

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**ÇOK BİLEŞENLİ BİR ALKOL KARIŞIMIN DAMITILDIĞI LABORATUVAR
ÖLÇEKTE SÜREKLİ ÇALIŞAN BİR DOLGULU DAMITMA KOLONUNUN
YAPAY SİNİR AĞLARI İLE ÇOK DEĞİŞKENLİ KONTROLÜ**

Fatma VAROL

KİMYA MÜHENDİSLİĞİ ANABİLİM DALI

**ANKARA
2008**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

ÇOK BİLEŞENLİ BİR ALKOL KARIŞIMIN DAMITILDIĞI LABORATUVAR ÖLÇEKTE SÜREKLİ ÇALIŞAN BİR DOLGULU DAMITMA KOLONUNUN YAPAY SİNİR AĞLARI İLE ÇOK DEĞİŞKENLİ KONTROLÜ

Fatma VAROL

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Kimya Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Süleyman KARACAN

Çok bileşenli bir alkol karışımının, laboratuvar ölçeğinde sürekli çalışan bir dolgulu damıtma kolonunda damıtılması incelenmiştir. Çalışmada, kolonun üst ve alt ürün sıcaklıklarının tek girdili tek çıktılı (SISO) ve çok girdili çok çıktılı (MIMO) kontrolü, deneysel ve teorik olarak yapılmıştır. Kontrol çalışmaları için yapay sinir ağı (ANN) temelli model öngörmeli kontrol (MPC) algoritması kullanılmıştır. Metanol, etanol, n-bütanol, isoamil alkol (1-pentanol) ve anisol (metil-fenil eter)'den oluşan beş bileşenli alkol karışımı damıtılmıştır. 2 L kazan hacmi ve 1 m'lik dolgu boyu olan laboratuvar ölçekli bir dolgulu damıtma kolonu kullanılmıştır. Proses tanımlama yapabilmek için, geri akma oranı ve kazana verilen ısı miktarı girdi değişkenleri, üst ve alt ürün sıcaklıkları çıkış değişkenleri seçilerek dinamik deneyler yapılmıştır. Girdi değişkenlerine pozitif ve negatif basamak etkiler verilerek çıkış değişkenlerinin zamanla değişimi elde edilmiştir. Deneysel veriler kullanılarak istatistiksel model tanımlama yöntemi ile prosesin iletim fonksiyonları bulunmuştur. Prosesin en iyi kontrol çiftini belirlemek için Bağlı Kazanç Matrisi (RGA) belirlenmiştir. Kontrol algoritması için, MATLAB ortamında prosesin ANN modeli tasarlanarak geri yayılım algoritması ile eğitilmiştir. Bu model temel alınarak MPC algoritması elde edilmiştir. ANN temelli MPC algoritması, deneysel kontrolde Visual Basic dilinde yazılarak paket programa eklenmiştir. Kontrol algoritması MATLAB ortamında da yazılarak teorik kontrol için kullanılmıştır. Kontrol çalışmalarında, üst ve alt ürün sıcaklıklarının set noktalarına ve besleme çözeltilisinin derişimine pozitif ve negatif etkiler verilerek üst ve alt ürün sıcaklıkları kontrol edilmiştir.

2008, 101 sayfa

Anahtar Kelimeler: Yapay sinir ağları, Çok bileşenli damıtma kolonu, MIMO kontrol

ABSTRACT

Master Thesis

MULTIVARIABLE CONTROL OF A LABORATORY – SCALE CONTINUOUS PACKED DISTILLATION COLUMN WITH A MULTICOMPONENT ALCOHOL MIXTURE USING ARTIFICIAL NEURAL NETWORKS

Fatma VAROL

Ankara University
Graduate School of Natural and Applied Sciences
Department of Chemical Engineering

Supervisor: Assoc.Prof. Dr. Süleyman KARACAN

Distillation of a multicomponent alcohol mixture was researched in a laboratory scale continuous packed distillation column. In this work, single input single output (SISO) and multi input multi output (MIMO) control of top and bottom product temperature of the column were made theoretically and experimentally. Model predictive control (MPC) algorithm based on artificial neural networks (ANN) was used for control studies. Alcohol mixture with five components consists of methanol, ethanol, n-buthanol, isoamine alcohol (1-pentanol) and anisole (methyl-phenyl ether) was distilled. A 2 L tank volume and 1 m packing height laboratory scale packed distillation column was used. Dynamic experiments were made to system identification by selecting reflux ratio and reboiler heat duty as input variables, top and bottom product temperatures as output variables. By giving positive and negative step effects to input variables, the variation of output variables with time was obtained. The transfer functions of process were obtained by using statistical model identification method from experimental data. Relative gain array (RGA) was determined to establish the best control pairing of the process. For control algorithm, ANN model of process was proposed and was trained with backpropagation algorithm. By basing on this model, MPC algorithm was obtained. In experimental control, model predictive control (MPC) algorithm based on artificial neural networks (ANN) was written at Visual Basic language. This algorithm was added to software. Control algorithm was also written in the MATLAB and used for theoretical control. In control studies, the top and bottom product temperatures were controlled by giving positive and negative step effects to set points of the top and bottom product temperatures and the concentration of feed mixture.

2008, 101 pages

Key Words: Artificial neural networks, Multicomponent distillation column, MIMO control

TEŞEKKÜR

Tez çalışmamın tüm aşamalarında değerli bilgi ve önerileriyle beni yönlendiren, her türlü konuda yardımcı olan danışman hocam sayın Doç. Dr. Süleyman KARACAN'a en derin duygularıyla teşekkür ederim.

Yüksek lisans çalışmalarım sırasında çok kıymetli bilgi ve düşüncelerini sunarak, yardımlarını esirgemeyen hocam sayın Prof. Dr. Mustafa ALPBAZ'a en içten saygı ve teşekkürleri sunmayı borç bilirim.

Çalışmalarım boyunca bana yardımlarıyla bir hoca bir arkadaş olarak destek olan Araş. Gör. Dr. Suna ERTUNÇ ve Kimya Yüksek Müh. Havva BOYACIOĞLU'na, Proses Kontrol Laboratuvarında birlikte çalıştığım değerli hocalarıma ve arkadaşlarıma çok teşekkür eder sevgilerimi sunarım.

Öğrenim hayatım boyunca maddi ve manevi desteklerini hiçbir zaman benden esirgemeyen, her türlü sıkıntıma katlanan ve her zaman yanımda olan aileme sonsuz teşekkürlerimi sunarım.

Fatma VAROL

Ankara, Şubat 2008

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
SİMGELER DİZİNİ	v
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	4
3. MATERYAL VE YÖNTEM.....	17
3.1 Laboratuvar Ölçekli Dolgulu Damıtma Kolonu	17
3.1.1 Deneysel çalışmalarda kullanılan çözelti	19
3.1.2 Deney yöntemi	20
3.2 Yapay Sinir Ağları (ANN) Temelli Model Öngörmeli Kontrol (MPC) Sistemi	20
3.2.1 İstatistiksel model tanımlama	21
3.2.2 Ziegler-Nichols ayarlama yöntemi.....	23
3.2.3 Bağlı kazanç matrisi (RGA) analizi.....	25
3.2.4 Çok girdili-çok çıktılı (MIMO) proseslerin kontrolü	30
3.2.5 Yapay sinir ağları (ANN).....	31
3.2.5.1 Yapay sinir ağı hücresi (Yapay nöron)	32
3.2.5.2 Yapay sinir ağı yapısı.....	36
3.2.5.3 Yapay sinir ağlarının çalışması.....	38
3.2.5.4 Yapay sinir ağlarının sınıflandırılması	38
3.2.5.5 Yapay sinir ağlarında eğitim algoritmaları	43
3.2.6 ANN temelli MPC	46
4. BULGULAR	49
4.1 İstatistiksel Model Tanımlama Bulguları	49
4.1.1 Geri akma oranına verilen kademe etkilerinin bulguları	50
4.1.2 Kazan ısıasına verilen kademe etkilerinin bulguları	52
4.1.3 Besleme çözeltisine verilen etkinin bulguları.....	53
4.2 Ziegler-Nichols Ayarlama Yöntemi Bulguları	54
4.3 Bağlı Kazanç Matrisi (RGA) Analizi Bulguları	56
4.4 Yapay Sinir Ağı (ANN) Bulguları.....	61
4.5 Kontrol Bulguları	65
4.5.1 Tek girdili tek çıktılı (SISO) kontrol bulguları	66
4.5.2 Çok girdili çok çıktılı (MIMO) kontrol bulguları	85
5. TARTIŞMA VE SONUÇ	98
KAYNAKLAR	99
ÖZGEÇMİŞ	101

SİMGELER DİZİNİ

B	Kazandan Çıkan Sıvı Akış Hızı, (mol/dak)
D	Üst Ürün Akış Hızı, (mol/dak)
E	Performans İndeksi
f	Nöron Transfer Fonksiyonu
F	Besleme Akış Hızı, (mol/dak)
G	İletim Fonksiyonu
G _C	Kontrol Edici İletim Fonksiyonu
G _P	Proses İletim Fonksiyonu
K	Kazanç Matrisi
K _C	Oransal Kazanç
K _U	Kontrol Edici Son Kazancı
L	Sıvı Akış Hızı, (mol/dak)
m	Ayarlanabilen Giriş Değişkeni
o	Nöron Çıktısı
Q	Kazan Isısı, (cal/dak)
R	Geri Akma Oranı
t	Zaman, (dak)
T _B	Alt Ürün Sıcaklığı, (°C)
T _D	Üst Ürün Sıcaklığı, (°C)
u	Ayarlanabilen Değişken
w	Bağlantı ağırlığı
x	Nöron Girdisi
y	Çıkış Değişkeni

Yunan Alfabesi

Σ	Nöron Toplama Fonksiyonu
θ	Ölü Zaman Değeri
τ	Zaman Sabiti
τ_I	İntegral Zaman Sabiti
τ_D	Türev Zaman Sabiti
λ	Bağıl Kazanç
Λ	Bağıl Kazanç Matrisi

Kısaltmalar

ANN	Yapay Sinir Ağları
ANNMPC	Yapay Sinir Ağı Temelli Model Öngörmeli Kontrol
CMPC	Kısıtlamalı Model Öngörmeli Kontrol
DMC	Dinamik Matris Kontrol
GC/MS	Gaz Kromatografi Kütle Spektrometresi
GPC	Genelleştirilmiş Öngörmeli Kontrol

IMC	İç Model Kontrol
ISE	Hata Kareleri İntegrali
İE	İşlemci Eleman
LVQ	Vektör Nicemleme İle Öğrenme
M	Kontrol Ufku
MIMO	Çok Girdili Çok Çıktılı
MLP	Çok katmanlı Algılayıcı
MPC	Model Öngörmeli Kontrol
NN	Sinir Ağı
P	Tahmin Ufku
P	Oransal Kontrol
PI	Oransal-Integral Kontrol
PID	Oransal-İntegral-Türev Kontrol
RGA	Bağıl Kazanç Matrisi
SISO	Tek Girdili Tek Çıktılı

ŞEKİLLER DİZİNİ

Şekil 2.1	Damıtma kolonu.....	4
Şekil 2.2	Model öngörmeli kontrol planı	5
Şekil 2.3	Tasarlanan tahmini kontrol planı	7
Şekil 2.4	ANN bloklarının iki boyutlu sırası.....	11
Şekil 2.5	Tipik bir NN bloğu.....	12
Şekil 3.1	Toplam deney düzeneği	18
Şekil 3.2	Sürekli salınımın sağlandığı son kazanç ve periyot	24
Şekil 3.3	RGA hesabında kullanılan diyagramlar a.Açık döngü, b.Yarı açık döngü...	26
Şekil 3.4	I. döngü konfigürasyonu	29
Şekil 3.5	II. döngü konfigürasyonu	29
Şekil 3.6	İki kontrol edilen ve iki ayarlanabilen değişkenli bir prosesin açık döngü blok diyagramı	31
Şekil 3.7	İki kontrol edilen ve iki ayarlanabilen değişkenli bir prosesin kapalı döngü blok diyagramı	31
Şekil 3.8	Yapay sinir ağı hücresi	33
Şekil 3.9	Adım transfer fonksiyonu	35
Şekil 3.10	Eşik transfer fonksiyonu	35
Şekil 3.11	Doğrusal transfer fonksiyonu.....	35
Şekil 3.12	Sigmoid transfer fonksiyonu	36
Şekil 3.13	Tanjant hiperbolik transfer fonksiyonu	36
Şekil 3.14	Yapay sinir ağı modeli (Yurtoğlu, 2005)	37
Şekil 3.15	İleri beslemeli çok katmanlı sinir ağı	43
Şekil 3.16	Dinamik matris kontrolünün hareket yörüngeleri	47
Şekil 4.1	Dolgulu damıtma kolonunun şematik gösterimi	50
Şekil 4.2	Geri akma oranına pozitif kademe etkisinde (1.5-4) üst ürün sıcaklığının zamanla değişimi.....	51
Şekil 4.3	Geri akma oranına negatif kademe etkisinde (1.5-0.67) üst ürün sıcaklığının zamanla değişimi.....	51
Şekil 4.4	Kazan ısisına pozitif kademe etkisinde (6-7) alt ürün sıcaklığının zamanla değişimi	52
Şekil 4.5	Kazan ısisına negatif kademe etkisinde (6-5) alt ürün sıcaklığının zamanla değişimi	52
Şekil 4.6	Besleme çözeltisine pozitif etkide (%47.56 mol Et-%58.37 mol Et) üst ürün sıcaklığının zamanla değişimi	53
Şekil 4.7	Besleme çözeltisine pozitif etkide (%47.56 mol Et-%58.37 mol Et) alt ürün sıcaklığının zamanla değişimi	53
Şekil 4.8	Dolgulu damıtma kolonunda RGA analizi için kullanılan açık-döngü blok diyagramı.....	57
Şekil 4.9	Dolgulu damıtma kolonunda RGA analizi için R'ye (u_1, m_1) pozitif kademe etkisi verildiğinde üst ürün sıcaklık değerinin (y_1) zamanla değişimi	58
Şekil 4.10	Dolgulu damıtma kolonunda RGA analizi için kullanılan MATLAB Simulink programı blok diyagramı	59
Şekil 4.11	Dolgulu damıtma kolonunda RGA analizi için m_1 etkisinde yarı açık döngü kontrol sonucu	60
Şekil 4.12	Dolgulu damıtma kolonunun modeli için tasarlanan ağ yapısının gösterimi	62

Şekil 4.13 ANN'ye girdi olarak verilen üst ürün sıcaklığının zamanla değişimi	62
Şekil 4.14 Eğitim öncesi ANN çıktısının zamanla değişimi.....	63
Şekil 4.15 Eğitim sonrası ANN çıktısının zamanla değişimi.....	63
Şekil 4.16 ANN'ye girdi olarak verilen alt ürün sıcaklığının zamanla değişimi	64
Şekil 4.17 Eğitim öncesi ANN çıktısının zamanla değişimi.....	64
Şekil 4.18 Eğitim sonrası ANN çıktısının zamanla değişimi.....	65
Şekil 4.19 Teorik olarak üst ürün sıcaklığının set noktasına pozitif kademe etkisinde üst ürün sıcaklığının zamanla değişimi (ISE=1.3051)	67
Şekil 4.20 Teorik olarak üst ürün sıcaklığının set noktasına pozitif kademe etkisinde geri akma oranındaki değişimin zamanla değişimi	67
Şekil 4.21 Teorik olarak üst ürün sıcaklığının set noktasına negatif kademe etkisinde üst ürün sıcaklığının zamanla değişimi (ISE=1.9094)	68
Şekil 4.22 Teorik olarak üst ürün sıcaklığının set noktasına negatif kademe etkisinde geri akma oranındaki değişimin zamanla değişimi	68
Şekil 4.23 Teorik olarak besleme çözeltisine pozitif etkide üst ürün sıcaklığının zamanla değişimi (ISE=1.1638)	69
Şekil 4.24 Teorik olarak besleme çözeltisine pozitif etkide geri akma oranındaki değişimin zamanla değişimi	69
Şekil 4.25 Teorik olarak besleme çözeltisine negatif etkide üst ürün sıcaklığının zamanla değişimi (ISE=4.3724)	70
Şekil 4.26 Teorik olarak besleme çözeltisine negatif etkide geri akma oranındaki değişimin zamanla değişimi	70
Şekil 4.27 Deneysel olarak üst ürün sıcaklığının set noktasına pozitif kademe etkisinde üst ürün sıcaklığının zamanla değişimi (ISE=1.3961)	71
Şekil 4.28 Deneysel olarak üst ürün sıcaklığının set noktasına pozitif kademe etkisinde geri akma oranının zamanla değişimi	71
Şekil 4.29 Deneysel olarak üst ürün sıcaklığının set noktasına negatif kademe etkisinde üst ürün sıcaklığının zamanla değişimi (ISE=15.0967)	72
Şekil 4.30 Deneysel olarak üst ürün sıcaklığının set noktasına negatif kademe etkisinde geri akma oranının zamanla değişimi	72
Şekil 4.31 Deneysel olarak besleme çözeltisine pozitif etkide üst ürün sıcaklığının zamanla değişimi (ISE=11.3977)	73
Şekil 4.32 Deneysel olarak besleme çözeltisine pozitif etkide geri akma oranının zamanla değişimi.....	73
Şekil 4.33 Deneysel olarak besleme çözeltisine negatif etkide üst ürün sıcaklığının zamanla değişimi (ISE=3.5095)	74
Şekil 4.34 Deneysel olarak besleme çözeltisine negatif etkide geri akma oranının zamanla değişimi.....	74
Şekil 4.35 Teorik olarak alt ürün sıcaklığının set noktasına pozitif kademe etkisinde alt ürün sıcaklığının zamanla değişimi (ISE=1.9026)	75
Şekil 4.36 Teorik olarak alt ürün sıcaklığının set noktasına pozitif kademe etkisinde kazan ısısındaki değişimin zamanla değişimi	75
Şekil 4.37 Teorik olarak alt ürün sıcaklığının set noktasına negatif kademe etkisinde alt ürün sıcaklığının zamanla değişimi (ISE=2.8294)	76
Şekil 4.38 Teorik olarak alt ürün sıcaklığının set noktasına negatif kademe etkisinde kazan ısısındaki değişimin zamanla değişimi	76
Şekil 4.39 Teorik olarak besleme çözeltisine pozitif etkide alt ürün sıcaklığının zamanla değişimi (ISE=6.2611)	77

