kurduğu DVM modelinde optimal parametre seçimini gerçekleştirememiş ve iyi bir sınıflandırma performansı sağlayamamıştır.

Sonuçta MBA-DVM modeli, EMK işlerinden kaynaklanan MBA riskinin tahmininde diğer çalışmalara oranla daha başarılı sonuç vermiştir.

5. SONUÇ

Günümüzde teknolojik gelişmeler sonucu otomasyona geçişe rağmen, endüstriyel işletmeler halen yoğun olarak fiziksel işgücüne ihtiyaç duymaktadır. Yoğun olarak EMK işlerini gerektiren aktiviteler mesleki sağlık ve güvenlik açısından tehlikeli bir faktör konumundadır. Yapılan çalışmalar, EMK işleri ile çalışanlarda ortaya çıkan MBA rahatsızlığı arasında doğrusal bir ilişki olduğunu göstermiştir.

MBA'ya yol açan faktörler ve EMK işlerine ait risk seviyelerinin belirlenmesi için literatürde yapılmış olan çalışmalar incelenmiştir. Marras vd. MBA'ya yol açan faktörleri farklı endüstri kollarında incelemiştir. Marras vd. tarafından 1993 yılında yapılmış olan çalışmada model girdi olarak gövde hareket değişkenlerini ve iş ile ilgili değişkenleri dikkate almaktadır. Modelin çıktısı ise, düşük ve yüksek MBA riskli işler [Marras vd., 1993].

DVM, Vapnik tarafından geliştirilen istatistiksel öğrenme teorisi alanında ortaya çıkmış bir öğrenme metodudur. DVM ikili sınıflandırma probleminin çözümünde kullanılır. DVM ile sınıflandırmada, veri ile sınıflandırma için gerekli fonksiyon belirlenmekte ve veri sınıflara ayrılmaktadır. DVM'de amaç, veriyi sınıflandıracak optimal ayırıcı hiperdüzlemin bulunmasıdır.

Bu tez çalışmasında, EMK işlerinden kaynaklanan MBA riski DVM ile sınıflandırılmıştır. MBA riski en iyi performansa sahip parametre kombinasyonu seçilerek belirlenmiştir. DVM ile MBA riski %93,1 oranında doğru sınıflandırılmıştır. DVM ile elde edilen sonuç ayrıca literatürde aynı veri kümesini kullanan diğer çalışmaların sonuçlarıyla karşılaştırılmış ve daha yüksek sınıflandırma yüzdesi elde edilmiştir.

EMK işlerinden kaynaklanan MBA riskinin sınıflandırılması ile MBA'ya yol açan riskler elimine edilebilecektir. İşyerinden ve kişisel özelliklerden kaynaklanan risklerin elimine edilmesi ile işgücü kayıplarının, sigorta ve sağlık masraflarının en

aza indirilebilmesi ve alıřanın iřyeri performansının ve verimlilięinin artması saęlanacaktır.

KAYNAKLAR

1. Abe, S., "Support Vector Machines for Pattern Classification 2nd ed.", 15-127, **Springer**, 15-77 (2005).
2. Akay, D., "Grey relational analysis based on instance based learning approach for classification of risks of occupational low back disorders", **Safety Science**, 49: 1277-1282 (2011).
3. Akay, D., Akcayol, M. A., Kurt, M., "NEFCLASS based extraction of fuzzy rules and classification of risks of low back disorders", **Expert Systems with Applications**, 35: 2107-2112 (2008).
4. Akay, D., Toksari, M. D., "Ant colony optimization approach for classification of occupational low back disorder risks", **Human Factors and Ergonomics in Manufacturing**, 19 (1): 1-14 (2009).
5. Ayoub, M.M., "Determination and Modelling of Lifting Capacity", **Texas Technical University Industrial Engineering Department Final Report**, 11-35 (1978).
6. Behrens, V., Seligman, P., Cameron, L., Mathias, C.G.T., Fine, L., "The prevalence of back pain, hand discomfort and dermatitis in the U.S. working population", **American Journal of Public Health**, 84: 1780-1785 (1994).
7. Bergenudd H., Nilsson B., "Back pain in middle age; occupational work load and psychologic factors: an epidemiologic survey", **Spine**, 13: 58-60 (1988).
8. Bramer, M., "Principles of Data Mining", **Springer**, 173-185 (2007).
9. Bazarra, M.S., Jarvis, J.J., Sherali, H.D., "Linear Programming and Network Flows 2nd ed.", **Wiley**, USA, 251-254 (1990).
10. Bigos, S.J., Spengler, D.M., Martin, N.A., Zeh, J., Fisher L., Nachemson A., "Back injuries in industry: A retrospective study. III. Employee-related factors", **Spine**, 11:252-256. (1986).
11. Burges, C.J.C., "Data Mining and Knowledge Discovery", ed.Usama Fayyad, **Kluwer Academic Publishers**, Boston, 2: 121-167 (1998).
12. Carnahan, B.J., Redfern, M.S., "Building a low back injury risk classifier using evolutionary computation", **Proceedings of the 49th Annual Meeting of the Human Factors and Ergonomics Society**, Chicago, Illinois, 2 881-885 (1998).