Şekil 4.40 Teorik olarak besleme çözeltisine pozitif etkide kazan ısısındaki değişimin zamanla değişimi.....	77
Şekil 4.41 Teorik olarak besleme çözeltisine negatif etkide alt ürün sıcaklığının zamanla değişimi ($ISE=0.3193$).....	78
Şekil 4.42 Teorik olarak besleme çözeltisine negatif etkide kazan ısısındaki değişimin zamanla değişimi.....	78
Şekil 4.43 Deneysel olarak alt ürün sıcaklığının set noktasına pozitif kademe etkisinde alt ürün sıcaklığının zamanla değişimi($ISE=10.6827$)	79
Şekil 4.44 Deneysel olarak alt ürün sıcaklığının set noktasına pozitif kademe etkisinde kazan ısısının zamanla değişimi	79
Şekil 4.45 Deneysel olarak alt ürün sıcaklığının set noktasına negatif kademe etkisinde alt ürün sıcaklığının zamanla değişimi($ISE=33.9190$)	80
Şekil 4.46 Deneysel olarak alt ürün sıcaklığının set noktasına negatif kademe etkisinde kazan ısısının zamanla değişimi	80
Şekil 4.47 Deneysel olarak besleme çözeltisine pozitif etkide alt ürün sıcaklığının zamanla değişimi($ISE=0.6397$).....	81
Şekil 4.48 Deneysel olarak besleme çözeltisine pozitif etkide kazan ısısının zamanla değişimi	81
Şekil 4.49 Deneysel olarak besleme çözeltisine negatif etkide alt ürün sıcaklığının zamanla değişimi($ISE=1.2239$).....	82
Şekil 4.50 Deneysel olarak besleme çözeltisine negatif etkide kazan ısısının zamanla değişimi	82
Şekil 4.51 Teorik olarak üst ve alt ürün sıcaklıklarının set noktalarına pozitif kademe etkisinde üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B=4.0805$, $ISE_D=2.0308$)	85
Şekil 4.52 Teorik olarak üst ve alt ürün sıcaklıklarının set noktalarına pozitif kademe etkisinde geri akma oranındaki değişimin ve kazan ısısındaki değişimin zamanla değişimi.....	86
Şekil 4.53 Teorik olarak üst ve alt ürün sıcaklıklarının set noktalarına negatif kademe etkisinde üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B= 4.0903$, $ISE_D= 3.8400$)	86
Şekil 4.54 Teorik olarak üst ve alt ürün sıcaklıklarının set noktalarına negatif kademe etkisinde geri akma oranındaki değişimin ve kazan ısısındaki değişimin zamanla değişimi.....	87
Şekil 4.55 Teorik olarak besleme çözeltisine pozitif etkide üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B= 1.2164$, $ISE_D= 0.6983$).....	87
Şekil 4.56 Teorik olarak besleme çözeltisine pozitif etkide geri akma oranındaki değişimin ve kazan ısısındaki değişimin zamanla değişimi.....	88
Şekil 4.57 Teorik olarak besleme çözeltisine negatif etkide üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B= 0.1345$, $ISE_D= 0.3136$)	88
Şekil 4.58 Teorik olarak besleme çözeltisine negatif etkide geri akma oranındaki değişimin ve kazan ısısındaki değişimin zamanla değişimi.....	89
Şekil 4.59 Deneysel olarak üst ve alt ürün sıcaklıklarının set noktalarına pozitif kademe etkisinde üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B=8.0964$, $ISE_D=8.2993$).....	90
Şekil 4.60 Deneysel olarak üst ve alt ürün sıcaklıklarının set noktalarına pozitif kademe etkisinde geri akma oranının ve kazan ısısının zamanla değişimi.....	90

Şekil 4.61 Deneysel olarak üst ve alt ürün sıcaklıklarının set noktalarına negatif kademe etkisinde üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B=39.1940$, $ISE_D=27.4309$)	91
Şekil 4.62 Deneysel olarak üst ve alt ürün sıcaklıklarının set noktalarına negatif kademe etkisinde geri akma oranının ve kazan ısının zamanla değişimi.....	92
Şekil 4.63 Deneysel olarak besleme çözeltisine pozitif etkide üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B=1.4130$, $ISE_D=3.2365$).....	92
Şekil 4.64 Deneysel olarak besleme çözeltisine pozitif etkide geri akma oranının ve kazan ısının zamanla değişimi	93
Şekil 4.65 Deneysel olarak besleme çözeltisine negatif etkide üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B=1.8812$, $ISE_D=1.6438$).....	93
Şekil 4.66 Deneysel olarak besleme çözeltisine negatif etkide geri akma oranının ve kazan ısının zamanla değişimi	94

ÇİZELGELER DİZİNİ

Çizelge 3.1 Laboratuvar ölçekli dolgulu damıtma kolonunun fiziksel özellikleri.....	19
Çizelge 3.2 Karışımdaki bileşenler ve mol yüzdeleri	19
Çizelge 3.3 Ziegler-Nichols Ayarlama Yöntemi (Stephanopoulos 1984)	25
Çizelge 4.1 Dolgulu damıtma kolonunun iletim fonksiyonları ve PID parametreleri	56
Çizelge 4.2 Kontrol deneylerinde kullanılan besleme çözeltilerinin bileşimleri	66
Çizelge 4.3 Besleme çözeltisine pozitif kademe etkisi verildiğinde üst ve alt ürünlerin GC/MS sonuçları.....	83
Çizelge 4.4 Üst ürün sıcaklığının set noktasına negatif basamak etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları	84
Çizelge 4.5 Alt ürün sıcaklığının set noktasına pozitif basamak etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları	84
Çizelge 4.6 Üst ve alt ürün sıcaklıklarının set noktasına pozitif basamak etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları	95
Çizelge 4.7 Üst ve alt ürün sıcaklıklarının set noktasına negatif basamak etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları	95
Çizelge 4.8 Besleme çözeltisine pozitif kademe etkisi verildiğinde üst ve alt ürünlerin GC/MS sonuçları.....	96
Çizelge 4.9 Besleme çözeltisine negatif kademe etkisi verildiğinde üst ve alt ürünlerin GC/MS sonuçları.....	97

1. GİRİŞ

Damıtma, bir sıvı karışımının ısı yardımı ile buhar haline dönüştürülmesi ve buharın da yoğunlaştırılarak sıvı hale dönüştürülmesi ile gerçekleştirilen bir ayırma yöntemidir. Damıtma, kimya ve petrol endüstrisinde en çok kullanılan ayırma yöntemlerinden biridir. Bir damıtma işlemi besleme karışımının durumuna göre ikili ve çok bileşenli olarak sınıflandırılabilir. Ticari damıtmanın hemen hemen hepsi çok bileşenli damıtma üzerinedir.

Damıtma kolonları işletim türüne göre sürekli ve kesikli, kolon tipine göre de dolgulu ve kademeli olarak ikiye ayrılmaktadır. Dolgulu kolonların küçük fakat sürekli temas alanları gerektiren sıvı-gaz temas sistemlerinde, özellikle de absorpsiyon ve damıtma işlemlerinde yoğun kullanım alanları bulunmaktadır. Kademeli kolonlara kıyasla daha düşük yatırım gerektirirler. Dolgulu kolon kullanılması ile ısı kayıplarının giderilmesi ve ayırım bakımından en uygun işletim şartları sağlanabilmektedir.

Çok bileşenli damıtmanın teorisi ve pratiği oldukça karmaşıktır. Literatürde çoğunlukla çok bileşenli kademeli kolonların kontrolü üzerine çalışmalar yoğunlaşmıştır ve ürün derişimlerinin kontrolü zor ve pahalı olduğundan onun yerine sıcaklık kontrolü yapılmaktadır.

Dolgulu damıtma kolonu doğrusal olmayan işletim özelliklerine sahiptir, üst ürün ile alt ürün arasındaki etkileşim nedeni ile dolgulu damıtma kolonun denetimi oldukça güçtür. Bu nedenle kontrol tasarımının yapılabilmesi için sistemin dinamik davranışının bilinmesi gerekmektedir. Damıtma kolonlarının en önemli özelliklerinden biri zaman gecikmeli yapılarıdır. Dinamik davranışını belirlemek amacıyla girdi değişkenlerine değişik etkiler verilerek çıkış değişkenin zamanla değişimi gözlenir. Bunun için basamak, ani darbe, sinüs ve rastgele etkileri verilerek dinamik davranışı belirlenir. Sistemin dinamik davranışı belirlendikten sonra prosesin kontrolü yapılabilir.

Damıtma kolonlarının kontrolü, kontrol değişkenleri ile çıkış değişkeni arasındaki ilişki doğrusal olmamasından dolayı oldukça zordur. Bu nedenle birçok kontrol yöntemi

kullanılmaktadır. Bunlardan bazıları: PI, PID, IMC, MPC, Bulanık Mantık vb.

Son yıllarda algoritma veya kural bazı gerektirmeyen, çoğu durumda zorunlu yazılım uzunluğunu önemli derecede azaltan yeni bir bilgi işleme şekli ortaya çıkmıştır. Nöral hesaplama denilen bu yaklaşım şekli, sensör işlevleri, şekil tanıma, veri analizi ve kontrolü gibi sahalardaki bazı özel problem tiplerine, algoritması veya kuralları bilinmeyen ya da bilinse de, bunları tasarlayacak yazılımların çok pahalı, zaman alıcı veya uygun olmadığı durumlarda veri işleme yeteneğini artırmıştır. Nöral hesaplamanın ilgilendiği temel bilgi işleme yapıları yapay sinir ağlarıdır. Yapay sinir ağları (ANN), insan beyninin öğrenme tarzından esinlenerek geliştirilmişlerdir. Mühendislik bakış açısından ANN, özellikle girdi-çıkı bilgisi göstermede, zaman sürecinde tahminler yapmada, verileri ayırmada, örnekleri tanımada faydalı, doğrusal olmayan deneysel bir model olarak düşünülebilir. ANN'nin geniş bir uygulama alanı bulmasındaki başlıca nedenler, onun yeni bilgileri öğrenerek girdiler ve çıktılar arasındaki yapısal bir ilişkiye gereksinim olmaması ve çoklu değişkenli sistemlerde kullanılabilmesidir. Son yıllarda model öngörmeli kontrol (MPC) sisteminin ANN'ye dayalı uygulaması değişik kimyasal prosesler için başarılı bir şekilde yapılmıştır. MPC algoritması özellikle ölü zamanlı ve çok değişkenli prosesler için oldukça çekici bir özelliğe sahiptir. Bu tür proseslerin kontrolünde oldukça etkilidir.

Çalışmada, çok bileşenli alkol karışımından saf etil alkol üretimi için laboratuvar ölçekli bir dolgulu damıtma kolonunun üst ve alt ürün sıcaklıklarının yapay sinir ağları ile çok değişkenli kontrolü yapılmıştır. Kolonun çok değişkenli kontrolü, ANN temelli MPC algoritması ile teorik ve deneysel olarak gerçekleştirilmiştir. Kontrol esnasında, kontrol edilen değişken olarak üst ve alt ürün sıcaklıkları, ayarlanabilen değişken olarak ise geri akma oranı ve kazana verilen ısı miktarı seçilmiştir.

Deneysel çalışmalarda, 2 L kazan hacmi ve Rasching halkalarıyla doldurulmuş 1 m lik dolgu boyu olan, laboratuvar ölçekli bir dolgulu damıtma kolonu kullanılmıştır. Kolonda damıtılan çok bileşenli alkol karışımı metanol, etanol, n-bütanol, isoamil alkol (1-pentanol), anisol (metil-fenil eter)den oluşmaktadır. Bu karışımdan etanolün ayrılması amaçlanmıştır. Öncelikle dinamik deneyler yapılarak kolonun dinamiği

gözenmiştir. Kolonun girdi değişkenlerine (geri akma oranı ve kazana verilen ısı miktarı) pozitif ve negatif etkiler verilerek çıkış değişkenleri (üst ve alt ürün sıcaklıkları)nin zamanla değişimi elde edilmiştir.

Dinamik deneylerin verileri kullanılarak, istatistiksel model tanımlama yöntemiyle prosesin iletim fonksiyonları bulunmuştur. Kolondaki etkileşimleri görmek amacıyla Bağlı Kazanç Matrisi (RGA) analizi yapılmıştır ve buna göre kullanılacak kontrol çiftleri belirlenmiştir. Dinamik veriler kullanılarak kolonun ANN modeli tasarlanmıştır. Tasarlanan model geri yayılım algoritması ile eğitilmiştir. Eğitimden sonra elde edilen ANN, çok girdili çok çıktılı (MIMO) MPC algoritmasının temelinde kullanılmıştır.


Kolonun deneysel kontrolü için, ANN temelli MPC algoritması deney sistemindeki bilgisayara eklenmiştir. Üst ve alt ürün sıcaklıklarının set noktalarına, besleme çözeltisinin derişimine pozitif ve negatif etkiler verilerek, üst ve alt ürün sıcaklıklarının tek girdili tek çıktılı (SISO) ve MIMO kontrolü yapılmıştır.

Teorik kontrol çalışmalarında ise, ANN temelli MPC algoritması ile MATLAB ortamında çalışılmıştır. Deneysel kontrolde kolona verilen etkiler teorik kontrolde de kullanılarak, üst ve alt ürün sıcaklıklarının SISO ve MIMO kontrolü yapılmıştır.

2. KAYNAK ÖZETLERİ

Brizuela *et al.* (1996) çok bileşenli damıtma kolonunun sinir ağları temelli öngörmeli kontrolü için çalışmışlardır. Üç bileşenli damıtma kolonunun üst ürün ve alt ürün bileşimlerinin kontrolü için öngörmeli plan verilmiştir. Gelecekteki çıktılarının tahmini için, ileri beslemeli sinir ağları (FNN) kullanan prosesin doğrusal olmayan modeli yerine getirilmiştir. Tasarlanan sinirsel-öngörmeli-kontrol stratejisinin birçok alternatifini kullanan kolon işletmesi, farklı düzensizlikler altında analizlenmiştir. Sistem davranışı, oransal-integral (PI) kontrol edilen tesisin davranışı ile karşılaştırılmıştır.


Bu çalışmada hesaba katılan sistem, dokuz kademeli, bir kaynatıcı, bir kısmi yoğunlaştırucu ve bir sabit holdup tanklı üç bileşenli damıtma kolonudur (Şekil 2.1).



Şekil 2.1 Damıtma kolonu

Model öngörmeli kontrol (MPC) edicilerin ana amacı; gelecekteki proses çıktılarından istenilen set noktalarından sapmalarının fonksiyonu olan değer indeksini en aza indiren, kontrol sinyallerinin sıralanışını oluşturmaktır. Bu amacı başarması gereken kontrol sinyallerini hesaplamak amacıyla, tesis çıktılarından tahminleri hesaplanmalıdır.

Şekil 2.2’de genel bir model öngörmeli kontrol edici tasarısı gösteriliyor.



Şekil 2.2 Model öngörmeli kontrol planı

Öngörmeli kontrol edicileri tamamlamak için sık sık kullanılan bir algoritma; bu amacı gerçekleştirmek için gerekli olan kontrol sırasından uygun değeri alırken, gelecekteki çıktının istenilen set noktalarındaki sapmalarını en aza indirendir.

$$J = \sum_{i=n_1}^{n_2} [y_r(t+i) - y_p(t+i)]^2 + \sum_{j=1}^{n_u} \lambda_j [u(t+j-1) - u(t+j-2)]^2 \quad (2.1)$$

burada:

- $y_r(t+i)$; $t+i$ anındaki referans sinyal
- $y_p(t+i)$; $t+i$ anındaki kontrol edilen çıktı
- $u(t)$; t anındaki ayarlanabilen girdi (kontrol sinyali)
- λ_j ; ayarlanabilen girdideki aşırı değişimleri yok eden ağırlık sabitidir. $\lambda_j=0$ için; kontrol sinyali, J indeksinin en aza indirilmesi için gerekli olduğu kadar fazla ve hızlı değişecektir diye bu değişimler üzerine sınırlama konmaz


- $n_2 > n_1$; n_1, n_2 değerlerinin çifti, iz hatalarının hesaba katıldığı zaman aralığına uygun tahmin ufkunu tanımlar
- n_u ; kontrol ufku, kontrol artışlarının hesaba katılması aracılığıyla zaman aralığını tanımlar.

Damıtma kolonunun çalışmasının otomasyonu için; sırasıyla alt ürün bileşimi ve üst ürün bileşimini kontrolü amacıyla ayarlanabilen değişkenler olarak kaynatıcı ısı vana pozisyonu $u_1(t)$ ve yoğunlaştırucu sıcaklığını $u_2(t)$ seçeriz. t anında 1 devresi için tesisin kontrol edilen çıktısı $y_{p,1}(t)$ hesaba katılır, kontrol edilen değişkenler:

- Alt ürünlerdeki ağır bileşen konsantrasyonu ($y_{p,1}$)
- Üst ürünlerdeki ağır bileşen konsantrasyonu ($y_{p,2}$)dur.

Temel diyagram ve tasarlanan öngörmeli kontrol stratejisinin şematik bir diyagramı Şekil 2.3'te gösterilir.

Dıştaki kontrol hattı, kontrol hata sinyallerini elde etmek için sinir ağından tesisin çıktılarının tahminlerini kullanır. Sonra, sisteme uygulanan kontrol sinyallerinin hesaplanmasına rehberlik eden, değer indeksinin en aza indirilmesi yapılır. Tahmin prosesi için kullanılan geçmişteki tesis çıktılarıyla birlikte sinir ağını tamamlamak amacıyla, tahmin devresi kullanılır.



Şekil 2.3 Tasarlanan tahmini kontrol planı

Optimizasyon aşağıdaki değer fonksiyonunu en aza indirir:

$$J = \sum_{l=1}^{N_L} \left\{ \sum_{i=n_1}^{n_2} \left[y_{r,l}(t+i) - \hat{y}_{p,l}(t+i) \right]^2 + \sum_{j=1}^{n_u} \lambda_{j,l} [u_l(t+j-1) - u_l(t+j-2)]^2 \right\} \quad (2.2)$$

burada:

- N_L kontrol devresinin sayısı (= 2 bu çalışma için)dır.

Biri üst ürün için ve diğeri alt ürün için olan iki farklı kontrol tasarısı tamamlanır.

Herhangi bir kontrol sisteminin istenilen bir özelliği, sıfır hatalı yatışkın hali başarmaktır. Tasarlanan plandan dolayı; kontrol proses modelinden elde edilen gelecekteki çıktılar tahmini üzerine kurulur, düzensizlikler ve tesis-model hatalı

eşleşmesi yüzünden off-setler meydana gelebilir. Her bir örnekleme anında hesaplanabilen model ve proses cevabı arasındaki fark, İç Model Kontrol (IMC)'ün genel kavramıdır.

Sinir ağı, sistemin aşağıdaki 14 hal değişkeni (ağ çıktıları) hesaplar:

- Üst üründeki üç bileşenin akışı (F_{top}), sıcaklığı (T_{top}) ve konsantrasyonu (X_{top}^i)
- Alt üründeki üç bileşenin akışı (F_{bot}), sıcaklığı (T_{bot}) ve konsantrasyonu (X_{bot}^i)
- Yanakım ürünündeki üç bileşenin akışı sıcaklığı (T_{side}) ve konsantrasyonu (X_{side}^i), akış hızı F_{side} nin sabit olduğu düşünülür.

Ağa girdi değişkenleri olarak; besleme hızı (F_{in}), kaynatıcı vana açıklığı (A) ve yoğuşturucu sıcaklığı (T_c) ve iki önceki örnekleme zamanındaki tüm çıktı değerleri tanıtılır. Bu, 31 girdi değişkenin toplamını verir.

Ağ için eğitim verisinin (girdi-çıkıtı ikilileri) üretilmesi amacıyla kolonun, başlangıç durumundan aşağıdaki girdi değişkenlerine karşılık gelen yatışkın işletme haline kadar çalıştırılması süresince benzetimi yapılmıştır:

- $F_{in} = 25$ mol/dak (girdi akış hızı)
- $A = 0.308$ (kaynatıcı ısı vanası açıklığı)
- $T_c = 76$ °C (kısmi yoğuşturucu sıcaklığı).

Bir, iki ve üç tane gizli tabaka ve bu tabakalardaki farklı bağlantı noktaları sayısı (20 ve 160 arasında) için farklı testler yapılmıştır. En iyi ağ yapısı; 50 nöron içeren bir gizli tabaka olarak bulunmuştur.

Kumpati *et al.* (1997) bu makalede, NARMA model yaklaşımında iki tür model tanıtılmıştır. Modellerde kontrol girdisi doğrusal kabul edilmiştir. Bu teorik kontrol

alışmalarını basite indirgemiřtir. Kapsamlı benzetim alışmaları, önerilen yaklaşım modellerini kullanarak tasarlanan sinirsel kontrol edicilerin ok iyi kontrol yaptığını göstermiřtir. Birok durumda tam NARMA modeli kullanarak tasarlanan yaklaşık kontrol ediciden daha iyi olduđu anlařılmıştır.

Dutta and Russel-Rhinehart (1999) bu alışmada sinir ağını kullanan yeni bir yöntemi deneysel olarak göstermiřtir. Yöntemde proses kontrolü için kazanç tahmininde doğrusal olmayan, ok deęişkenli ve kısıtlama kolaylığı olan sinir ağı kullanılmıştır. Yöntem laboratuvar ölçekli, ideal olmayan, metanol-su damıtma kolonunun ‘servo’, ‘regulator’ ve kısıtlamalı kontrolüne uygulanmıştır. Deneysel sonuçlar, sinir ağı kullanan Genelleřtirilmiş Model Kontrol Edici (GMC) ile gösterilmiştir. Bu sinir ağı model temelli kontrol edicinin dięer gelişmiş kontrol edicilerle (örneğin; Doğrusal Olmayan Proses Modeli Kontrol, Dinamik Matris Kontrol kullanan Model Öngörmeli Kontrol (DMC) ve Gelişmiş Klasik Kontrol) karşılaştırılması da yapılmıştır.


Hagan *et al.* (2002) sinir ağlarını ve sinir ağlarının kontrol sistemlerinde nasıl kullanıldıklarını açıklamayı amaçlamışlardır. ok katmanlı algılayıcı sinir ağı (MLP) tanıtılmıştır ve tahmin fonksiyonu için nasıl kullanıldığı tanımlanmıştır. ok katmanlı algılayıcıların eğitimi için başlıca yöntem olan geri yayılım algoritması özet olarak tanımlanmıştır. alışmada bir sürekli karıştırmalı tank reaktöre, model referans uyarlamalı kontrol, model öngörmeli kontrol ve geribeslemeli doğrusal kontrol uygulanmıştır. Bu kontrol ediciler, temel yapı blokları olarak kullanılabilen ok katmanlı algılayıcı sinir ağlarındaki yöntem türlerini göstermiştir.

Chu *et al.* (2003) bu alışmada farklı modellerin ok adımlı model öngörmeli kontrol (MMPC) performansı üstüne etkisini incelemiřlerdir. alışma için benzetim örneklerinden ve tezgah ve pilot ölçekte yapılan deneylerden yararlanılmıştır. alışmada model olarak da yapay sinir ağlarının iki genel türü ileri beslemeli ağlar ve yinelemeli ağlar kullanılmıştır. Tahmin ufku kontrol ufkundan uzun olduđu taktirde, benzetim durumları ve deneyler için, FFN modelini kullanan MMPC’de offset gözlenmiştir. alışmanın deneysel kısmında, laboratuvar ölçekli etanol-su damıtma kolonundaki ve pilot ölçekli i-bütan ve n-bütan damıtma kolonundaki ikili sıcaklık

problemleri için, iki ANN modelini kullanan MMPC'lerin performansları, PI kontrol ediciler ve doğrusal model öngörmeli kontrol karşılaştırılmıştır.

Rad (2004), çoklu sinir ağlarının bir kombinasyonu seçmiş ve zaman gecikmeli doğrusal olmayan çok girdili çok çıktılı (MIMO) proseslerin modellenmesinde kullanmıştır. Sonra bir doğrusal olmayan MPC algoritması için bu model üzerinde kurulan bir optimizasyon yöntemini geliştirmiştir. Kurduğu planı, çok bileşenli damıtma kolonun MPC'sini içeren iki problem için uygulamıştır ve hesaplamıştır.


Bu çalışmada ilk olarak, sinir ağlarının birleştirmek için yöntem verilmiştir. Bir tek ANN model, proses çıktılarını tahmin etmek için kullanılabilir. Yine de bu model veri takımı ve tahmini hata artışlarından, konuyla ilgili tüm bilgilerin elde edilmesi için yeterli olmayabilir. Bu yüzden gelecek tahminlerinin doğruluğunun en yüksek derecede olması için, sistem modelinde çoklu ANN'den yararlanılmıştır. Çoklu ANN'nin bir kombinasyonu M girdili N çıktılı doğrusal olmayan dinamik bir sistemi modellemek için kullanılmıştır. Şekil 2.4'de gösterildiği gibi, tasarlanan sistem NN bloklarının iki boyutlu sıralarından oluşur. MIMO sistemin her bir y_j çıktısını göstermek için tanımlanan her blok bir adım ilerideki tahmini nöron modeli, NN_j 'den oluşur. Bu yüzden her bir blok, tüm MIMO sistemin çok girdili tek çıktılı (MISO) bir alt bölümünü gösterir. j. sıradaki bütün bloklar benzer model olarak NN_j 'den yaranır. Bu modeller, P zaman adımlarının tahmin ufku aralığındaki y_j çıktısının gelecek çıktısını tahmin etmek için kurulur.



Şekil 2.4 ANN bloklarının iki boyutlu sırası

Sinirsel modeller, bir gizli tabaka içeren çok tabakalı ileri beslemeli ANN'lerdir. Gizli tabaka 10 nöron içerir. Gizli tabakadaki nöronlar içim aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu kullanılmıştır. Her bir ağın tek çıktı noktası (boğumu) için doğrusal aktivasyon fonksiyonu kullanılmıştır. Şekil 2.5, bu sistemde kullanılan tipik bir NN bloğunun ayrıntılarını gösterir. Bu şekilde gösterildiği gibi, her bir proses girdisi u_i nin ve her bir proses çıktısı y_j nin geçmiş ve şimdiki modelleri ağ için girdi olarak kullanılmıştır.

İkinci olarak, bir MPC optimizasyon algoritması kullanılarak kurulan model tanımlanmıştır. Son olarak kurulan modelin performansı iki örnek için uygulanmasıyla gösterilmiştir.



Şekil 2.5 Tipik bir NN bloğu

Birinci örnek, aşağıdaki eşitlikle tanımlanan basit iki girdili-iki çıktılı dinamik prosesi içerir. Bu çalışma yardımcıdır; çünkü gerçek proses bilinen verilerin temelini oluşturur ve böylece kurulan tasarı sonucunun doğruluğu kanıtlanabilir.

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} 0.4e^{-s}/(10s+1) - 0.6e^{-4s}/(25s+1) \\ 0.3e^{-3s}/(20s+1) - 0.7e^{-2s}/(15s+1) \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} \quad (2.3)$$

Daha önce açıklanan çoklu sinir ağları, Eşitliğin dinamiklerini öğrenmek için seçilmiştir. Eğitilen ağ ile tahmin ufku $P=7$ ve kontrol ufku $M=7$ olarak önerilen doğrusal olmayan optimizasyon algoritması, basit MIMO prosesin kontrolü için uygulanmıştır. Sistem sonra set noktası değişimlerine tabi tutulmuştur.

İkinci örnekte, çok bileşenli damıtma kolonunda çalışılmıştır. Kolon, tabaka verimi 0.5 olan 18 tabakaya sahiptir. Bu, alt kademe ile 9 denge kademesinden oluşan bir kolon meydana getirir. Buhar kolona beslemek için dördüncü kademenin altından girecektir ve üç bileşenli bir karışımdan oluşmaktadır. Sıvı tarafı akımı beşinci kademedan ayrılacaktır. Sistem, bir kısmi yoğunlaştırucu ile üstte bir geri akım ayar cihazına ve altta kazana sahiptir.

Kolonun ilk olarak, doğrusal modeli elde edilmiştir. Bunun için dinamik deneyler yapılmıştır. Deneylerden elde edilen verilerinden, MATLAB'ın sistem tanımlama kısmı yardımıyla kolonun doğrusal modeli oluşturulmuştur.

İkinci olarak ise, daha önce anlatılan çoklu ANN kullanılarak kolonun sinirsel modeli elde edilmiştir. Sinirsel modelinin oluşturulması için gereken veriler için de kolon, farklı geri döngü akımı oranlarında ve buhar hızlarında işletilmiştir. Ağın eğitimi sırasıyla ayarlanabilen değişkenler L ve V için yapılmıştır.

Kolon için doğrusal ve sinirsel model elde edildikten sonra, her iki model MPC ile kontrol edilmiştir.

Kolonun doğrusal modellenli MPC kullanarak yapılan kontrolü için, kolon set noktası değişimlerine tabi tutulmuştur. Bu deneyler sırasında, tahmin ufku P dörtte sabitlenir ve kontrol ufku M'nin değeri 1'den 4'e değiştirilmiştir. M'nin farklı değerleri için performans kriterinin hesaplanmasıyla kontrol kalitesi değerlendirilmiştir. Hata kareleri toplamı (ISE) anahtar ölçüm olarak kullanılmıştır. Sonuçlara bakıldığında, M=4 değerli kontrol edicinin yüksek kaliteli bir performansa sahip olduğu görülmüştür. Ama gerçek kontrolde M'nin yüksek bir değeri daha fazla dinamik hareketler verebilir ve kararlılık problemleri doğabilir. Bu yüzden, M için düşük bir değer seçilmelidir.

Kolonun sinirsel modellenli MPC kullanarak yapılan kontrolü için de yine, kolonda set noktası değişimleri yapılmıştır ve P dörtte sabitlenerek M'nin değeri 1'den 4'e değiştirilmiştir. Kontrolde elde edilen sonuçlar performans indeks değerlerine göre karşılaştırıldığında; sinir modeli kullanan MPC algoritmasından elde edilen cevabın doğrusal modeli kullananından elde edilenden daha kaliteli olduğu görülmüştür. Ayrıca sinir modeli kullanan MPC'de azalan M ayarlanabilen değişkenlerdeki küçük değişimlerle sonuçlanmıştır. Proses doğrusal olmayan bölgede işletilmez ve aslında proses modeli benzetimlerin uygulandığı aralık içinde doğrusaldır. Bununla birlikte, MPC'de M'nin küçük değerleri proses-model uyumsuzluğunda sağlamlığa neden olur. Bu yüzden, böyle durumlarda daha doğru bir model kullanmanın etkisi hiçbir şeye değmeyebilir.

Sharma *et al.* (2004) bu çalışmada yapay sinir ağlarını, amonyak-su dolgulu damıtma kolonunda hata teşhis aleti olarak kullanmışlardır. Geri yayılım algoritması kullanan ağ ile öğrenme için, girdiler (sensör ölçümleri) ve çıktılar (hatalar) arasındaki korelasyonları gösteren bağlantı kuvvetleri yapılmıştır. İlk olarak, hata karesinin aritmetik ortalamasının ve yaklaşık yüzde hatanın aritmetik ortalamasının minimum kökü ve Pearson korelasyon sabitinin (C_p) bir maksimum değeri üzerine kurulan 6-4-6 (hal değişkenlerine uyan altı girdi bağlantı noktası ve altı aksaklığa uyan altı çıktı bağlantı noktası) ağ mimarisi seçilmiştir. Öğrenme hızı, momentum ve kazanç terimlerinin değerleri sırasıyla 0.8, 0.8 ve 1.0 olarak alınmıştır. Ağ ile gösterilen hataların bulunması başarılı olmuştur. Çeşitli girdi değişkenlerinin çıktı değişkenlerine bağlı önemi; besleme hızındaki gürültüler, verilen aralıktaki besleme bileşimi ve buhar hızı ile çok etkilenmeyen dip sıcaklıklarını, tepe bileşimini ve tepe sıcaklığını gösteren bağlantı ağırlıklarının ayrılması üzerine kurularak hesaplanmıştır. Bu, hesaplamaların sayısının azaltılması suretiyle 6-4-6 ile benzer yetenekli basitleştirilmiş bir 3-4-6 ağ mimarisi elde edilmiştir.

Fabro *et al.* (2005) bu çalışmada sürekli bir damıtma kolonun çalıştırılmasının benzetimi için bir akıllı öngörmeli kontrol edicinin geliştirilmesini önermişlerdir. Kontrol hareketlerinin uygulandığı sistem üzerine kurulan, prosesin davranışı hakkında tahminler sağlayan yinelemeli sinir ağları proses tanımlama için kullanılmıştır. Bu bilgiler sonra, daha iyi bir kontrol performansını başarmak için bulanık mantık kontrol edicilerde kullanılmıştır.

Kontrol edilen değişkenler arasındaki birleştirmenin sinir ağları ile modellendiği farklı bulanık mantık kontrol edicilerle, kullanan çok değişkenli proseslerin kontrolü sağlanmıştır.

Gadkar *et al.* (2005) maya fermantasyonunda besleme katma dinamiklerini takip etmek için, yinelenen sinir ağı geliştirmişlerdir. Çeşitli işletme şartlarında hesaplama için yalnızca eritilmiş oksijen ölçümlerini kullanan sinir ağı, on-line olarak uyarlanmıştır. Sistemin diğer durumları yani, substrat, etanol ve biyokütle konsantrasyonları ölçülmemiştir ama uyarlanmış ağ ile öngörülmüştür. Sinir ağı, geribeslemeli 10-8-4 ağ

mimarisi sahip olarak tasarlanmıştır. Sinir ağına ağırlıkların online uyarlamalı ve uyarlamasız performanslarının karşılaştırması yapılmıştır. Maya fermentasyon prosesinin kontrolünde ağıın tamamlanmasında online uyarlamanın kolaylıklar sağladığı görülmüştür.

Singh *et al.* (2005) bu çalışmada, üst ürün bileşimini tahmin etmek için yapay sinir ağları temelli bir tahmin edici önermişlerdir. Optimum zamanda en iyi sonuçları elde etmek amacıyla çeşitli değişkenlerin kontrolü birleştirilmiştir. Bu yüzden, her bir seçilen algoritma için tüm istenilen değişkenleri ve kontrol hareketlerinin (ileri belleme, geribesleme, dolaylı) yapılışı izlenmiştir. Geliştirilen tahmin edici test edilmiştir ve sonuçlar karşılaştırılmıştır. Sonuçlar, sinir ağı ile yapılan tahminlerin benzetim sonuçları ile iyi bir uyuşma içinde olduğunun göstermiştir.

Bahar *et al.* (2006) damıtma kolonlarının kontrolünde, on-line bileşim ölçümleri sorunlar meydana getirdiği için, sıcaklık ölçümlerinden bileşim tahmini yapmayı amaçlamışlardır. Çalışmada, damıtma kolonu olarak Türkiye’de rafineride kullanılan C₃-C₄ ayırıcı kolonunu seçmişlerdir. Kolon propan, i-bütan, n-bütan ve i-pentan karışımından üst üründe % 96.05 saflıkta propan, alt üründe de % 62.56 saflıkta n-bütan elde etmek için tasarlanmıştır. 32 kademedan oluşan kolonda, üst ürün bileşimini için 10., 11. ve 12. kademe sıcaklıkları, alt ürün bileşimi için ise 30., 31. ve 32. kademe sıcaklıkları on-line olarak ölçülmüştür. On-line sıcaklık ölçümlerinden ürün bileşimlerini tahmin etmek için, yatışkın olmayan hal kolon benzetimi kullanılarak Yapay Sinir Ağı (ANN) ve Sinirsel-Bulanık Mantıklı Sonuçlandırma Sistemi (ANFIS) olmak üzere iki durum tahmin edici geliştirilmiş ve test edilmiştir. Çalışmada birinci tabakada 36, ikinci tabakada 12 nöron olan iki gizli tabakaya sahip, ileri beslemeli bir sinir ağı tasarlanmıştır. Ölçülen sıcaklık ve kolon benzetimi kullanılarak hesaplanan bileşim değerleri ağa girdi olarak verilmiş, ağdan ürün bileşimini hesaplanması istenmiştir. Her iki tahmin edicinin, üst ve alt ürün bileşimlerini başarıyla hesapladığı görülmüştür. Kolonun ikili bileşim kontrolü için ise, ayrı ayrı geliştirilen tahmin edicilerde Model Öngörmeli Kontrol Edici (MPC) kullanılmıştır. Tahmin edicilerden faydalanılarak geliştirilen dolaylı kontrol sistemin performansı, set noktası değişimleri ve düzensizlikler için test edilip yeterli bulunmuştur.

Singh *et al.* (2007) bu çalışmada, damıtma prosesinin öngörmeli dolaylı kontrolü için Levenberg-Marquardt (LM) yöntemini kullanan yapay sinir ağı tahmin edici önermişlerdir. LM yöntemi kullanılarak geliştirilen tahmin ediciyle, kolonun sıcaklık profili ile birlikte kolon basıncı, kazan işi ve geri akma akışını girdi olarak kullanılarak üst ürün bileşimi tahmin edilmiştir.

Çıktının birçok parametreye bağlı olduğu karmaşık kimya endüstrilerinde, üst ürün bileşimini hesaplamak için, istenen sonuçlardan farklı doymuş çıktılarla sonuçlanan adım azalan geri yayılım (SDBP) algoritması tam olarak çalışmaz. Böyle bir durumu aşmak için geliştirilen tahmin edicide LM yöntemi kullanılmıştır. Hesaplanan değerler benzetim sonuçları ile karşılaştırılmıştır ve SDBP algoritmasından elde edilen sonuçlardan LM yönteminden elde edilen sonuçlar geliştirilmiştir. Hesaplanan sonuçların doğruluğunu arttırmak amacı ile kolonun sıcaklık profiliyle basınç, geri akma akışı ve ısı girdisi sinir ağını eğitmek için girdi olarak kullanılmıştır.

3. MATERYAL VE YÖNTEM


Bu çalışmada, çok bileşenli bir alkol karışımının damıtıldığı laboratuvar ölçekte sürekli çalışan bir dolgulu damıtma kolonunun yapay sinir ağları ile çok değişkenli kontrolü yapılmıştır.

3.1 Laboratuvar Ölçekli Dolgulu Damıtma Kolonu

Deneysel çalışmalarda kullanılan toplam deney düzeneği Şekil 3.1’de gösterilmiştir.

Kolonun kazan kısmı (1), toplam 2 L hacime sahip cam balondan yapılmıştır. Kaynatma kazanı, etrafındaki 2 kW gücündeki bir ısıtıcı manto ile ısıtılmaktadır. Isıtıcı manto (7), kontrol ünitesinde yer alan bir triyak ile bilgisayara (10) bağlanmıştır. Böylece on-line olarak ısıtma gücü istenilen değere ayarlanabilmektedir. Sisteme sürekli besleme yapmak amacı ile yine bilgisayara bağlı bir adet peristaltik pompa (8) kullanılmıştır. Peristaltik pompadan gelen çözelti ön ısıtma sıcaklığının set edildiği bir ısı değiştiriciden (6) geçirildikten sonra ön ısıtılmış olarak kazana beslenir.