13. Carnahan, B.J., Redfern, M.S., Norman, B., "Designing safe job rotation schedules using optimisation and heuristic search", *Ergonomics*, 43 (4): 543-560 (2000).
14. Ciriello, V.M., Snook, S.H., "Survey of manual handling tasks", *International Journal of Industrial Ergonomics*, 23: 149-156 (1999).
15. Chen-Luang, C., Kaber, D.B., Dempsey, P.G., "A new approach to applying feedforward neural networks to the prediction of musculoskeletal disorder risk", *Applied Ergonomics*, 31: 269-282 (2000).
16. Chen-Luang, C., Kaber, D.B., Dempsey, P.G., "Using feedforward neural networks and forward selection of input variables for an ergonomics data classification problem", *Human Factors and Ergonomics in Manufacturing*, 14: 31-49 (2004).
17. Cherkassky, V., Ma, Y., "Practical selection of SVM parameters and noise estimation for SVM regression", *Neural Networks*, 17: 113-126 (2004).
18. Chung, M.K., Dohyung, K., "Evaluation of lifting tasks frequently performed during fire brick manufacturing", *International Journal of Industrial Ergonomics*, 25: 423-433 (2000).
19. "Code of Practice for Manual Handling", *Occupational Health and Safety Act, 1985*, 25: 55 (2000).
20. Friedman, J., Hastie T., Tibshirani R., "The Elements of Statistical Learning Data Mining", *Springer*, (2001).
21. Genaidy, A., Beltroni, J., Yeung, S., Karwowski, W., Succop, P., "Use of human expertise in the evaluation of manual lifting activities", *Occupational Ergonomics*, 2 (2): 105-124, (1999/2000).
22. Herrin, G.D., Jaraiedi, M., Anderson, C.K., "Prediction of overexertion injuries using biomechanical and psychophysical models", *American Industrial Hygiene Association Journal*, 47: 322-330 (1986).
23. Hsu, C.W., Chang, C.C., Lin, C.J., "A practical guide to support vector classification", *Department of Computer Science, National Taiwan University*, Taipei 106, Taiwan, (2010).
24. Huang, G.J., Yeh, W.Y., Lee, C.L., "Manual lifting task risk evaluation using computer vision system", *Computers & Industrial Engineering*, 31: (3/4): 655-660 (1996).

25. Ismael, K., Salleh, S.H., Najeb, J.M., Jahangir Bakhteri R.B., “Efficient Parameter Selection of Support Vector Machines”, **BIOMED 2008**, Kuala Lumpur, 183-186, (2008).
26. Jiang, B.C., Smith, J.L., Ayoub, M.M., “Psychophysical modelling for combined manual material handling activities”, **Ergonomics**, 29 (10): 1173-1190 (1986).
27. Jung, E.S., Freivalds, A., “Multiple criteria decision making for the resolution of conflict ergonomics knowledge in MMH”, **Ergonomics**, 34 (11): 1351-1356 (1991).
28. Jung, H.S., Jung, H.S., ”A survey of the optimal handle position for boxes with different sizes and manual handling positions”, **Applied Ergonomics**, 41: 115–122 (2010).
29. Jager, M., Luttman, A., “Critical survey on the biomechanical criterion in the NIOSH method for the design and evaluation of lifting tasks”, **International Journal of Industrial Ergonomics**, 23: 331-337 (1999).
30. Kara İ., “Yöneylem Araştırması Doğrusal Olmayan Modeller”, **T.C. Anadolu Üniversitesi Yayınları No.139**, Eskişehir, (1986).
31. Karwowski, W., Marras, W.S., ”Occupational Ergonomics Engineering and Administrative Controls”, **CRC Press**, 10.1-10.20 (2003).
32. Karwowski, W., Marras W.S., “Fundamentals and Assessment Tools for Occupational Ergonomics”, **CRC Press**, 35.1-35.7 (2006).
33. Karwowski, W., Mital, A., “Development of a safety index for manual lifting tasks”, **Applied Ergonomics**, 17 (1): 58-94 (1986).
34. Karwowski, W., Mullholland, N.D., Ward, T.L., Jagannathan, V., Kirchner, R.L., “LIFTAN: An experimental expert system for analysis of manual lifting tasks”, **Ergonomics**, 29 (10): 1213-1234 (1986).
35. Kecman, V., ”Learning And Soft Computing, Support Vector Machines, Neural Network And Fuzzy Logic Models”, **The MIT Press**, 121-176 (2001).
36. Keyserling, W.M., Punnett, L., Fine, L.J., “Trunk posture and back pain: Identification and control of occupational risk factors”, **Applied Industrial Hygiene**, 3:87-92 (1988).
37. Kelsey, J.L., Hardy, R.J., “Driving of motor vehicles as a risk factor for acute herniated lumbar intervertebral disc”, **American Journal of Epidemiology**, 102(1):63-73 (1975).

38. Kelsey, J.L., Cunningham, L.S., “Epidemiology of musculoskeletal impairments and associated disability”, *American Journal of Public Health*, 74:574-579, (1984).
39. Kurtcephe M., “Risk Estimation By Maximizing Area Under Receiver Operating Characteristics Curve with Application to Cardiovascular Surgery”, Yüksek lisans tezi, *Bilkent Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü*, Ankara, 8-13 (2010).
40. Lavender, S.A., Oleske D.M., Andersson, G.B.J., Kwasny, M.J.M., “Low-back disorder risk in automotive parts distribution”, *International Journal of Industrial Ergonomics*, 36: 755–760 (2006).
41. Luczak, H., Shuangsheng, G.E., “Fuzzy modelling of relations between physical weight and perceived heaviness: The Effect of size-weight illusion in industrial lifting tasks”, *Ergonomics*, 32 (7): 823-837 (1989).
42. Lloyd, M.H., Gauld, S., Soutar, C.A., “Epidemiologic study of back pain in miners and office workers”, *Spine*, 11:136-140 (1986).
43. Magora, A., “Investigation of the relation between low back pain and occupation. 2. Work history”, *Industrial Medicine and Surgery*, 39(12): 504-510 (1970).
44. Magora, A., “Investigation of the relation between low back pain and occupation. 5. Psychological aspects”, *Scandinavian Journal of Rehabilitation Medicine* 5, 191-196 (1973).
45. Marras, W.S., Allread, W.G., Burr, D.L., Fathallah, F.A., “Prospective validation of low-back disorders risk model and assessment of ergonomic interventions associated with manual materials handling”, *Ergonomics*, 43 (11): 1866-1886 (2000).
46. Marras, W.S., “The Working Back: A system review”, *Wiley*, USA, 11-30, (2008).
47. Marras, W.S., Lavender, S.A., Leurgans, S., Sudhakar, L.R., Allread, W.G., Fathallah, F., “The role of dynamic three-dimensional trunk motion in occupationally-related low back disorders”, *Spine*, 18: 617-628 (1993).
48. Marras, W.S., Lavender, S.A., Ferguson SA., Splittstoesser RE., Yang G, Schabo P., “Instrumentation for measuring dynamic spinal load moment exposures in the workplace”, *Journal of Electromyography and Kinesiology*, 20: 1–9 (2010).
49. McCauley, P., Badiru, A.B., “A fuzzy linguistic model for job-related injury risk assessment”, *Computers & Industrial Engineering*, 23 (1-4): 209-212 (1992).