Geri döngü oranını ayarlayabilmek için zaman ayarlı bir geri döngü cihazı kullanılmaktadır (5). Bu cihazda da istenilen geri döngü oranı bilgisayardan on-line olarak ayarlanabilmektedir. Burada ayarlanan zaman oranlarına göre yoğunlaştırıcıdan gelen çözeltinin bir kısmı geri döngü olarak kolona verilmekte, bir kısmı ise üst ürün toplama kabına gönderilmektedir. Sistemin sıcaklıkları kolonun tepe, kazan ve besleme hattında olmak üzere 3 adet kontrol modülü aracılığı ile bilgisayardan on-line olarak okunmaktadır. Her bir saniyede üç noktadan okunan sıcaklıklar ve geri akma oranı değeri, triyak ısıtma değeri ve besleme akış hızı değerlerinin zamanla değişimleri veri bankasına kaydedilmektedir. On-line veri alımı ve kontrol Visidaq paket programı ile sağlanmaktadır. Deneyler sırasında veri alımı ve prosesin kontrol için Visual Basic dilinde bir program yazılmıştır. Kazanı ısıtmak için triyak değeri, besleme akış hızı için peristaltik pompanın akış hızı değeri ve geri akma oranı için zaman değeri bu program aracılığıyla elle ayarlanabilecektir.



Şekil 3.1 Toplam deney düzeneği

- | | |
|---------------------------|-------------------------------|
| 1. Kazan | 6. Isı Değiştirici |
| 2. Dolgulu Kolon | 7. Ceket tipi ısı değiştirici |
| 3. Yoğunlaştırıcı | 8. Peristaltik pompa |
| 4. Toplayıcı | 9. Alt ürün çıkış vanası |
| 5. Geri döngü ayar vanası | 10. Bilgisayar |

Dolgulu damıtma kolonun fiziksel özellikleri ise Çizelge 3.1’de verilmiştir.

Çizelge 3.1 Laboratuvar ölçekli dolgulu damıtma kolonunun fiziksel özellikleri

Dolgu boyu (mm)	1000
Kolon iç çapı (mm)	50
Dolgu cinsi	Rasching Halkası
Dolgu boyutları, boy/çap (mm)	20/15
Besleme tankı hacmi (L)	5
Ceket ısıtıcı gücü	2 kW
Kolon kaynatma kazanı hacmi (L)	2
İşletme basıncı (mmHg)	690

3.1.1 Deneysel çalışmalarda kullanılan çözelti

Deneysel çalışmalarda çok bileşenli bir alkol karışımı kullanılmıştır. Bu karışımdaki bileşenler ve mol yüzdeleri Çizelge 3.2’de verilmiştir.

Çizelge 3.2 Karışımdaki bileşenler ve mol yüzdeleri

Bileşen	% mol
Metanol	30.45
Etanol	47.56
n-Bütanol	13.47
İsoamil alkol (1-pentanol)	5.69
Anisol (metil-fenil eter)	2.83

3.1.2 Deney yöntemi

Deneye başlarken besleme çözeltisi olan alkol karışımı, kolonun kazanına doldurulur. Geri akma oranı toplam geri akmaya ayarlanır. Bilgisayardan ısıtıcıya verilen enerji değeri ayarlanır. Sistem ısıtılmaya başlanır. Kazan sıcaklığı besleme çözeltisinin kaynama noktasına yaklaştığında yoğunlaştırıcı suyu devreye sokulur. Kolon toplam geri akmada yatışkın hale gelene kadar çalıştırılır. Bu durumda kolona besleme yapılmadığı gibi üründe alınmaz. Bilgisayar ekranında izlenerek, kolonun tepe sıcaklığına bakılır. Sıcaklık sabit kaldığında sistem yatışkın hale gelmiş olur. Sistem ilk yatışkın hale ulaştıktan sonra peristaltik pompanın açıklık değeri bilgisayardan ayarlanarak, ön ısıtmaya tabi tutulmuş çözelti kazana beslenir. Geri akma oranı da belirli bir değere ayarlanır ve alt ürün vanası da açılarak ürün alınmaya başlanır. Böylece sistem sürekli işleme alınmış olur. Sistemin okunan sıcaklıkları ise bilgisayara aktararak kaydedilir. Sıcaklıkların sabit kalması ile sistemin tekrar yatışkın hale geldiği anlaşılır. Laboratuvar ölçekli damıtma kolonunun sürekli yatışkın hal durumunda kolonun geri akma oranına, kazana verilen ısı değerine veya besleme çözeltisine negatif veya pozitif kademe etkisi verilerek sistem dinamik hale getirilir. Böylece kolon tekrar yatışkın olmayan hale geçer. Sıcaklıklar okunarak sistemin tekrar yatışkın hale gelişi beklenir. Sıcaklıkların sabit kalmasıyla damıtma kolonunun dinamik yatışkın hale geldiği anlaşılır.

Kontrol çalışmaları için Visidaq paket programına ANNMPC kontrol algoritması Visual Basic dilinde yazılarak eklenmiştir.

3.2 Yapay Sinir Ağları (ANN) Temelli Model Öngörmeli Kontrol (MPC) Sistemi

Çalışmada yapay sinir ağları (ANN) temelli model öngörmeli kontrol (MPC) algoritması elde etmek için, ilk olarak istatistiksel model tanımlama ile proses modeli tanımlanmıştır. Daha sonra Bağlı Kazanç Matrisi (RGA) analizi ile prosesin kontrolü için uygun kontrol çiftine karar verilmiştir. Çok girdili çok çıktılı (MIMO) proses için ANN tasarlanmıştır. Tasarlanan ANN, MPC algoritmasında kullanılmıştır.

3.2.1 İstatistiksel Model Tanımlama

Model tanımlamasında kullanılan bir yöntem olan istatistiksel yöntem 4 aşamadan oluşur:

1. Proses yatışkın hale getirilir.
2. Giriş değişkenine bir etki verilir.
3. Giriş ve çıkış değişkenleri gözlenir (İşlem sonrasında prosesin tekrar yatışkın hale dönmesi zorunlu değildir).
4. Model parametreleri hesaplanır.

Model parametrelerinin hesaplanması için ilk olarak, birinci mertebeden ölü zaman modeli (zaman alanında) aşağıda verildiği gibi yazılabilir.

$$\tau \frac{dY(t)}{dt} + Y(t) = K_p X(t - \theta) \quad (3.1)$$

Bu diferansiyel eşitlik t_i ve $t_i + \Delta t$ aralığında integre edilir ($\Gamma = \theta / \Delta t$);

$$Y_{i+1} = e^{-\Delta t / \tau} Y_i + K_p (1 - e^{-\Delta t / \tau}) X_{i-\Gamma} \quad (3.2)$$

Eşitlik daha basitçe ifade edilirse;

$$Y_{i+1} = aY_i + bX_{i-\Gamma} \quad (3.3)$$

En iyi modeli sağlamak için verilerden a, b ve Γ parametreleri belirlenir. Daha sonra model parametreleri K_p , τ ve θ hesaplanabilir.

Parametre belirlemede doğrusal regresyon kullanılır. Ölçümlerden yararlanılarak çıkış değişkenin herhangi bir andaki değeri tahmin edilebilir.

$$(Y_{i+1})_p = a(Y_i)_m + b(X_{i-\Gamma})_m \quad (3.4)$$

Eşitlikteki m simgesi ölçülen değeri, p simgesi ise tahmin edilen çıktı değerini gösterir. En iyi a ve b parametreleri, her bir andaki tahmini çıktı değerini doğru olarak sağlayan değerlerdir. Yani $(Y_{i+1})_m$ ve $(Y_{i+1})_p$ değerleri neredeyse birbirine eşit olmalıdır. Bunu sağlayan a ve b parametrelerini belirlemek için, tüm örnekler $i = \Gamma + 1$ den n e kadar ölçülen ve tahmin edilen değerler arasındaki hata kareleri toplamını en aza indiren en küçük kareler yöntemi uygulanır. Hata aşağıda verildiği gibi ifade edilebilir:

$$\sum_{i=\Gamma+1}^n E_i^2 = \sum_{i=\Gamma+1}^n [(Y_{i+1})_m - (Y_{i+1})_p]^2 = \sum_{i=\Gamma+1}^n [(Y_{i+1})_m - (a(Y_i)_m + b(X_{i-\Gamma})_m)]^2 \quad (3.5)$$

Bu terimin en aza indirilmesi için, hata kareleri toplamındaki parametrelerin türevlerinin sıfır olması gerekir.

$$\frac{\partial}{\partial a} \left[\sum_{i=\Gamma+1}^n E_i^2 \right] = -2 \sum_{i=\Gamma+1}^n (Y_i)_m [(Y_{i+1})_m - a(Y_i)_m - b(X_{i-\Gamma})_m] = 0 \quad (3.6)$$

$$\frac{\partial}{\partial b} \left[\sum_{i=\Gamma+1}^n E_i^2 \right] = -2 \sum_{i=\Gamma+1}^n (X_{i-\Gamma})_m [(Y_{i+1})_m - a(Y_i)_m - b(X_{i-\Gamma})_m] = 0 \quad (3.7)$$

Eşitlik 3.6 ve 3.7 düzenlenirse;

$$a \sum_{i=\Gamma+1}^n (Y_i)_m^2 + b \sum_{i=\Gamma+1}^n (Y_i)_m (X_{i-\Gamma})_m = \sum_{i=\Gamma+1}^n (Y_i)_m (Y_{i+1})_m \quad (3.8)$$

$$a \sum_{i=\Gamma+1}^n (Y_i)_m (X_{i-\Gamma})_m + b \sum_{i=\Gamma+1}^n (X_{i-\Gamma})_m^2 = \sum_{i=\Gamma+1}^n (X_{i-\Gamma})_m (Y_{i+1})_m \quad (3.9)$$

elde edilir. Bu eşitliklerin çözümü için de matrisler kullanılır.

$$U = \begin{bmatrix} Y_3 & X_{3-\Gamma} \\ Y_4 & X_{4-\Gamma} \\ \cdot & \cdot \\ \cdot & \cdot \\ \cdot & \cdot \\ Y_{n-1} & X_{n-\Gamma-1} \end{bmatrix} \quad z = \begin{bmatrix} Y_3 \\ Y_4 \\ \cdot \\ \cdot \\ Y_n \end{bmatrix} \quad (3.10)$$

Matrislerden yararlanarak en küçük kareler çözümü aşağıdaki gibi gösterilir ve bu eşitlikten a ve b parametreleri belirlenebilir (Bequette 1998).

$$\begin{bmatrix} a \\ b \end{bmatrix} = (U^T U)^{-1} U^T z \quad (3.11)$$

3.2.2 Ziegler-Nichols Ayarlama Yöntemi

Prosesin yanıtını birinci dereceden ölü zamanlı bir sistemin yanıtına benzediği yaklaşımı yapılmıştır. Prosesin transfer fonksiyonu $G(s)$ Eşitlik 3.12'deki gibidir.


$$G(s) = \frac{K e^{-\theta s}}{\tau s + 1} \quad (3.12)$$

Buna göre Ziegler-Nichols kontrol edici ayarlama yöntemi şu şekilde uygulanır;

- Proses kapalı devre oransal kontrole alınır.
- a. İntegral zaman sabiti sonsuza getirilir (reset hızı=0)
- b. Türev zaman sabiti 0'a getirilir. (türev hızı=0)
- c. Kontrol edici kazancına yeteri kadar küçük bir değer verilir.
- Set noktasına küçük bir basamak etki verilir. Proses değişkeni gözlenir.

- Kontrol edici kazancı yavaş yavaş arttırılarak proses değışkeni sürekli salınım verecek hale getirilir.
- Sürekli salınım gözleendiğinde, salınım periyodu (P_u) ve kontrol edici son kazancı (K_u) not edilir.

Şekil 3.2'de kontrol edicinin sürekli salınım sağladığı son kazanç değeri (K_u) salınım periyodu (P_u) gösterilmiştir.



Şekil 3.2 Sürekli salınımın sağlandığı son kazanç ve periyot

Ziegler-Nichols Yöntemi ile optimum kontrol parametrelerinin hesaplanmasında kullanılan K_u ve P_u 'ya bağlı denklemler Çizelge 3.3'te verilmiştir.

Çizelge 3.3 Ziegler-Nichols ayarlama yöntemi (Stephanopoulos 1984)

Ziegler-Nichols Ayarlama Yöntemi			
Kontrol Edici	P	PI	PID
K_c	$\frac{K_u}{2}$	$\frac{K_u}{2.2}$	$\frac{K_u}{1.7}$
τ_I		$\frac{P_u}{1.2}$	$\frac{P_u}{2}$
τ_D			$\frac{P_u}{8}$


3.2.3 Bağlı kazanç matrisi (RGA) analizi

N tane kontrol edilen ve ayarlanan değişken için N! tane kontrol döngüsü vardır. Etkileşimin en az olduğu döngü seçimi yapılan en iyi seçimdir. Döngüler arasında minimum etkileşimi yapacak kontrol çifti seçilir (Stephanopoulos 1984).

➤ Bağlı kazanç (λ_{11}) hesabı:

İki girdi ve iki çıktılı sistem için RGA hesabında kullanılan diyagramlar Şekil 3.3'te verilmiştir.

λ_{11} 'i tespit etmek için Şekil 3.3.a ve Şekil 3.3.b göz önüne alındığında;



Şekil 3.3 RGA hesabında kullanılan diyagramlar

a. Açık döngü, b. Yarı açık döngü

i) Şekil 3.3.a'da m_2 sabit iken m_1 'e basamak değişimi verilirse y_1 'in yeni yatışkın hal değeri tespit edilir ve Δy_1 elde edilir. y_1 ve m_1 arasındaki açık-döngü yatışkın kazanç, m_2 sabit olduğunda hesaplanabilir.

$$\left(\frac{\Delta y_1}{\Delta m_1} \right)_{m_2} = K_1 \quad (3.13)$$

ii) Şekil 3.3.b'ye göre m_1 değiştiğinde y_2 de değişir fakat kontrol döngüsü ile m_2 ayarlanarak y_2 sabit kalır. Bu durumdan y_1 'in yatışkın hali etkilenir. $\Delta y_1'$ yatışkın hal değeri oluşur, bu değer Δy_1 'den farklıdır. $\Delta y_1'$, m_1 ve m_2 'nin değişiminden sonra hesaplanır. Yeni açık döngü kazancı y_1 ve m_1 arasındadır ve y_2 sabit durumdadır.

$$\left(\frac{\Delta y_1'}{\Delta m_1} \right)_{y_2} = K_2 \quad (3.14)$$

Yukarıda hesaplanan bu iki açık döngü kazançlarının oranı Bağlı Kazanç, λ_{11} olarak tanımlanır.

$$\lambda_{11} = \frac{K_1}{K_2} = \frac{\left(\Delta y_1 / \Delta m_1 \right)_{m_2}}{\left(\Delta y_1' / \Delta m_1 \right)_{y_2}} \quad (3.15)$$

Proses değişkenleri arasındaki etkileşimde λ_{11} çok önemlidir.

1. $\lambda_{11} = 0$ ise;

m_1 , y_1 'i etkilemez ve y_1 'i kontrol etmek için kullanılamaz.

2. $\lambda_{11} = 1$ ise;

m_2 , y_1 'i etkilemez. y_1 ve m_1 arasındaki kontrol döngüsü y_2 ve m_2 arasındaki döngüyü etkilemez. Bu durum döngülerin ayrıştırılması anlamındadır.

3. $0 < \lambda_{11} < 1$ ise;

etkileşim vardır ve m_2 , y_1 'in yatışkın halini etkiler. λ_{11} küçüldükçe etkileşim artar.

4. $\lambda_{11} < 0$ ise;

m_2 , y_1 üzerinde güçlü bir etki yapar ve m_1 'in sebep olduğundan ters yönde bir etki verir. Bu etkileşim çok tehlikelidir.

Diğer RGA'lar da benzer şekilde yazılabilir. Eşitlik 3.16, y_1 ve m_2 arasındaki RGA'yı göstermektedir.

$$\lambda_{12} = \frac{\left(\Delta y_1 / \Delta m_2 \right)_{m_1}}{\left(\Delta y_1' / \Delta m_2 \right)_{y_2}} \quad (3.16)$$

Eşitlik 3.17, y_2 ve m_1 arasındaki RGA'yı göstermektedir.


$$\lambda_{21} = \frac{\left(\Delta y_2 / \Delta m_1 \right)_{m_2}}{\left(\Delta y_2' / \Delta m_1 \right)_{y_1}} \quad (3.17)$$

Eşitlik 3.18, y_2 ve m_2 arasındaki RGA'yı göstermektedir.


$$\lambda_{22} = \frac{\left(\Delta y_2 / \Delta m_2 \right)_{m_1}}{\left(\Delta y_2' / \Delta m_2 \right)_{y_1}} \quad (3.18)$$

➤ Döngüler arasındaki etkileşim

Şekil 3.4 ve Şekil 3.5'te iki girdi ve iki çıktı için farklı konfigürasyon gösterilmiştir.



Şekil 3.4 I. döngü konfigürasyonu



Şekil 3.5 II. döngü konfigürasyonu

Döngüler arasında minimum etkileşim için konfigürasyon seçerken bağıl kazançların 4 farklı RGA değeri bir matris formunda yazılabilir. Bu matris Eşitlik 3.19’da görüldüğü gibidir.

$$\Lambda = \begin{bmatrix} \lambda_{11} & \lambda_{12} \\ \lambda_{21} & \lambda_{22} \end{bmatrix} \begin{matrix} y_1 \\ y_2 \end{matrix} \quad (3.19)$$

Herhangi bir satır veya kolonun RGA toplamı 1 olmalıdır.


$$\lambda_{11} + \lambda_{12} = 1; \quad \lambda_{11} + \lambda_{21} = 1;$$

$$\lambda_{21} + \lambda_{22} = 1; \quad \lambda_{12} + \lambda_{22} = 1.$$


3.2.4 Çok girdili-çok çıktılı (MIMO) proseslerin kontrolü

Çok girdili-çok çıktılı (MIMO) prosesler için birden fazla kontrol konfigürasyonu vardır ve kontrol sistemleri problemleri oldukça karmaşıktır. Çünkü proses etkileşimleri kontrol edilen ve ayarlanabilen değişkenler arasında olur. Genelde ayarlanabilen değişkendeki bir değişim m_1 , tüm kontrol edilen değişkenleri etkiler. Proses etkileşiminden dolayı, çok döngülü kontrol şeması için ayarlanabilen ve kontrol edilen değişkenlerin en iyi çiftini seçmek zor bir iştir. Özellikle n tane kontrol edilen ve ayarlanabilen değişkenlerin kontrol problemi için $n!$ tane kontrol döngü konfigürasyonu vardır. Bu durumda $n=5$ için 120 tane konfigürasyon vardır (Stephanopoulos 1984).

İki girdi ve iki çıktılı bir prosesin açık döngü blok diyagramı Şekil 3.6'daki gibi ve alternatif kontrol döngülerinden birisi de Şekil 3.7'deki gibidir.