50. Mital, A., Ramakrishnan, A., "A comparison of literature based design recommendations and experimental capability data for a complex MMH activity", ***International Journal of Industrial Ergonomics***, 24: 73-80 (1999).
51. Nelles, O., "Nonlinear System Identification", ***Springer-Verlag***, Berlin, 165-170, (2001)
52. Neuman, W.P, Wells, R.P., Norman, R.W., Frank, J., Shannan, H., Kerr, M.S., The OUBS Working Group, "A posture and load sampling approach to determining low back risk in occupational settings", ***International Journal of Industrial Ergonomics***, 27: 65-77 (2001).
53. Patvin, J.R., "Use of NIOSH equation to calculate lumbosacral compression forces", ***Ergonomics***, 40 (7): 691-707 (1997).
54. Platt, J.C., "Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines", ***Microsoft Research Technical Report***, MSR-TR-98-14 (1998).
55. Platt, J.C., "Probabilistic Outputs for Support Vector Machines and Comparison to Regularized Likelihood Methods", ***Microsoft Research***, (1999).
56. Riihimäki, H., Wickström, G., Hanninen, K., Luopajarvi, T., "Predictors of sciatic pain among concrete reinforcement workers and house painters. A five year follow-up", ***Scandinavian Journal of Work, Environment and Health***, 15: 415-423 (1989).
57. Saygun, M., "Sağlık Çalışanlarında İş Sağlığı Ve Güvenliği Sorunları", ***TAF Preventive Medical Bulletin***, 11(4): 373-382 2012.
58. Scott, P. A., "Ergonomics in Developing Regions Needs and Applications", ***CRC Press***, (2010).
59. Schaefer, P., Boocock, M. , Rosenberg, S., Jager M., Schaub K., "A target-based population approach for determining the risk of injury associated with manual pushing and pulling", ***International Journal of Industrial Ergonomics***, 37: 893-904 (2007).
60. Schölkopf, B., Smola A.J., "Learning with Kernels", ***The MIT Press***, (2002).
61. Smola, A.J., Schölkopf B., "A Tutorial on Support Vector Regression", ***NeuroCOLT Technical Report***, TR-98-030 (2003).
62. Snook, S.H., Ciriello, V.G., "The design of manual handling task: Revised tables of maximum acceptable weights and factors", ***Ergonomics***, 34 (9): 1197-1213 (1991).


63. St-Vincent, M., Denis, D., Imbeau, D., Laberge, M., "Work factors affecting manual materials handling in a warehouse superstore", ***International Journal of Industrial Ergonomics***, 35: 33–46 (2005).
64. Svensson, H.O., Andersson, G.B.J., "Low back pain in forty to forty-seven year old men: Work history and work environment factors", ***Spine***, 8 272-276 (1983).
65. Svensson, H.O., Vedin, A., Wilhelmsson C., "Low back pain in relation to other diseases and cardiovascular risk factors", ***Spine***, 8:277 (1983).
66. Taha H.A., "Yöneyem Araştırması", 6.basım, Baray Ş.A.; Esnaf Ş., ***Literatür Yayıncılık***, İstanbul, (2000).
67. Tan P.N., Steinbach M, Kumar V., "Introduction to Data Mining", ***Pearson***, (2006).
68. Tayyari, F., Smith, J.K., "Occupational Ergonomics: Principles and Applications", ***Chapman & Hall***, 191-214 (1997).
69. Temple, R., Adams, T., "Ergonomic analysis of a multi-task industrial lifting station using the NIOSH method", ***Journal of Industrial Technology***, 16 (2): 2-6 (2000).
70. Uyttendaele, D., Vandendriessche, G., Vercauteren, M., DeGroote W., "Sicklisting due to low back pain at the Ghent State University and University Hospital", ***Acta Orthop Belgica***, 47:523-546 (1981).
71. Waters, T.R., Putz-Anderson, V., Garg, A., "Applications Manual for the Revised NIOSH Lifting Equation", ***National Institute for Occupational Safety and Health Publications***, Cincinnati, 1-117 (1994).
72. Waters, T.R., Garg, A., "Two-dimensional biomechanical model for estimating strength of youth and adolescents for manual material handling tasks", ***Applied Ergonomics***, 41: 1–7 (2010).
73. Westrin, C.G., "Low back sick-listing. A nosological and medical insurance investigation", ***Scandinavian Journal of Social Medicine***, 7: 1-116 (1973).
74. Zurada, J., Karwowski, W., Marras, W., "A neural network-based system for classification of industrial jobs with respect to risk of low back disorders due to workplace design", ***Applied Ergonomics***, 28 (1): 49-55 (1997).
75. Zurada, J., Karwowski, W., Marras, W., "Classification of jobs with risk of low back disorders by applying data mining techniques", ***Occupational Ergonomics*** 4, 291–305 (2004).

76. Zurada, J., "Classifying the risk of work related low back disorders due to manual material handling tasks", *Expert Systems with Applications*, 7753 (2012).
77. Internet: Chang, C.C.; Lin, C. J., "LIBSVM - A Library for Support Vector Machines" [http://www.csie.ntu.edu.tw/~cjlin/libsvm/\(2011\).](http://www.csie.ntu.edu.tw/~cjlin/libsvm/(2011).)
78. Internet: Moore, A.W., "Support Vector Machines" [http://www.cs.cmu.edu/~awm/\(2010\).](http://www.cs.cmu.edu/~awm/(2010).)

EKLER

EK-1 VC boyutu

DVM'nin temelini oluşturan VC boyutu, sınıflandırma fonksiyonlarının kapasitesini ölçer. VC boyutu genellikle h ile gösterilir. m boyutlu hiperdüzlem en fazla $m+1$ örneği ayırır. VC boyutu $h = m+1$ 'dir.



Şekil 1.1. VC boyutu

VC boyutunu örnekle açıklamak gerekirse, Şekil 1.1'de soldaki gibi 3 veri olduğunu varsayalım. Bu 3 veri, 2 boyutlu düzlemler ile birbirlerinden ayrılabilir. Şekil 1.1'de sağdaki gibi elimizde 4 veri olduğunda ise veri 2 boyutlu düzlemler ile ayrılabilir. Burada görüldüğü gibi veriyi $\{1, 4\}$, $\{3, 2\}$ veya $\{1, 3\}$, $\{2, 4\}$ gibi ayrılabilir; fakat $\{1, 2\}$ ve $\{3, 4\}$ gibi ayıramamaktayız. Sınıflandıracak düzlemin boyutunu bilmek verinin doğru sınıflandırılması için önemlidir [Abe, 2005].

EK-2 Yapısal risk minimizasyonu

Yapısal risk minimizasyonu Vapnik tarafından 1979 yılında ortaya konulmuştur [Burges, 1998]. Klasik metotlarla (örn. yapay sinir ağları) DVM arasındaki en önemli farklılıklardan biri risk minimizasyonu problemindedir. Klasik metotlar deneyimsel risk minimizasyonunu kullanırken DVM yapısal risk minimizasyonunu kullanır. Deneyimsel risk minimizasyonda örnekler üzerindeki hata oranı azaltılmaya çalışılırken, yapısal risk minimizasyonu prensibinde tüm örnekler üzerinde oluşabilecek hata oranının üst sınırının minimum olmasına çalışılır Eş. 2.1 [Kecman, 2001; Burges, 1998].


$$R(\alpha) \leq R_{emp}(\alpha) + \phi \quad (2.1)$$

$R(\alpha)$ gerçek risk, $R_{emp}(\alpha)$ deneyimsel risk, ϕ VC güven aralığı

$$\phi = \sqrt{\frac{h \left[\ln \left(\frac{2M}{h} \right) + 1 \right] - \ln \left(\frac{\eta}{4} \right)}{M}} \quad (2.2)$$

M gözlem sayısı, h VC boyutu, η ($0 \leq \eta \leq 1$) olasılık değeridir. Eğer VC boyutu bilinirse, Eş. 2.2'deki sağ taraf hesap edebilir [Abe, 2005].