Şekil 3.6 İki kontrol edilen ve iki ayarlanabilen değişkenli bir prosesin açık döngü blok diyagramı



Şekil 3.7 İki kontrol edilen ve iki ayarlanabilen değişkenli bir prosesin kapalı döngü blok diyagramı

3.2.5 Yapay sinir ağları (ANN)

Yapay sinir ağları (ANN), yapay zeka biliminin tekniklerinden biridir (Saraç 2004).

Yapay zeka; öğrenme, gerekçeleme, problem çözme, yabancı bir dili alma v.b. gibi insanoğlunun davranışlarını gösterebilen sistemlerle ilgilenen bir bilgisayar bilimidir. Yapay zekanın ana amacı insanların davranışlarının ve sezgisel yeteneklerinin bilgisayar üzerinde benzetimidir (Dereli 2000).

ANN, insan beyninin temel işlem elemanı olan nöronu (neuron) şekilsel ve işlevsel olarak basit bir şekilde taklit ederek, biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlardır. Bu tanımdan anlaşılacağı gibi ANN'nin temel işlem elemanı da yapay nöron olarak adlandırılan nörondur. Milyonlarca nöronun bir araya gelerek biyolojik sinir sistemini oluşturduğu gibi yapay nöronlarda bir araya gelerek ANN'yi oluşturur (Öztemel 2005).


3.2.5.1 Yapay sinir ağı hücresi (Yapay nöron)

Yapay sinir hücresi yani yapay nöron, ANN'nin çalışmasına esas teşkil eden en küçük ve temel bilgi işleme birimidir (Saraç 2004).

Yapay nöronlar, biyolojik nöronların dört temel fonksiyonunu simüle ederler. Yani biyolojik nöron bölümleri olan dentrit, hücre gövdesi, akson ve sinapsın görevlerini yerine getiren bölümlerden oluşur (Yurtoğlu 2005). Bu bölümler;

- Girişler (inputs)
- Ağırlıklar (weights)
- Toplama fonksiyonu (sum function)
- Transfer fonksiyonu (transfer function)
- Çıktı (output)' dır.

Biyolojik nöronun matematiksel olarak modellenen yapay nöronun temel yapısı, Şekil 3.8’de gösterilmektedir. Bu nöron modeli, ilk olarak McCulloch ve Pitts (1943) tarafından tanımlandığı için McCulloch-Pitts nöronu olarak da bilinir (Yalcin 2001).



Şekil 3.8 Yapay sinir ağı hücresi

Buradaki x 'ler nörona girişler, w 'lar ağırlıklar, Σ toplama fonksiyonu, b (bias) transfer fonksiyonun eşik değeri, f transfer fonksiyonu ve o ise nöron çıktısıdır (Koç 2004).

➤ **Girdiler:** Yapay sinir ağına dış dünyadan gelen bilgilerdir. Ancak bazı durumlarda bu bilgiler dış dünyadan gelmez, ağ geri besleme yapısıyla çıktıları girişlerine tekrar verebilir.

➤ **Ağırlıklar:** Bilgiler, bağlantılar üzerindeki ağırlıklar üzerinden hücreye girer ve ağırlıklar, ilgili girişin hücre üzerindeki etkisini belirler. Ağırlıklar bir nöronda girdi olarak kullanılacak değerlerin göreceli kuvvetini (matematiksel katsayısını) gösterir. Yapay sinir ağı içinde girdilerin nöronlar arasında iletimini sağlayan tüm bağlantıların farklı ağırlık değerleri bulunmaktadır. Böylelikle ağırlıklar her işlem elemanının her girdisi üzerinde etki yapmaktadır. Ağırlıklar değişken veya sabit değerler olabilir.

➤ **Toplama fonksiyonu:** Bir hücreye gelen net girdiyi hesaplayan bir fonksiyondur ve genellikle net girdi, girişlerin ilgili ağırlıkla çarpımlarının toplamıdır.

Yani, $w = w_1, w_2, \dots, w_n$ ve $x = x_1, x_2, x_3, \dots, x_n$ olmak üzere net girdi;

$$\text{net} = \sum_{i=1}^n w_i x_i + b \quad (3.20)$$


dir. Hücrede toplama fonksiyonu, bu basit çarpımlar toplamına ek olarak, minimum, maksimum, mod, çarpım veya çeşitli normalizasyon işlemlerinden birisi olabilir. Bunlara ek olarak, uygulamacı kendi fonksiyonunu oluşturup toplama fonksiyonu olarak kullanabilir. Toplama fonksiyonu tasarıma göre işlemci elemanlarının hepsinde aynı biçimde seçilebileceği gibi hepsinde farklı da seçilebilir veya bazı işlemci eleman grupları arasında bir toplama fonksiyonu kullanılırken diğerlerinde farklı bir toplam fonksiyonu kullanılabilir (Haykin 1997).

➤ **Transfer fonksiyonu:** Bu fonksiyon, aldığı net girdi değerini bir algoritma ile gerçek bir çıktıya dönüştürür. Transfer fonksiyonu genellikle doğrusal olmayan bir fonksiyondur.


Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli tipte transfer fonksiyonları kullanılabilir. Transfer fonksiyonları sabit parametrelili ya da uyarlanabilir parametrelili seçilebilir. En uygun transfer fonksiyonu tasarımcının denemeleri sonucunda belli olur. Transfer fonksiyonunun seçimi büyük ölçüde yapay sinir ağı verilerine ve ağı neyi öğrenmesinin istendiğine bağlıdır (Saraç 2004).

Transfer fonksiyonları bir ANN'de nöronun çıkış genliğini, istenilen değerler arasında sınırlar. Bu değerler genellikle $[0,1]$ veya $[-1,1]$ arasındadır (Öztemel 2005).


Şekil 3.9 - 3.13'te hücre modellerinde yaygın olarak kullanılan çeşitli transfer fonksiyonlarının grafikleri gösterilmiştir (Stergiou, http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html, 2006).




Şekil 3.9 Adım transfer fonksiyonu




Şekil 3.10 Eşik transfer fonksiyonu



Şekil 3.11 Doğrusal transfer fonksiyonu



Şekil 3.12 Sigmoid transfer fonksiyonu



Şekil 3.13 Tanjant hiperbolik transfer fonksiyonu

➤ **Çıktı:** Aktivasyon fonksiyonu tarafından belirlenen çıktı değerleridir. İşlemci elemanının birden fazla çıktısı olmasına rağmen tek bir çıktı değeri vardır ve bu diğer bir işlemci elemanına girdi olarak gelmektedir (Haykin 1997).

3.2.5.2 Yapay sinir ağı yapısı

Yapay sinir ağında, biyolojik sinir ağının bir modelinin oluşturulması amaçlanır. Bu sebeple biyolojik nöronlar gibi yapay nöronlar da bağlantılar aracılığıyla bir araya gelip yapay sinir ağını oluştururlar.


Nöronların aynı doğrultu üzerinde bir araya gelmesi tabakaları, tabakaların değişik şekilde birbirleriyle bağlanmaları ise değişik ağ mimarilerini doğurur.

ANN'ler sırasıyla; girdi, ara (gizli) ve çıktı tabakası olmak üzere üç tabakadan oluşur.

➤ **Girdi Tabakası:** Bu katmandaki proses elemanları dış dünyadan bilgileri alarak ara katmanlara transfer ederler. Bazı ağlarda girdi katmanında herhangi bir bilgi işleme olmaz.

➤ **Ara Tabakası:** Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderilirler. Bu bilgilerin işlenmesi ara katmanlarda gerçekleştirilir. Bir ağ içinde birden fazla ara katman olabilir.

➤ **Çıktı Tabakası:** Bu katmandaki proses elemanları ara katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti için üretmesi gereken çıktıyı üretirler. Üretilen çıktı dış dünyaya gönderilir (Öztemel 2005).



Şekil 3.14 Yapay sinir ağı modeli (Yurtoğlu 2005)

3.2.5.3 Yapay sinir ağlarının çalışması

Yapay sinir ağlarının çalışma prensibi bir girdi setini alarak onları çıktı setine çevirmek olarak tanımlanabilir. Bunun için ağın kendisine gösterilen girdiler için doğru çıktılar üretmesi yani eğitilmesi gereklidir. Ağa gösterilecek girdiler bir vektör haline getirilir, bu vektör ağa gösterilir ve ağ çıktı vektörünü oluşturur. Ağın parametreleri doğru çıktıyı oluşturacak biçimde düzenlenir. Girdi vektörü, bir parmak izini gösteren sayısal değerler, borsada bir kağıdın haftalık satış miktarına ait sayısal değerler, bir resmin mavi tonları gibi değişik olayları gösteren nümerik değerlerden oluşabilir. Benzer şekilde çıktı vektörü de girdi vektörünün sınıfından olabilir. Girdi ve çıktı vektörlerinin tasarımı tasarımcı tarafından belirlenir ve girdiler belirlenen formatta toplanarak eğitim sırasında ağa gösterilir (Yurtoğlu 2005).

Yapay sinir ağı herhangi bir girdi vektörünün çıktı vektörüne nasıl dönüştüğü konusunda bir bilgi vermez. Çünkü ağların sonuçları nasıl oluşturduğunu açıklama yeteneği yoktur. Bu, ağa olan güveni sarsmakla birlikte yapılan başarılı uygulamalar yapay sinir ağlarına olan ilgiyi sürekli artırmaktadır. Açıklama yeteneğinin de kazandırılması bilim dünyasında yapay sinir ağlarının öneminin daha da artacağı açıktır (Stergiou, <http://www.doc.ic.ac.uk/~nd/surprise96/journal/vol4/cs11/report.html>, 2006).

3.2.5.4 Yapay sinir ağlarının sınıflandırılması

ANN'ler, genel olarak birbirleri ile bağlantılı işlemci birimlerden oluşurlar. Her bir sinir hücresi arasındaki bağlantıların yapısı ağın yapısını belirler. İstenilen hedefe ulaşmak için bağlantıların nasıl değiştirileceği eğitim algoritması tarafından belirlenir. Kullanılan eğitim algoritmasına göre, hatayı sıfıra indirecek şekilde, ağın ağırlıkları değiştirilir. ANN'ler yapılarına ve eğitim yöntemlerine göre sınıflandırılırlar (Haykin 1997).

a) Yapay sinir ağlarının mimari yapılarına göre sınıflandırılması

Yapay sinir ağları, yapılarına göre; ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde sınıflandırılırlar.

➤ İleri beslemeli ağlar

İleri beslemeli bir ağda işlemci elemanlar (İE) genellikle katmanlara ayrılmışlardır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. İE'ler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz (Hagan 2002).

İleri beslemeli ağlara örnek olarak, çok katmanlı algılayıcı (Multi Layer Perseptron-MLP) ve vektör nicemleme ile öğrenme (Learning Vector Quantization) yapan ağlar verilebilir (Hagan 2002).

İleri beslemeli ANN'de, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta katmandaki hücrelere iletir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir. Bu yapı ile ileri beslemeli ağlar, doğrusal olmayan statik bir işlevi gerçekleştirir. İleri beslemeli 3 katmanlı ANN'nin, orta katmanında yeterli sayıda hücre olmak kaydıyla, herhangi bir sürekli fonksiyonu istenilen doğrulukta yaklaştırabileceği gösterilmiştir (Hagan 2002).

İleri beslemeli yapay sinir ağlarında gecikmeler yoktur, işlem girişlerden çıkışlara doğru ilerler. Çıkış değerleri öğreticiden alınan istenen çıkış değeriyle karşılaştırılarak bir hata sinyali elde edilerek ağ ağırlıkları güncellenir (Hagan 2002).

➤ Geri beslemeli ağlar

Geri beslemeli yapay sinir ağlarında ise tıpkı kontrol uygulamalarında olduğu gibi gecikmeler söz konusudur. Geri beslemeli nöral ağ, çıkışlar girişlere bağlanarak ileri beslemeli bir ağdan elde edilir. Ağın t anındaki çıkışı $o(t)$ ise, $t + \Delta$ anındaki çıkışı ise $o(t + \Delta)$ 'dır. Buradaki Δ sabiti sembolik anlamda gecikme süresidir. İleri beslemeli yapay sinir ağları gösterimi kullanılarak $o(t + \Delta)$ şöyle yazılabilir:

$$o(t + \Delta) = f [W.o(t)] \quad (3.21)$$

bu formül aşağıdaki şekilde ifade edilmiştir. Dikkat edilmesi gereken nokta başlangıç anında $x(t)$ 'ye ihtiyaç duyulmasıdır. Başlangıç anında $o(0) = x(0)$ 'dır (Hagan 2002).

Bir geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur. Bu ağlar çeşitli tipteki zaman serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir (Hagan 2002).

Geri beslemeli ANN'de, en az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli ANN, doğrusal olmayan dinamik bir davranış gösterir. Dolayısıyla, geri beslemenin yapılış şekline göre farklı yapıda ve davranışta geri beslemeli ANN yapıları elde edilebilir (Haykin 1997).

Geriye doğru hesaplamada, ağın ürettiği çıktı değeri, ağın beklenen çıktıları ile kıyaslanır. Bunların arasındaki fark, hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. Çıktı katmanında m . proses için oluşan hata,

$Em(Hata) = Bm(Ağ \text{ çıktısı}) - Çm(Beklenen çıktı)$ olacaktır. Çıktı katmanında oluşan toplam hatayı bulmak için, bütün hataların toplanması gereklidir. Bazı hata değerleri negatif olacağından, toplamın sıfır olmasını önlemek amacıyla ağırlıkların kareleri hesaplanarak sonucun karekökü alınır. Toplam hata aşağıdaki formül ile bulunur:

$$ToplamHata = \frac{1}{2} \sum_m E_m^2 \quad (3.22)$$

Toplam hatayı en aza indirmek için, hataya neden olan proses elemanlarına dağıtılması gerekmektedir. Bu proses elemanlarının ağırlıklarını değiştirmek demektir (Öztemel 2005).

b) Yapay sinir ağlarının eğitim yöntemlerine göre sınıflandırılması

Belirli bir uygulamaya yönelik bir ağ yapılandırıldıktan sonra, bu ağ artık eğitime hazır durumdadır. Eğitme, ya da diğer bir ifadeyle öğrenme işlemi, bağlantı ağırlıklarının belirlendiği aşamadır.

Yapay sinir ağlarının eğitilmesi: İşlemci elemanlarının ağırlık değerlerinin saptanması işlemine ağırlık eğitilmesi denir. Başlangıçta ağırlık değerleri rastgele atanır. Daha sonra ağa ilk girdiler verilir. Sonuçta oluşan çıktıya göre ağa yeniden örnekler verilir. Böylece defalarca verilen örnekler sayesinde ağda doğru bağlantı ağırlıklarının oluşması sağlanır. Test için ise daha önce ağa gösterilmeyen örnekler kullanılır. Bu örnekler sayesinde ağ test edilir ve ağın performansı ölçülür. Eğitimde kullanılan örnekler *eğitim seti*, test de kullanılan örneklere *test seti* denir (Öztemel 2005).

1990'lı yıllardan bugüne gelinceye kadar birçok eğitim algoritması geliştirilmiştir. Eğitim yöntemleri temelde danışmanlı eğitim, danışmansız eğitim ve takviyeli eğitim olmak üzere üç grupta toplanmaktadır (Öztemel 2005).

➤ **Danışmanlı eğitim**

Bu tip eğitimde, ANN'ye örnek olarak bir doğru çıkış verilir. Bu eğitimde ağın ürettiği çıktılar ile hedef çıktılar arasındaki fark hata olarak ele alınır ve bu hata minimize edilmeye çalışılır. Bunun için de bağlantıların ağırlıkları en uygun çıkışı verecek şekilde değiştirilir. Bu sebeple danışmanlı eğitim yönteminin bir “öğretmene” veya “danışmana” ihtiyacı vardır. Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geribesleme (backpropagation) algoritması danışmanlı eğitim algoritmalarına örnek olarak verilebilir (Yurtoğlu 2005).

➤ **Danışmansız eğitim**

Bu tür eğitimde ağa sadece girdiler verilir. Ağın ulaşması gereken hedef çıktılar verilmez. Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren desenler (patterns) oluşturmak üzere ayarlar. Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) eğitim algoritması danışmansız eğitime örnek olarak verilebilir (Yurtoğlu 2005).

➤ **Takviyeli eğitim**

Takviyeli eğitim (reinforcement training) yöntemi, istenilen çıkışın bilinmesine gerek duymaz. Bu yöntem, danışmanlı eğitim yöntemine benzemekle birlikte, ağa hedef çıktılar yerine, ağın çıktılarının ne ölçüde doğru olduğunu belirten bir skor veya derece bildirilir. Optimizasyon problemlerini çözmek için Hinton ve Sejnowski'nin geliştirdiği Boltzmann kuralı veya GA takviyeli eğitim örnek olarak verilebilirler (Stergiou, http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html, 2006).


3.2.5.5 Yapay sinir ağlarında eğitim algoritmaları

➤ Geri yayılım eğitim algoritması

Geri yayılım algoritması, sinir ağının danışmanlı sınıfına giren genel bir algoritmadır. Daha öncede belirtildiği gibi girişlerle çıkışlar arasındaki hata sinyali bulunarak, ağırlıklar bu hata sinyaliyle güncellenmektedir. Hata yani $e(k)$, arzu edilen çıkış (gerçek çıkış - $y(k)$) ile sinir ağının çıkışı ($o(k)$) arasındaki farktır.

$$e(k) = y(k) - o(k) \quad (3.23)$$

Aşağıdaki şekilde birçok sinir hücresinin bir birine bağlandığı ileri yönlü çok katmanlı bir yapay sinir ağı görülmektedir. Giriş katmanı ile çıkış katmanı arasındaki katman veya katmanlar gizli katman olarak adlandırılır. Sinir ağlarında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç nöron olacağı bugüne kadar belirlenememiştir, probleme göre değişen bu nitelikler deneme-yanılma yoluyla bulunur.