EK-2 (Devam) Yapısal risk minimizasyonu



Şekil 2.1. Verinin uyumu [Nelles, 2001]

Genelleştirme teorisi, verinin eğitilmesinden sonra elde edilen fonksiyonun test edilecek veriye veya daha sonra ortaya çıkabilecek olası gözlemlere uyması (doğru sınıfa ayırması) olarak kısaca açıklanabilir. Şekil 2.1’de verinin eğitilme işleminde olası sonuçlar görülmektedir. Verinin yetersiz uyumu ve verinin aşırı uyumu genelleştirme performansını düşürecektir. Burada önemli olan yapısal risk minimizasyonu ve genelleştirme teorisinden hareketle Şekil 2.1’deki durulacak noktadaki (optimum nokta) parametrelerin seçimi veya bulunmasıdır [Burges, 1998; Nelles, 2001].

EK-3 Lagrange çarpanlarının anlamı

Lagrange çarpanları, kaynakların marjinal katkılarını yani gölge fiyatlarını vermektedir. Lagrange çarpanları yöntemiyle ilgili kısıtın gölge fiyatının bulunmuş olması, karar verme açısından kısıtlardaki artışlara ilişkin fayda/maliyet analizi yapabilme olanağının elde edilmiş olduğunu göstermektedir [Kara, 1986; Taha, 2000].

$$\text{Min } f(u) \quad (3.1)$$

k.a.

$$g_i(u) \leq 0 \quad , \quad i = 1, \dots, m \quad (3.2)$$

Böyle bir model, karar değişkenlerinin negatif olmamaları da kısıt olarak göz önüne alınıp uygun işlemlerle

$$\text{Min } f(u) \quad (3.3)$$

k.a.

$$g_i(u) + S_i^2 \leq 0 \quad , \quad i = 1, \dots, m \quad (3.4)$$

veya

$$\text{Min } f(u) \quad (3.5)$$

k.a.

$$g(u) + S^2 \leq 0 \quad (3.6)$$

EK-3 (Devam) Lagrange çarpanlarının anlamı

şeklinde yazılsın. Böylece model, kısıtları eşitlik halinde olan doğrusal olmayan bir karar modeli durumuna getirilmiş olup, karşı gelen lagrange fonksiyonu,

$$L(X, S, \lambda) = f(x) - \lambda(g(x) + S^2) \quad (3.7)$$

olarak yazılır.

Lagrange fonksiyonundan hareketle en iyi nokta için gerekli koşullar yazılırsa;

$$\frac{\partial L(X, S, \lambda)}{\partial X} = \frac{\partial f}{\partial x_j} - \sum_{i=1}^m \lambda_i \frac{\partial g_i(x)}{\partial x_j} = 0 \quad (3.8)$$

$$\frac{\partial L(X, S, \lambda)}{\partial S} = -2\lambda S = 0 \quad (3.9)$$

$$\frac{\partial L(X, S, \lambda)}{\partial \lambda} = g(x) + S^2 = 0 \quad (3.10)$$

Denklem sistemleri elde edilir. Burada yer alan (Eş. 3.9) grup eşitlik, doğrusal programlamadaki aylaklığın tamamlanması özelliğinin benzeridir. Bu grup içindeki herhangi bir denklem açık olarak yazılırsa,

$$\frac{\partial L(X, S, \lambda)}{\partial S_i} = -2\lambda_i S_i = 0 \quad (3.11)$$

olduğu görülür ki, en iyi çözümün olduğu noktada $\lambda_i > 0$ ise $S_i = 0$; $S_i > 0$ ise $\lambda_i = 0$ olması gerektiği anlaşılır.

EK-3 (Devam) Lagrange çarpanlarının anlamı

$\lambda_i > 0$ iken $S_i = 0$ olduğuna göre, başlangıçta $g_i(x) < 0$ olarak verilen bu kısıt, en iyi çözümde $g_i(x) = 0$ haliyle gerçekleşiyor demektir ki, bu durumda $\lambda_i g_i(x) = 0$ yazılır [Kara, 1986; Taha, 2000].

$S_i > 0$ iken $\lambda_i = 0$ olduğuna göre, başlangıçta $g_i(x) \leq 0$ olarak verilen bu kısıt, en iyi çözümde $g_i(x) < 0$ haliyle gerçekleşiyor demektir ki, yine $\lambda_i g_i(x) = 0$ yazılır. O halde λ_i ve S_i hangi değeri alırlarsa alsınlar en iyi çözümde,

$$\lambda_i g_i(x) = 0 \quad (3.12)$$

gerçekleşiyor demektir.

Lagrange çarpanlarının ekonomik anlamı hatırlanırsa en iyi çözümde,

$$\frac{\partial Z}{\partial b_i} = \lambda_i \quad (3.13)$$

olduğuna göre, en büyük Z için b_i deki bir birim artışın amaç fonksiyonundaki marjinal katkısı olan λ_i 'nin negatif olamayacağı görülür. Yani yukarıdaki eşitlikte $\lambda_i \geq 0$ olmalıdır.

EK-4 Sonsal olasılık değerinin hesaplanması

Bir sınıflandırıcının ortaya çıkan yeni verinin sınıfı için öngöründe bulunması önemlidir; çünkü bu öngörü değeriyle (sonsal olasılık) model yeni verinin sınıfına karar verir. Sonsal olasılık $P(Sınıf = 1 | Girdi)$ genel karardan yeni bir karar oluştururken gereklidir (Eş. 4.1).

DVM olasılık hesabı üretememektedir. Ham puan değeri, olasılık hesabı tahmini için daha sonra gelen karmaşık işlemlere bağlı olarak bulunabilmektedir. Olasılık hesabı için Platt tarafından ortaya konmuş olan iki parametrelili fonksiyon kullanılmaktadır [Platt, 1999].

x test verisinin hangi sınıfa dahil olduğu olasılığı aşağıdaki formülle hesaplanmaktadır. A ve B parametreleri eğitim sonrası bulunmaktadır.

$$P(Sınıf = 1 | Girdi) = P(y = 1 | x) = p(x) = \frac{1}{1 + \exp(Af(x) + B)} \quad (4.1)$$

$$f(x) = \sum_i y_i \alpha_i k(x_i, x) \quad (4.2)$$

EK-5 Katmanlı örneklem için Matlab kodu

```

clc
clear
warning off

w_train_data=xlsread('data.xls','train');
w_test_data=xlsread ('data.xls','test');
wdata=[w_train_data; w_test_data];

train_data=[];
test_data=[];

%-----
% 10 cross validation yapılacak. 10 kere farkli stratified sampling yap.

Class_low=(wdata(:,end-1)==1);
Class_high=(wdata(:,end-1)==0);

ni=size(wdata,1);

nClass_low=sum(double(Class_low));
nClassB_hig=sum(double(Class_high));

Train=1;
Test=2;

Segment= repmat(Test,ni,1); % baslangicta test=2 atansin tum segment elemanlarına

DistinctStrata=unique(wdata(:,end-1));
nDistinctStrata=size(DistinctStrata,1);

for Stratum=1:nDistinctStrata
    ROI=find(wdata(:,end-1)==DistinctStrata(Stratum));
    nROI=length(ROI);
    R=randperm(nROI);
    Segment(ROI(R(1:round(0.70 * nROI))))=Train;
    % segment vektorunde 1 degeri train, 2 degeri alan test
end

%-----
train_data=wdata((Segment(:,1)==1),:);
test_data=wdata((Segment(:,1)==2),:);

```

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : ERDEM, Mehmet
 Uyruğu : T.C.
 Doğum tarihi ve yeri : 22.03.1984 Samsun
 Medeni hali : Bekar
 Telefon : 0 (312) 239 35 69
 Cep : 0 (544) 580 83 60
 e-mail : emehmet@windowlive.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Lisans	Başkent Üniversitesi /Endüstri Müh. Bölümü	2008
Lise	Tülay Başaran Anadolu Lisesi	2002

İş Deneyimi

Yıl	Yer	Görev
2010-2011	T.C. Ziraat Bankası A.Ş. Bankacılık Okulu	Uzman Yrd.
2011-devam	T.C. Ziraat Bankası A.Ş.	Uzman Yrd.

Yabancı Dil

İngilizce