Şekil 3.15 İleri beslemeli çok katmanlı sinir ağı

Şekil 3.15'teki çok katmanlı ağı düşünürsek;

k+1. katmanda i. birime net giriş;

$$n^{k+1}(i) = \sum_{j=1}^{S_k} w^{k+1}(i, j) o^k(j) + b^{k+1}(i) \quad (3.24)$$

Birim i'nin çıkışı şöyle olacaktır.

$$o^{k+1}(i) = f^{k+1}(n^{k+1}(i)) \quad (3.25)$$

M katmanlı bir ağı matris biçiminde ifade edilirse;

$$\underline{o}^0 = \underline{x} \quad (3.26)$$

$$\underline{o}^{k+1} = \underline{f}^{k+1}(\underline{W}^{k+1} \underline{o}^k + \underline{b}^{k+1}) \quad k=0,1,\dots,M-1 \quad (3.27)$$

Ağın temel görevi giriş-çıkış çiftleri arasındaki ilişkiyi öğrenmektir.

$$\{(\underline{x}_1, \underline{y}_1), (\underline{x}_2, \underline{y}_2), \dots, (\underline{x}_Q, \underline{y}_Q)\} \quad (3.28)$$

Ağın performansı şöyledir;

$$E = \frac{1}{2} \sum_{q=1}^Q (\underline{y}_q - \underline{o}_q^M)^T (\underline{y}_q - \underline{o}_q^M) = \frac{1}{2} \sum_{q=1}^Q \underline{e}_q^T \underline{e}_q \quad (3.29)$$

Buradaki $\underline{o}_q^M$, q. giriş ($\underline{x}_q$) olduğunda ağın çıkışıdır, $\underline{e}_q = \underline{y}_q - \underline{o}_q^M$ ise q.girişin hatasıdır. Standart geri yayılım algoritması için yaklaşık adım düşümü algoritmasını kullanır. Performans indeksiyle şöyle yaklaşılır;

$$E = \frac{1}{2} \underline{e}_q^T \underline{e}_q \quad (3.30)$$

burada toplam karelerin toplamı tek giriş-çıkış çifti için karesel hatayla yer değiştirilir. Yaklaşık adım (eğim) düşümü algoritması bundan sonra şöyle olur;

$$\Delta w^k(i, j) = -\alpha \frac{\partial E}{\partial w^k(i, j)} \quad (3.31)$$

$$\Delta b^k(i) = -\alpha \frac{\partial E}{\partial b^k(i)} \quad (3.32)$$

burada α öğrenme oranıdır, şöyle tanımlanır;

$$\delta^k(i) \equiv \frac{\partial E}{\partial n^k(i)} \quad (3.33)$$

performans indeksinin duyarlılığı k.katmanda i. birimin net girişinde değiştirilir. Şimdi Eşitlik 3.24, 3.30 ve 3.33 kullanılarak,

$$\frac{\partial E}{\partial w^k(i, j)} = \frac{\partial E}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial w^k(i, j)} = \delta^k(i) o^{k-1}(j) \quad (3.34)$$

$$\frac{\partial E}{\partial b^k(i)} = \frac{\partial E}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial b^k(i)} = \delta^k(i) \quad (3.35)$$

Hassaslık yeterliliği aşağıdaki yinelemeli ilişkiyle de gösterilebilir.

$$\underline{\delta}^k = \dot{\underline{F}}^k(\underline{n}^k) \underline{W}^{k+1} \underline{\delta}^{k+1} \quad (3.36)$$

burada;

$$\dot{\underline{F}}^k(\underline{n}^k) = \begin{bmatrix} \dot{f}^k(n^k(1)) & 0 & \dots & 0 \\ 0 & \dot{f}^k(n^k(2)) & \dots & 0 \\ \cdot & \cdot & \dots & \cdot \\ 0 & 0 & \dots & \dot{f}^k(n^k(Sk)) \end{bmatrix} \quad (3.37)$$

ve

$$f^k(n) = \frac{df^k(n)}{dn} \quad (3.38)$$

$$\underline{\delta}^M = -\dot{\underline{F}}^M(\underline{n}^M)(\underline{y}_q - \underline{o}_q) \quad (3.39)$$


Tüm öğrenme algoritmalarında şu adımlar izlenir. İlk önce Eşitlik 3.26 ve 3.27 kullanılarak giriş ileri yönde yayılır, sonra Eşitlik 3.19 ve 3.36 kullanılarak geri yayılır ve son olarak ağırlıklar ve denge Eşitlik 3.31, 3.32, 3.34 ve 3.35 kullanılarak güncellenir (Hagan 2002).

3.2.6 ANN temelli MPC

MPC algoritması tahmin ufku P olarak bilinen bazı sonlu gelecek zaman aralıklarında proses çıktılarını optimize eder (Rad 2004).

Proses modeli kullanılarak, ayarlanabilen değişkenlerdeki değişimlere karşı prosesin yanıtını öngörülebilir. Ayarlanabilen değişkenlerin şimdiki ve gelecekteki değişimleri öyle seçilir ki, öngörülen yanıtım istenen belli karakteristiklere (veya optimum değere) sahip olsun. Ayarlanabilen değişkenlere sadece ilk hesaplanan değişimler uygulanır.

$k+1$ anında zaman ufku, bir zaman aralığı kadar öteye alınarak hesaplama yinelenir. (Seborg *et al.* 1989).



Şekil 3.16 Dinamik matris kontrolünün hareket yörüngeleri

ANN temelli MPC için, k zamanında, $NN_j(1)$ bloğu için girdi vektörü $I_j(k)$:

$$I_j(k) = [u_1(k - d_{1j}), \dots, u_1(k - d_{1j} - n_{u1}), u_2(k - d_{2j}), \dots, u_2(k - d_{2j} - n_{u2}), \dots, u_{ni}(k - d_{nij}), \dots, u_{ni}(k - d_{nij} - n_{uni}), y_{pj}(k), \dots, y_{pj}(k - n_{yj})] \quad (3.40)$$

k zamanında, nonlinear optimize edicinin görevi performans indeksini en aza indiren şimdiki ve gelecek kontrol hareketlerini aşağıdaki eşitlikten hesaplamaktır:

$$E = \sum_{j=1}^N \sum_{i_n=l+d_{ij}}^p [y_{pj}(k + i_n) - y_{dj}(k + i_n)]^2 / 2 \quad (3.41)$$

burada $yp_j(k + i_n)$ ve $yd_j(k + i_n)$ sırasıyla j . kontrol edilen değişken için tahmin edilen ve istenen değerleridir.

Şimdiki zamanda, elle işlenmiş i . şimdiki ve gelecek girdileri $u_i(k - d_{ij} + i_n - 1)$ ($i_n = 1 + d_{ij}, \dots, d_{ij} + M$; $d_{ij} + M \leq P$) tekrar tekrar hesaplanır:

$$(u_i(k'))_{\text{yeni}} = (u_i(k'))_{\text{eski}} - \eta (\partial E / \partial u_i(k')) \quad (3.42)$$

burada k' , $k' = k - d_{ij} + i_n - 1$ olarak tanımlandı ve η azalan adımlı metodun adım büyüklüğüdür.

Eşitlik 3.41'e göre elle ayarlanabilen değişkenlere uyan amaç fonksiyonun eğimleri aşağıdaki eşitlikten elde edilebilir:

$$\partial E / \partial u_i(k') = \sum_{j=1}^N \sum_{i_n=1+d_{ij}}^P [yp_j(k + i_n) - yd_j(k + i_n)] \times [\partial yp_j(k + i_n) / \partial u_i(k')] \quad (3.43)$$

Aşağıda verilen eşitlik ile bu çalışmada kurulan NN'in çıktısı yp_j 'nin i . girdisi u_i ya bağlı kısmi diferansiyeli gösterilebilir:

$$\partial yp_j / \partial u_i = \sum_{i_h=1}^H w_2(j, i_h) \times [1 - Q_{hid}(i_h)^2] \times w_1(i_h, i) \quad (3.44)$$

burada ω_1 ve ω_2 sırasıyla birinci ve ikinci tabakadaki bağlantı ağırlıkları, $Q_{hid}(i_h)$ gizli tabakadaki i_h . nöronun çıktısı ve H gizli tabakadaki nöron sayısıdır (Rad 2004).

4. BULGULAR

Çalışmanın deneysel kısmına dinamik deneyler yapılarak başlanmıştır. Dinamik deney verilerinden yararlanılarak istatistiksel model tanımlama yöntemiyle laboratuvar ölçekte sürekli çalışan çok bileşenli bir karışımın damıtıldığı dolgulu damıtma kolonu tanımlaması yapılmıştır. Bunun için MATLAB programa dili kullanılmıştır. Böylece prosesin birinci mertebeden ölü zamanlı bir proses modeli göz önünde bulundurularak prosesin iletim fonksiyonları elde edilmiştir.

Daha sonra, proses çok girdili çok çıktılı (MIMO) bir proses olduğu için RGA analizi yapılarak girdiler ve çıktılar arasındaki etkileşimlere bakılmıştır. En az etkileşimin olduğu girdi-çıkı çifti seçilmiştir. Seçilen çift ile prosesin MIMO modeli oluşturulmuştur.

Sistemin yapay sinir ağı (ANN) modelini elde etmek için dinamik deney verileri kullanılmıştır. Yazılan MATLAB programı ile prosesin ANN modeli tasarlanmıştır ve eğitilmiştir.


Tasarlanan ANN model, üst ürün ve alt ürün sıcaklıklarının teorik ve deneysel kontrolü için model öngörmeli kontrol (MPC) algoritmasının temelinde kullanılmıştır.

4.1 İstatistiksel Model Tanımlama Bulguları

Çok bileşenli alkol karışımının damıtıldığı laboratuvar ölçekte sürekli çalışan dolgulu damıtma kolonu, 1. mertebeden ölü zamanlı bir prosestir.

Prosesin iletim fonksiyonlarını, Bölüm 3.2.1’de açıklanan istatistiksel model tanımlama yöntemi ile bulmak için dinamik deneyler yapılmıştır. Bunun için Şekil 4.1’de şematik olarak gösterilen prosesin girdi değişkenleri olan geri akma oranı, kazana verilen ısı ve besleme bileşimine basamak etkiler verilmiş ve çıkış değişkenleri olan üst ve alt ürün sıcaklıklarının değişimleri incelenmiştir.


Deneylerde geri akma oranına ve kazan ısısına basamak etkisi vermek için ilk olarak kolonun sürekli yatışkın hale gelmesi sağlanmıştır. Kolon, sürekli yatışkın haldeyken geri akma oranı (R) = 1.5, kazan ısısı (Q) = 6, besleme akış hızı (F) = 2’dir.




Şekil 4.1 Dolgulu damıtma kolonunun şematik gösterimi

4.1.1 Geri akma oranına verilen kademe etkilerinin bulguları

Dolgulu damıtma kolonu sürekli yatışkın hale geldikten sonra, geri akma oranına sırasıyla pozitif ve negatif kademe etkileri verilmiştir. Pozitif kademe etkisi olarak geri akma oranı 1.5’ten 4’e yükseltilmiştir. Verilen etki sonrası üst ürün sıcaklığının zamanla değişimi Şekil 4.2’de verilmiştir. Negatif kademe etkisinde ise, geri akma oranı 1.5’ten 0.67’ye indirilmiştir. Bu etki sonrası üst ürün sıcaklığının zamanla değişimi de Şekil 4.3’te gösterilmiştir.




Şekil 4.2 Geri akma oranına pozitif kademe etkisinde (1.5-4) üst ürün sıcaklığının zamanla değişimi




Şekil 4.3 Geri akma oranına negatif kademe etkisinde (1.5-0.67) üst ürün sıcaklığının zamanla değişimi

4.1.2 Kazan ısisına verilen kademe etkilerinin bulguları

Kazan ısisı (Q), pozitif kademe etkisi için 6 değerinden 7'ye yükseltilmiş, negatif kademe etkisi için ise 6 değerinden 5 değerine indirilmiştir. Verilen etkiler sonucu alt ürün sıcaklığının zamanla değişimi Şekil 4.4 ve 4.5'te gösterilmiştir.




Şekil 4.4 Kazan ısisına pozitif kademe etkisinde (6-7) alt ürün sıcaklığının zamanla değişimi




Şekil 4.5 Kazan ısisına negatif kademe etkisinde (6-5) alt ürün sıcaklığının zamanla değişimi

4.1.3 Besleme çözeltisine verilen etkinin bulguları

Besleme çözeltisindeki etanol mol yüzdesi 47.56'dan 58.37'ye yükseltilmiştir. Verilen etki sonucu üst ve alt ürün sıcaklıklarının zamanla değişimi Şekil 4.6 ve 4.7'de gösterilmiştir.



Şekil 4.6 Besleme çözeltisine pozitif etkide (%47.56 mol Et-%58.37 mol Et) üst ürün sıcaklığının zamanla değişimi



Şekil 4.7 Besleme çözeltisine pozitif etkide (%47.56 mol Et-%58.37 mol Et) alt ürün sıcaklığının zamanla değişimi

Bu deneysel verilerden yararlanılarak MATLAB ortamında istatistiksel model tanımlama yöntemi ile kolonun üstü ve altı için 1. mertebeden ölü zamanlı iletim fonksiyonları elde edilmiştir.

$$\frac{T_D(s)}{R(s)} = \frac{0.7 e^{-1.6s}}{10.96s + 1} \quad (4.1)$$

$$\frac{T_B(s)}{R(s)} = \frac{1.5 e^{-0.8s}}{10.75s + 1} \quad (4.2)$$

$$\frac{T_D(s)}{Q(s)} = \frac{1.6 e^{-12s}}{16.3s + 1} \quad (4.3)$$

$$\frac{T_B(s)}{Q(s)} = \frac{2.62 e^{-0.9s}}{9.43s + 1} \quad (4.4)$$

$$\frac{T_D(s)}{X_F(s)} = \frac{20.53 e^{-1.11s}}{3.45s + 1} \quad (4.5)$$

$$\frac{T_B(s)}{X_F(s)} = \frac{32.56 e^{-1.87s}}{11.03s + 1} \quad (4.6)$$

4.2 Ziegler-Nichols Ayarlama Yöntemi Bulguları

Çok bileşenli laboratuvar ölçekli dolgulu damıtma kolonunun üst ürün sıcaklıklarının kontrolü geleneksel PID ile de yapılmıştır. Bu amaçla öncelikle Bölüm 3.2.2’de anlatılan Ziegler-Nichols ayarlama yöntemine göre PID parametreleri elde edilmiştir. Bunun için daha önce elde edilmiş olan Eşitlik 4.1, 4.2, 4.3 ve 4.4’te verilen iletim fonksiyonları kullanılmıştır. Alt ürün için;

$$G_p(s) = \frac{T_B(s)}{Q(s)} = \frac{2.62 e^{-0.9s}}{9.43 s + 1} \quad \text{ise;} \quad (4.4)$$

1. mertebe Pade Yaklaşımı kullanılarak sistemin yeni iletim fonksiyonu,

$$G_p(s) = \frac{-2.62 s + 5.8222}{9.43 s^2 + 21.9553 s + 2.2222}$$

şeklinde bulunur. Sistemin bu iletim fonksiyonu kullanılarak MATLAB ortamında Simulink Toolbox'ı (Morari and Ricker 1998) yardımıyla kontrol edici son kazancı (Ku) ve salınım periyodu (Pu) aşağıdaki gibi bulunmuştur:

$$G_m = K_u = 8.3799$$

$$P_u = \frac{2 * \pi}{W_{cg}} = \frac{2 * \pi}{2.3258} = 2.7015$$

Elde edilen Ku ve Pu değerlerinden, Çizelge 3.3'teki eşitlikler yardımıyla PID parametreleri aşağıdaki gibi bulunur:

$$K_c = \frac{K_u}{1.7} = \frac{8.3799}{1.7} = 4.9293$$

$$\tau_I = \frac{P_u}{2} = \frac{2.7015}{2} = 1.3507$$

$$\tau_D = \frac{P_u}{8} = \frac{2.7015}{8} = 0.3377$$

Diğer iletim fonksiyonları içinde aynı adımlar izlenerek Ziegler-Nichols ayarlama yöntemiyle PID parametreleri bulunmuş ve Çizelge 4.1'de gösterilmiştir.

Çizelge 4.1 Dolgulu damıtma kolonunun iletim fonksiyonları ve PID parametreleri

İletim Fonksiyonu	PID Parametreleri		
	Kc	τ_I (dak)	τ_D (dak)
$G_{p11} = \frac{T_D(s)}{R(s)} = \frac{0.7 e^{-1.6s}}{10.96s + 1}$	12.3530	2.3477	0.5869
$G_{p12} = \frac{T_D(s)}{Q(s)} = \frac{1.6 e^{-12s}}{16.3s + 1}$	1.3666	14.3032	3.5758
$G_{p21} = \frac{T_B(s)}{R(s)} = \frac{1.5 e^{-0.8s}}{10.75s + 1}$	10.9314	1.2123	0.3031
$G_{p22} = \frac{T_B(s)}{Q(s)} = \frac{2.62 e^{-0.9s}}{9.43s + 1}$	4.9293	1.3507	0.3377


4.3 Bağlı Kazanç Matrisi (RGA) Analizi Bulguları

Çok bileşenli alkol karışımının damıtıldığı laboratuvar ölçeğinde sürekli çalışan dolgulu damıtma kolunu için, teorik bilgisi Bölüm 3.2.3'te verilen yöntem ile RGA analizi yapılmıştır.

Toplam sistemi ifade eden iletim fonksiyonu, istatistiksel model tanımlama ile bulunan iletim fonksiyonlarından elde edilmiştir ve aşağıda gösterilmiştir.

$$G_p(s) = \begin{bmatrix} G_{p11} & G_{p12} \\ G_{p21} & G_{p22} \end{bmatrix} = \begin{bmatrix} \frac{0.7 e^{-1.6s}}{10.96s + 1} & \frac{1.6 e^{-12s}}{16.3s + 1} \\ \frac{1.5 e^{-0.8s}}{10.75s + 1} & \frac{2.62 e^{-0.9s}}{9.43s + 1} \end{bmatrix} \quad (4.7)$$

Sistemin RGA analizi için kullanılan açık-döngü blok diyagramı Şekil 4.8'de gösterilmiştir.



Şekil 4.8 Dolgulu damıtma kolonunda RGA analizi için kullanılan açık-döngü blok diyagramı

Blok diyagramına göre;

$$T_D(s) = G_{p11}(s) \cdot R(s) + G_{p12}(s) \cdot Q_R(s) \quad (4.8)$$

$$T_D(s) = \frac{0.7 e^{-1.6s}}{10.96s+1} \cdot R(s) + \frac{1.6 e^{-12s}}{16.3s+1} \cdot Q_R(s) \quad (4.9)$$

$$T_B(s) = G_{p21}(s) \cdot R(s) + G_{p22}(s) \cdot Q_R(s) \quad (4.10)$$


$$T_B(s) = \frac{1.5 e^{-0.8s}}{10.75s+1} \cdot R(s) + \frac{2.62 e^{-0.9s}}{9.43s+1} \cdot Q_R(s) \quad (4.11)$$

Bağıl Kazanç(λ) Hesabı:

λ_{11} elde etmek için Eşitlik 4.12'deki kesrin pay ve payda değerleri ayrı ayrı hesaplanmıştır.

$$\lambda_{11} = \frac{\left(\frac{\Delta y_1}{\Delta m_1} \right)_{m_2}}{\left(\frac{\Delta y_1}{\Delta m_1} \right)_{y_2}} \quad (4.12)$$

$\left(\frac{\Delta y_1}{\Delta m_1} \right)_{m_2}$ 'nin bulunabilmesi için, MATLAB ortamında ayarlanabilen değişken R'ye pozitif kademe etkisi verilerek T_D 'nin değişimi elde edilmiştir. Elde edilen değerler Şekil 4.9'da gösterilmiştir. Grafikten de görüldüğü gibi $\left(\frac{\Delta y_1}{\Delta m_1} \right)_{m_2} = -1.7490$ olarak bulunmuştur.




Şekil 4.9 Dolgulu damıtma kolonunda RGA analizi için R'ye (u_1, m_1) pozitif kademe etkisi verildiğinde üst ürün sıcaklık değerinin (y_1) zamanla değişimi

$\left(\frac{\Delta y_1}{\Delta m_1} \right)_{y_2}$ 'nin bulunabilmesi için m_1 'e etki verilerek y_2 PID ile kontrol edilmiştir.

Kontrol MATLAB ortamında Şekil 4.10'da blok diyagramı gösterilen Simulink

programı ile yapılmıştır. Kontrol sonucu elde edilen değerler Şekil 4.11’de verilmiştir.

Şekildeki grafikte de $\left(\frac{\Delta y_1}{\Delta m_1} \right)_{y_2} = -3.7501$ olarak bulunduğu görülmektedir.




Şekil 4.10 Dolgulu damıtma kolonunda RGA analizi için kullanılan MATLAB Simulink programı blok diyagramı

$\left(\frac{\Delta y_1}{\Delta m_1} \right)_{m_2}$ ve $\left(\frac{\Delta y_1}{\Delta m_1} \right)_{y_2}$ değerlerinden λ_{11} değeri;

$$\lambda_{11} = \frac{\left(\frac{\Delta y_1}{\Delta m_1} \right)_{m_2}}{\left(\frac{\Delta y_1}{\Delta m_1} \right)_{y_2}} = \frac{-1.7490}{-3.7501} = 0.4664$$

olarak hesaplanmıştır. λ_{12} değeri de $\lambda_{11} + \lambda_{12} = 1$ eşitliği yardımıyla $\lambda_{12} = 0.5336$ olarak bulunmuştur. Diğer λ değerleri de,



Şekil 4.11 Dolgulu damıtma kolonunda RGA analizi için m_1 etkisinde yarı açık döngü kontrol sonucu

$$\lambda_{12} + \lambda_{22} = 1,$$

$$\lambda_{21} + \lambda_{22} = 1,$$

$$\lambda_{21} + \lambda_{11} = 1$$

eşitliklerinden hesaplanmıştır.

Hesaplanan RGA değerleri matris formunda yazılarak,

$$\Lambda = \begin{bmatrix} 0.4664 & 0.5336 \\ 0.5336 & 0.4664 \end{bmatrix}$$

matrisi elde edilmiştir.

$0 < \lambda_{11} < 1$ olduğundan değişkenler arasında etkileşim vardır. m_1 y_2 'yi, m_2 de y_1 'i etkiler.


Analiz sonucuna göre, üst ürün sıcaklığı (T_D) kontrolü için geri akma oranı (R), alt ürün sıcaklığı (T_B) kontrolü için kazan ısısı (Q) ayarlanabilen değişken olarak seçilmiştir. Seçilen kontrol çifti kolonun MIMO kontrolü için kullanılmıştır.

4.4 Yapay Sinir Ağı (ANN) Bulguları


Kolonu kontrol edecek MPC algoritmasını yazabilmek için, ilk olarak sistemin modelinin elde edilmesi gerekir. Çalışmada, kolon modelinin elde edilmesinde ANN kullanılmıştır.

MATLAB ortamında dinamik deney verilerinden yararlanılarak kolon için bir ANN tasarlanmıştır. Tasarlanan ANN, 10 nöronlu bir gizli tabaka içeren ileri beslemeli çok tabakalı bir ANN'dir. Ağ yapısı Şekil 4.12'de gösterilmiştir. Ağdaki nöronlar için aktivasyon fonksiyonu gizli tabakada tanjant sigmoid fonksiyonu, çıktı tabakasında ise doğrusal aktivasyon fonksiyonu seçilmiştir. Ağa girdi olarak dinamik deneylerde ölçülen sıcaklık değerleri ve geri akma oranı ile kazan ısısına verilen etki değerleri verilmiştir. Ağdan, girdi değerlerini kullanarak hedeflenen sıcaklık değerlerini elde etmesi istenmiştir. Ağ, değişik girdi değerlerine karşı yine hedeflenen çıktı değerlerini elde edebilmesi için geri yayılım algoritması ile eğitilmiştir. Eğitim sonunda ağdaki bağlantı ağırlıkları belirlenmiştir. Bu ağırlık değerleri MPC algoritmasında kolon modelini tanımlamak için kullanılmıştır.


Ağa ilk olarak Şekil 4.13'te gösterilen üst ürün sıcaklık değerleri girdi olarak verilmiştir. Ağdan, bu sıcaklık değerlerini set noktası değerine getirmesi istenmiştir. Ağın eğitilmeden önce ürettiği çıktı değerleri Şekil 4.14'de, eğitimden sonra ürettiği çıktı değerleri de Şekil 4.15'te verilmiştir. Ağın verilen sıcaklık değerlerini istenilen set noktası sıcaklığına getirdiği görülmüştür.




Şekil 4.12 Dolgulu damıtma kolonunun modeli için tasarlanan ağ yapısının gösterimi



Şekil 4.13 ANN'ye girdi olarak verilen üst ürün sıcaklığının zamanla değişimi




Şekil 4.14 Eğitim öncesi ANN çıktısının zamanla değişimi




Şekil 4.15 Eğitim sonrası ANN çıktısının zamanla değişimi

Ağa ikinci olarak Şekil 4.16'da gösterilen alt ürün sıcaklık değerleri girdi olarak verilmiştir. Ağdan, bu sıcaklık değerlerini set noktası değerine getirmesi istenmiştir.




Şekil 4.16 ANN'ye girdi olarak verilen alt ürün sıcaklığının zamanla değişimi

Ağın eğitilmeden önce ürettiği çıktı değerleri Şekil 4.17'de, eğitildikten sonra ürettiği çıktı değerleri de Şekil 4.18'de verilmiştir. Ağın verilen sıcaklık değerlerini istenilen set noktası sıcaklığına getirdiği görülmüştür.



Şekil 4.17 Eğitim öncesi ANN çıktısının zamanla değişimi



Şekil 4.18 Eğitim sonrası ANN çıktısının zamanla değişimi

4.5 Kontrol Bulguları

Laboratuvar ölçeğinde sürekli çalışan dolgulu damıtma kolonunun üst ve alt ürün sıcaklıklarının tek ve çok değişkenli kontrolü, ANN temelli MPC algoritmasıyla teorik ve deneysel olarak yapılmıştır.

MPC algoritması teorik kontrol için MATLAB dilinde, deneysel kontrol için ise Visual Basic dilinde yazılmıştır.

Kontrol çalışmaları üst ve alt ürün sıcaklıklarının set noktalarına pozitif ve negatif kademe etkileri, besleme çözeltisindeki etanol derişimine pozitif ve negatif etkiler verilerek yapılmıştır. Besleme çözeltisine verilen etkiler sonucunda elde edilen çözeltilerinin bileşimleri Çizelge 4.2’de gösterilmiştir.

Çizelge 4.2 Kontrol deneylerinde kullanılan besleme çözeltilerinin bileşimleri

Bileşen	Besleme Çözeltisi (% mol)	Etanol Derişimine Pozitif Etki Verilmiş Besleme Çözeltisi (% mol)	Etanol Derişimine Negatif Etki Verilmiş Besleme Çözeltisi (% mol)
Metanol	30.45	22.93	37.91
Etanol	47.56	58.37	36.84
n-Bütanol	13.47	10.14	16.76
İsoamil alkol (1-pentanol)	5.69	5.72	5.67
Anisol (metil-fenil eter)	2.83	2.84	2.82


4.5.1 Tek girdili tek çıktılı (SISO) kontrol bulguları

Kolonun SISO kontrolünde, üst ve alt ürün sıcaklıkları ayrı ayrı kontrol edilmiştir. Üst ürün sıcaklığının kontrolü için geri akma oranı, alt ürün sıcaklığının kontrolü için kazan ısı değeri ayarlanabilen değişken olarak seçilmiştir.


Kontrol sisteminin etkinliğini görmek için, elde edilen sıcaklık değerlerinden hata kareleri integrali (ISE) değerleri hesaplanmıştır.

Teorik olarak üst ürün sıcaklığının kontrolü için, MATLAB ortamında etkiler verilmiştir. Etkiler sonunda kontrol edilen üst ürün sıcaklığının ve ayarlanabilen değişken olan geri akma oranının zamanla değişimi elde edilmiştir.


Üst ürün sıcaklığının set noktasına (68-69-70-71°C) değerlerinde pozitif kademe etkileri verildiğinde elde edilen sonuçlar Şekil 4.19 ve 4.20’de, (68-67-66°C) değerlerinde negatif kademe etkileri verildiğinde elde edilen sonuçlar Şekil 4.21 ve 4.22’de gösterilmiştir.




Şekil 4.19 Teorik olarak üst ürün sıcaklığının set noktasına pozitif kademe etkisinde üst ürün sıcaklığının zamanla değişimi (ISE=1.3051)



Şekil 4.20 Teorik olarak üst ürün sıcaklığının set noktasına pozitif kademe etkisinde geri akma oranındaki değişimin zamanla değişimi




Şekil 4.21 Teorik olarak üst ürün sıcaklığının set noktasına negatif kademe etkisinde üst ürün sıcaklığının zamanla değişimi (ISE=1.9094)




Şekil 4.22 Teorik olarak üst ürün sıcaklığının set noktasına negatif kademe etkisinde geri akma oranındaki değişimin zamanla değişimi


Üst ürün sıcaklığının kontrolü için besleme çözeltisinin derişimine verilen pozitif ve negatif etkide ulařılan deęerler řekil 4.23 - 4.26'da çizilmiřtir.




Şekil 4.23 Teorik olarak besleme çözeltisine pozitif etkide üst ürün sıcaklığının zamanla değişimi (ISE=1.1638)



Şekil 4.24 Teorik olarak besleme çözeltisine pozitif etkide geri akma oranındaki değişimin zamanla değişimi




Şekil 4.25 Teorik olarak besleme çözeltisine negatif etkide üst ürün sıcaklığının zamanla değişimi (ISE=4.3724)




Şekil 4.26 Teorik olarak besleme çözeltisine negatif etkide geri akma oranındaki değişimin zamanla değişimi

Deneyssel olarak üst ürün sıcaklığının kontrolünde, etkiler kolon sürekli yatışkın hale geldikten sonra verilmiştir. Üst ürün sıcaklığının tekrar yatışkın hale gelmesi beklenmiştir. Deneyler sırasında elde edilen değerler zamana karşı grafiğe geçirilmiştir.


Üst ürün sıcaklığının deneysel kontrolünde, set noktasına pozitif ve negatif kademe etkisi verildiğinde MPC sonuçları Şekil 4.27 - 4.30'da gösterilmiştir.




Şekil 4.27 Deneysel olarak üst ürün sıcaklığının set noktasına pozitif kademe etkilerinde üst ürün sıcaklığının zamanla değişimi (ISE=1.3961)



Şekil 4.28 Deneysel olarak üst ürün sıcaklığının set noktasına pozitif kademe etkisinde geri akma oranının zamanla değişimi




Şekil 4.29 Deneysel olarak üst ürün sıcaklığının set noktasına negatif kademe etkilerinde üst ürün sıcaklığının zamanla değişimi (ISE=15.0967)




Şekil 4.30 Deneysel olarak üst ürün sıcaklığının set noktasına negatif kademe etkisinde geri akma oranının zamanla değişimi


Üst ürün sıcaklığının deneysel kontrolünde, besleme çözeltisine Çizelge 4.1’de verilen pozitif ve negatif etki değerlerinde ANN MPC sonuçları Şekil 4.31 - 4.34’te gösterilmiştir.




Şekil 4.31 Deneysel olarak besleme çözeltisine pozitif basamak etkisinde üst ürün sıcaklığının zamanla değişimi (ISE=11.3977)



Şekil 4.32 Deneysel olarak besleme çözeltisine pozitif etkide geri akma oranının zamanla değişimi




Şekil 4.33 Deneysel olarak besleme çözeltisine negatif basamak etkisinde üst ürün sıcaklığının zamanla değişimi (ISE=3.5095)




Şekil 4.34 Deneysel olarak besleme çözeltisine negatif etkide geri akma oranının zamanla değişimi

Alt ürün sıcaklığının teorik kontrolünde de, MATLAB ortamında etkiler verilerek sonuçlar gözlenmiştir. Verilen etkilere karşı kontrol edilen alt ürün sıcaklığının ve değişerek kontrolü sağlayan kazan ısının zamanla değişimi elde edilmiştir.


Alt ürün sıcaklığının teorik kontrolünde, set noktasına (78-79-80°C) pozitif ve (77-76°C) negatif kademe etkisi verildiğinde elde edilen sonuçlar sırasıyla Şekil 4.35 - 4.38’de çizilmiştir.




Şekil 4.35 Teorik olarak alt ürün sıcaklığının set noktasına pozitif kademe etkisinde alt ürün sıcaklığının zamanla değişimi (ISE=1.9026)



Şekil 4.36 Teorik olarak alt ürün sıcaklığının set noktasına pozitif kademe etkisinde kazan ısısındaki değişimin zamanla değişimi




Şekil 4.37 Teorik olarak alt ürün sıcaklığının set noktasına negatif kademe etkisinde alt ürün sıcaklığının zamanla değişimi (ISE=2.8294)




Şekil 4.38 Teorik olarak alt ürün sıcaklığının set noktasına negatif kademe etkisinde kazan ısısındaki değişimin zamanla değişimi


Alt ürün sıcaklığının teorik kontrolünde, besleme çözeltisinin derişimine Çizelge 4.1'deki gibi verilen pozitif ve negatif etkide ulařılan deęerler řekil 4.39 - 4.42'de gösterilmiřtir.




řekil 4.39 Teorik olarak besleme çözeltisine pozitif etkide alt ürün sıcaklığının zamanla deęiřimi (ISE=6.2611)



řekil 4.40 Teorik olarak besleme çözeltisine pozitif etkide kazan ıısındaki deęiřimin zamanla deęiřimi




Şekil 4.41 Teorik olarak besleme çözeltisine negatif etkide alt ürün sıcaklığının zamanla değişimi (ISE=0.3193)




Şekil 4.42 Teorik olarak besleme çözeltisine negatif etkide kazan ısısındaki değişimin zamanla değişimi

Alt ürün sıcaklığının deneysel olarak kontrolü için, kolon sürekli yatışkın hale geldikten sonra etkiler verilmiştir. Etkiler nedeniyle değişen alt ürün sıcaklığının tekrar yatışkın hale gelmesi beklenmiştir. Deneyler sırasında elde edilen değerler zamana karşı grafiğe geçirilmiştir.


Alt ürün sıcaklığının deneysel kontrolünde, set noktasına (78-79-80°C) pozitif ve (77-76°C) negatif kademe etkisi verildiğinde MPC sonuçları Şekil 4.43 - 4.46'da gösterilmiştir.




Şekil 4.43 Deneysel olarak alt ürün sıcaklığının set noktasına pozitif kademe etkisinde alt ürün sıcaklığının zamanla değişimi(ISE=10.6827)



Şekil 4.44 Deneysel olarak alt ürün sıcaklığının set noktasına pozitif kademe etkisinde kazan ısısının zamanla değişimi




Şekil 4.45 Deneysel olarak alt ürün sıcaklığının set noktasına negatif kademe etkisinde alt ürün sıcaklığının zamanla değişimi(ISE=33.9190)




Şekil 4.46 Deneysel olarak alt ürün sıcaklığının set noktasına negatif kademe etkisinde kazan ısısının zamanla değişimi


Alt ürün sıcaklığının deneysel kontrolünde, besleme çözeltisine Çizelge 4.1'deki gibi pozitif ve negatif etki verildiğinde MPC sonuçları Şekil 4.47 - 4.50'de gösterilmiştir.




Şekil 4.47 Deneysel olarak besleme çözeltisine pozitif etkide alt ürün sıcaklığının zamanla değişimi(ISE=0.6397)



Şekil 4.48 Deneysel olarak besleme çözeltisine pozitif etkide kazan ısısının zamanla değişimi



Şekil 4.49 Deneysel olarak besleme çözeltisine negatif etkide alt ürün sıcaklığının zamanla değişimi(ISE=1.2239)



Şekil 4.50 Deneysel olarak besleme çözeltisine negatif etkide kazan ısısının zamanla değişimi

Tek girdili tek çıktılı kontrol deneyleri için alt ve üst ürünlerden yatışkın koşullar için numuneler alınarak GC/MS’de analizleri yapılmıştır. Bu analiz sonuçları ile karışımdaki bileşenlerin derişimleri hakkında bilgi sahibi olunmuştur. Çizelge 4.3’te besleme bileşimine pozitif kademe etkisi verildiğinde alt ve üst ürün bileşimleri kontrolden önceki ve kontrol sonundaki yatışkın koşul değerleri verilmiştir. Tabloda görüldüğü gibi alt üründeki etanol derişiminin minimum üst üründekinin ise maksimum olduğu görülmektedir.

Çizelge 4.3 Besleme çözeltisine pozitif kademe etkisi verildiğinde üst ve alt ürünlerin GC/MS sonuçları

Bileşen	Etanol Derişimine Pozitif Etki Verildiğinde Besleme Çözeltisi (% mol)	Üst ürün Derişimi (%mol)	Alt ürün Derişimi (%mol)
Metanol	22.93	3.60	0.27
Etanol	58.37	91.32	0.27
n-Bütanol	10.14	2.47	39.57
İsoamil alkol (1-pentanol)	5.72	1.36	44.22
Anisol (metil-fenil eter)	2.84	1.25	15.67

Üst ürün sıcaklığının set noktasına (68-69-70°C) pozitif etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları Çizelge 4.4’te verilmiştir. Alt ürün sıcaklığının set noktasına (78-79-80°C) basamak etkisi için alt ürün numunelerinin GC/MS sonuçları ise Çizelge 4.5’te gösterilmiştir.

Çizelge 4.4 Üst ürün sıcaklığının set noktasına negatif basamak etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları

Bileşen	68°C Üst ürün derişimi (% mol)	69°C Üst ürün derişimi (% mol)	70°C Üst ürün derişimi (% mol)
Metanol	6.71	4.60	3.24
Etanol	87.42	92.53	94.67
n-Bütanol	2.56	1.35	1.04
İsoamil alkol (1-pentanol)	1.73	1.07	0.79
Anisol (metil-fenil eter)	1.58	0.45	0.26

Çizelge 4.5 Alt ürün sıcaklığının set noktasına pozitif basamak etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları


Bileşen	78°C Alt ürün derişimi (% mol)	79°C Alt ürün derişimi (% mol)	80°C Alt ürün derişimi (% mol)
Metanol	22.93	0.35	0.28
Etanol	58.37	0.40	0.34
n-Bütanol	10.14	39.79	40.12
İsoamil alkol (1-pentanol)	5.72	44.34	44.56
Anisol (metil-fenil eter)	2.84	15.12	14.70

4.5.2 Çok girdili çok çıktılı (MIMO) kontrol bulguları


Kolonun MIMO kontrolünde, üst ve alt ürün sıcaklıkları aynı anda kontrol edilmiştir. Sıcaklıkların kontrolü için geri akma oranı ve kazan ısısı ayarlanabilen değişkenler olarak seçilmiştir. Kontrol sisteminin etkinliğini görmek için, elde edilen sıcaklık değerlerinden hata kareleri toplamı (ISE) değerleri hesaplanmıştır.

Teorik MIMO kontrol MATLAB ortamında yapılmıştır. Çeşitli etkiler verilerek kontrol edilen sıcaklıkların ve ayarlanabilen değişkenlerin zamanla değişimi elde edilmiştir.

Üst ve alt ürün sıcaklıklarının teorik kontrolünde, üst ürün sıcaklığının set noktasına ($66-67^{\circ}\text{C}$)'ye pozitif kademe alt ürün sıcaklığının set noktasına ise ($77-78^{\circ}\text{C}$)'ye pozitif kademe etkisi için elde edilen MIMO kontrol sonuçları Şekil 4.51 ve 4.52'de gösterilmiştir.




Şekil 4.51 Teorik olarak üst ve alt ürün sıcaklıklarının set noktalarına pozitif kademe etkisinde üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B=4.0805$, $ISE_D=2.0308$)




Şekil 4.52 Teorik olarak üst ve alt ürün sıcaklıklarının set noktalarına pozitif kademe etkisinde geri akma oranındaki değişimin ve kazan ısısındaki değişimin zamanla değişimi

Ürün sıcaklıklarına negatif basamak etkilerinde teorik kontrol için ise, üst ürün sıcaklığının set noktasına ($66-65^{\circ}\text{C}$)'ye negatif basamak etkisi, alt ürün sıcaklığının set noktasına ise ($77-76^{\circ}\text{C}$)'ye pozitif kademe etkisi için elde edilen MIMO kontrol sonuçları Şekil 4.53 ve 4.54'te gösterilmiştir.




Şekil 4.53 Teorik olarak üst ve alt ürün sıcaklıklarının set noktalarına negatif kademe etkisinde üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B = 4.0903$, $ISE_D = 3.8400$)




Şekil 4.54 Teorik olarak üst ve alt ürün sıcaklıklarının set noktalarına negatif kademe etkisinde geri akma oranındaki değişimin ve kazan ısısındaki değişimin zamanla değişimi

Bir başka MIMO teorik kontrol çalışması, SISO kontrolde olduğu gibi besleme bileşimine basamak etkisi verilerek yapılmıştır. Besleme bileşiminde etanol derişimine birim pozitif basamak etkisi verildiğinde üst ve alt ürün sıcaklıklarının kontrol sonuçları Şekil 4.55 ve 4.56’da çizilmiştir.




Şekil 4.55 Teorik olarak besleme çözeltisine pozitif etkide üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B = 1.2164$, $ISE_D = 0.6983$)




Şekil 4.56 Teorik olarak besleme çözeltisine pozitif etkide geri akma oranındaki değişimin ve kazan ısısındaki değişimin zamanla değişimi

Besleme bileşiminde etanol derişimine birim negatif basamak etkisi verildiğinde ise elde edilen kontrol sonuçları ise Şekil 4.57 ve 4.58’de çizilmiştir.



Şekil 4.57 Teorik olarak besleme çözeltisine negatif etkide üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B = 0.1345$, $ISE_D = 0.3136$)




Şekil 4.58 Teorik olarak besleme çözeltisine negatif etkide geri akma oranındaki değişimin ve kazan ısısındaki değişimin zamanla değişimi


Şekillerden ve hesaplanan ISE değerlerinden de görüldüğü gibi tatmin edici teorik kontrol sonuçları elde edilmiştir

Deneysel çalışmalarda kontrol algoritması MIMO sistem göz önüne alınarak üst ve alt ürün sıcaklıklarının kontrolü yapılmıştır. Bunu için öncelikle MIMO sistem için yapay sinir ağları modeli geliştirilmiştir. Elde edilen model çok değişkenli MPC algoritmasına uygulanmıştır. Deney sisteminde Visadaq programı algoritmasına Visual Basic dilinde yazılan yapay sinir ağı modeli temelli MPC algoritması programı eklenmiştir

Yapılan birinci kontrol çalışmasında üst ve alt ürün sıcaklıklarının deneysel kontrolünde, üst ürün sıcaklığının set noktasına (66-67°C) ye pozitif kademe ve alt ürün sıcaklığının set noktasına ise (77-78°C)'ye pozitif kademe etkisi için elde edilen deneysel MIMO kontrol sonuçları Şekil 4.59 ve 4.60'da gösterilmiştir. Şekillerden de görüldüğü gibi küçük salınımlarla sistem kontrol edilmiştir. Hesaplanan ISE değerleri de tatmin edici değerlerdedir.




Şekil 4.59 Deneyssel olarak üst ve alt ürün sıcaklıklarının set noktalarına pozitif kademe etkisinde üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B=8.0964$, $ISE_D=8.2993$)




Şekil 4.60 Deneyssel olarak üst ve alt ürün sıcaklıklarının set noktalarına pozitif kademe etkisinde geri akma oranının ve kazan ısının zamanla değişimi

İkinci deneysel kontrol çalışması üst ürün sıcaklığının set noktasına ($66-65^{\circ}\text{C}$)'ye ve alt ürün sıcaklığının set noktasına ise ($77-76^{\circ}\text{C}$)'ye negatif kademe etkisi için elde edilen deneysel çok değişkenli MPC sonuçları Şekil 4.61 ve 4.62'de gösterilmiştir. Burada sistem kontrolü çok tatmin edici olamamıştır. ISE değerleri birinci deney sonuçlarına göre daha büyük çıkmıştır. Sistemdeki etkileşimler ve karışımdaki bileşenlerin kaynama noktaları birbirine yakın olmalarından dolayı kontrol sonuçları SISO kontrole göre daha az etkin gözükmemektedir.




Şekil 4.61 Deneysel olarak üst ve alt ürün sıcaklıklarının set noktalarına negatif kademe etkisinde üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B=39.1940$, $ISE_D=27.4309$)




Şekil 4.62 Deneyel olarak üst ve alt ürün sıcaklıklarının set noktalarına negatif kademe etkisinde geri akma oranının ve kazan ısının zamanla değişimi

Bir başka MIMO deneysel kontrol çalışması, besleme bileşimindeki etanol derişimine Çizelge 4.1'deki gibi pozitif etki verildiğinde yapılmıştır. Elde edilen kontrol sonuçları Şekil 4.63 ve 4.64'te gösterilmiştir. Burada ISE değerlerine de bakarak oldukça tatmin edici kontrol sonucu elde edilmiştir.




Şekil 4.63 Deneyel olarak besleme çözeltisine pozitif etkide üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B=1.4130$, $ISE_D=3.2365$)




Şekil 4.64 Deneyisel olarak besleme çözeltisine pozitif etkide geri akma oranının ve kazan ısının zamanla değişimi

Besleme bileşimindeki etanolün derişimine %45'ten %35'e negatif kademe etkisi için de MIMO kontrol çalışması yapılmıştır. Elde edilen sonuçlar Şekil 4.65 ve 4.66'da gösterilmiştir. Buradan elde edilen sonuçlarda yine hesaplanmış olan ISE değerlerine bakıldığında oldukça tatmin edici olduğu görülmektedir.



Şekil 4.65 Deneyisel olarak besleme çözeltisine negatif etkide üst ve alt ürün sıcaklıklarının zamanla değişimi ($ISE_B=1.8812$, $ISE_D=1.6438$)



Şekil 4.66 Deneysel olarak besleme çözeltisine negatif etkide geri akma oranının ve kazan ısının zamanla değişimi

Çok girdili çok çıktıli kontrol deneyleri için de alt ve üst ürünlerden yatışkın koşullar için numuneler alınarak GC/MS’de analizleri yapılmıştır. Bu analiz sonuçları ile karışımdaki bileşenlerin derişimleri hakkında bilgi sahibi olunmuştur. Üst ürün sıcaklığının set noktasına ($66-67^{\circ}\text{C}$) ve alt ürün sıcaklığının set noktasına ($77-78^{\circ}\text{C}$)’ye pozitif etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları Çizelge 4.6’da verilmiştir. Çizelgede görüldüğü gibi kontrol MIMO çalışmasında üst ve alt ürün sıcaklıklarının set noktalarına pozitif etkiler verilerek üst üründe daha yüksek derişimde alt üründe ise daha düşük derişimde etanol elde edilmesi amaçlanmıştır. Çizelge 4.7’de üst ürün sıcaklığının set noktasına ($66-65^{\circ}\text{C}$) ve alt ürün sıcaklığının set noktasına ($77-76^{\circ}\text{C}$)’ya negatif etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları verilmiştir.

Çizelge 4.6 Üst ve alt ürün sıcaklıklarının set noktasına pozitif basamak etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları

Bileşen	Üst ürün Bileşimleri (% mol) (T _D =66°C)	Üst ürün Derişimi (%mol) (T _D =67°C)	Alt ürün Derişimi (%mol) (T _B =77°C)	Alt ürün Derişimi (%mol) (T _B =78°C)
Metanol	14.71	3.60	0.42	0.31
Etanol	82.42	91.32	2.35	4.58
n-Bütanol	1.22	2.47	40.26	41.75
İsoamil alkol	1.13	1.36	46.14	35.58
Anisol	0.52	1.25	10.83	17.78

Çizelge 4.7 Üst ve alt ürün sıcaklıklarının set noktasına negatif basamak etkilerde yatışkın koşullarda alınan numunelerin GC/MS sonuçları

Bileşen	Üst ürün Derişimi (% mol) (T _D =66°C)	Üst ürün Derişimi (%mol) (T _D =65°C)	Alt ürün Derişimi (%mol) (T _B =77°C)	Alt ürün Derişimi (%mol) (T _B =76°C)
Metanol	14.71	17.45	0.42	0.42
Etanol	82.42	78.73	2.35	2.09
n-Bütanol	1.22	2.13	40.26	39.57
İsoamil alkol	1.13	1.25	46.14	39.01
Anisol	0.52	0.44	10.83	18.91

Besleme bileşimindeki etanolün derişimine %47.56'dan %58.37'ye pozitif kademe etkisi verildiğinde alt ve üst ürün bileşimleri kontrolden önceki ve kontrol sonundaki yatışkın koşul değerleri GC/MS'de analizlenerek elde edilmiştir. Analiz sonuçları Çizelge 4.8'de gösterilmiştir.

Besleme bileşimindeki etanolün derişimine %47.56'dan %36.84'e negatif kademe etkisi verildiğinde alt ve üst ürün bileşimleri kontrolden önceki ve kontrol sonraki yatışkın koşul değerleri de GC/MS'de analizlenerek elde edilmiştir. Analiz sonuçları Çizelge 4.9'da gösterilmiştir.

Çizelge 4.8 Besleme çözeltisine pozitif kademe etkisi verildiğinde üst ve alt ürünlerin GC/MS sonuçları

Bileşen	Üst Ürün Bileşimleri (% mol)		Alt Ürün Bileşimleri (% mol)	
	Beslemede (%47.56 Etanol derişimi için)	Beslemede (%58.37 Etanol derişimi için)	Beslemede (%47.56 Etanol derişimi için)	Beslemede (%58.37 Etanol derişimi için)
Metanol	16.55	15.21	0.38	0.47
Etanol	79.63	81.12	2.24	1.87
n-Bütanol	2.04	1.86	40.12	39.13
İsoamil alkol	1.31	1.02	47.24	48.65
Anisol	0.47	0.79	10.02	9.88

Çizelge 4.9 Besleme çözeltisine negatif kademe etkisi verildiğinde üst ve alt ürünlerin GC/MS sonuçları

Bileşen	Üst Ürün Bileşimleri (% mol)		Alt Ürün Bileşimleri (% mol)	
	Beslemede (%47.56 Etanol derişimi için)	Beslemede (%36.84 Etanol derişimi için)	Beslemede (%47.56 Etanol derişimi için)	Beslemede (%36.84 Etanol derişimi için)
Metanol	16.42	15.21	0.38	0.55
Etanol	79.84	81.12	2.24	1.71
n-Bütanol	1.93	1.86	40.12	41.13
İsoamil alkol	1.23	1.02	47.24	48.86
Anisol	0.58	0.79	10.02	7.75

5. TARTIŞMA VE SONUÇ

Çalışmada, çok bileşenli alkol karışımının damıtıldığı laboratuvar ölçekte sürekli çalışan dolgulu damıtma kolonunun yapay sinir ağları ile çok değişkenli kontrolü yapılmıştır. Çok bileşenli alkol karışımı olarak metanol, etanol, n-bütanol, isoamil alkol (1-pentanol) ve anisol (fenil-metil eter) bileşenlerini içeren beş bileşenli alkol karışımı kullanılmıştır. Kolonun üst ve alt ürün sıcaklıklarının, SISO ve MIMO kontrolü teorik ve deneysel olarak yapılmıştır. Kontrol algoritmasında yapay sinir ağı temelli model öngörmeli kontrol algoritması kullanılmıştır.

Kolonun öncelikle dinamik davranışını öğrenmek için dinamik deneyler yapılmıştır. Dinamik deney verilerinden istatistiksel model tanımlama yöntemiyle kolonun 1. mertebeden ölü zamanlı iletim fonksiyonları elde edilmiştir. Kolonda en az etkileşimin olduğu kontrol çiftini bulmak için bağıl kazanç matrisi analizi yapılmıştır. Üst ürün sıcaklığını kontrol etmek için geri akma oranı, alt ürün sıcaklığını kontrol etmek için de kazan ısısı ayarlanabilen değişken olarak seçilmiştir. Yapay sinir ağları kullanılarak kolon modeli oluşturulmuştur. Kolon modeli için çok tabakalı ileri beslemeli bir yapay sinir ağı tasarlanmıştır. Tasarlanan ağ geri yayılım algoritması ile eğitilmiştir. Eğitimin sonunda elde edilen bağlantı ağırlıkları temel alınarak model öngörmeli kontrol algoritması oluşturulmuştur.. Kontrol çalışmalarında sıcaklıklarının set noktalarına pozitif ve negatif kademe etkileri ile besleme çözeltisinin derişimine pozitif ve negatif etkiler verilmiştir. Kontrol sonunda kontrol edilen ve ayarlanabilen değişkenlerin değerleri zamana karşı grafiğe geçirilmiştir. Hata kareleri integrali (ISE) değerleri hesaplanarak kontrol edici etkinliği incelenmiştir.

Kontrol algoritması, teorik ve deneysel kontrolde sıcaklıkları set noktalarına getirmeyi başarmıştır. Teorik kontrolde daha az salınımla daha kısa sürede kontrol sağlanmıştır. Deneysel kontrol çalışmalarında, çeşitli aşamalarda alınan numuneler GC/MS'de analizlenmiştir. Analiz sonuçlarındaki üst ve alt üründeki etanol derişim değerlerine bakıldığında, sıcaklık kontrolü yapılırken etanol derişiminin de beklenildiği gibi değiştiği gözlenmiştir. MIMO kontrolün sistemdeki etkileşimlerden dolayı SISO kontrole göre daha zor olmasına rağmen başarı ile gerçekleştirildiği görülmüştür.

KAYNAKLAR

- Ay, S. 2006. Çok bileşenli bir karışımın damıtıldığı laboratuvar ölçekli dolgu damıtma kolonunun kısıtlanmış model öngörmeli kontrolü. Yüksek lisans tezi. Ankara Üniversitesi, 81 s., Ankara
- Bahar, A., Güner E., Özgen, C. and Halici, U. 2006. Design of state estimators for the inferential control of an industrial distillation column. Neural Networks, 2006. IJCNN '06. International Joint Conference on; 1112-1115.
- Brizuela, E., Uria, M. and Laamanna, R. 1996. Predictive control of a multi-component distillation column based on neural networks. Proceedings of the 1996 International Workshop on Neural Networks for Identification, Control, Robotics, and Signal/Image Processing (NICROSP '96); 270-278.
- Chu, J., Tsai, P., Tsai, W., Jang, S., Shieh, S., Lin, P. and Jiang, S. 2003. Multistep model predictive control based on artificial neural networks. Industrial & Engineering Chemistry Research, 42; 5215-5228.
- Dereli, T. 2000. Toplam kalite yönetiminin ışığı altında yapay zekanın endüstriyel problemlerin çözümünde kullanımı. Gaziantep Üniversitesi Mühendislik Fakültesi Konferans Salonu, www1.gantep.edu.tr/~dereli/turkce/tsky.ppt. Erişim Tarihi: 15.12.2006.
- Dutta, P. and Rhinehart, R. 1999. Application of neural network control to distillation and an experimental comparison with other advanced controllers. ISA Transactions, 38; 251-278.
- Fabro, J.A., Arruda, L.V.R. and Neves, F. 2005. Startup of a distillation column using intelligent control techniques. Computers and Chemical Engineering, 30; 309-320.
- Gadkar, K.G., Mehra, S. and Gomes, J. 2005. On-line adaption of neural networks for bioprocess control. Computers and Chemical Engineering, 29; 1047-1057.
- Hagan, M.T., Demuth, H. and Jesús, O. 2002. An introduction to the use of neural networks in control systems. International Journal Of Robust and Nonlinear Control, 12; 959-985.
- Haykin, S. 1997. Neural networks: A comprehensive foundation. Artech House Press, 842 p., Boston.
- Koç, L.M., Balas, C.E. ve Arslan, A. 2004. Taş dolgu dalgakıranların yapay sinir ağları ile ön tasarımı. IMO Teknik Dergi, 15(4); 3351-3375.

- Kumpati, S.N. and Kannan, P. 1997. Identification and control of dynamical systems using neural networks. IEEE Transactions on Neural Networks, 1(1); 4-27.
- MATLAB Version 6.5.0.180913a Release 13, June 18, 2002. Copyright 1984-2002, The MathWorks, Inc.
- Moore, W. 2005. Web sitesi. <http://www.cs.cmu.edu/~awm/tutorials/>, Eriřim Tarihi: 24.12.2006.
- Öztemel, E. 2005. Yapay sinir ağıları. Papatya Yayıncılık, 232 s., İstanbul.
- Bequette, B.W. 1998. Process dynamics modeling, analysis and simulation. Prentice Hall, 640 p., New Jersey.
- Rad, H.J. 2004. The nonlinear model-predictive control of a chemical plant using multiple neural networks. Neural Comput & Applic, 13; 2–15.
- Saraç, T. 2004. Yapay sinir ağıları. Seminer projesi. Gazi Üniversitesi Endüstri Mühendisliği Bölümü Ana Bilim Dalı, 75 s., Ankara.
- Sharma, R., Singh, K., Singhal, D. and Ghoshd, R. 2004. Neural network applications for detecting process faults in packed towers. Chemical Engineering and Processing, 43; 841–847.
- Singh, V., Gupta, I. and Gupta, H.O. 2005. ANN based estimator for distillation — inferential control. Chemical Engineering and Processing, 4; 785–795.
- Singh, V., Gupta, I. and Gupta, H.O. 2007. ANN-based estimator for distillation using Levenberg – Marquardt approach. Engineering Applications of Artificial Intelligence, 20; 249–259.
- Stephanopoulos, G. 1984. Chemical process control an introduction to theory and practice. PTR Prentice Hall International, 704 p., USA.
- Stergiou, C. and Siganos, D., 1996. Web sitesi. http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html, Eriřim Tarihi: 15.11.2006.
- Yalcin, E., Johan, A.K. and Suykens, P.L. 2001. Cellular neural networks, multi-scroll chaos and synchronization. World Scientific, 231 p., Singapore.
- Yurtoğlu, H. 2005. Yapay sinir ağıları metodolojisiyle öngörü modellenmesi. Uzmanlık tezi. Devlet Planlama Teřkilatı, 103 s., Ankara.

ÖZGEÇMİŞ

Adı Soyadı : Fatma VAROL

Doğum Yeri : Nevşehir

Doğum Tarihi : 07.11.1983

Medeni Hali : Bekar

Yabancı Dil : İngilizce

Eğitim Durumu

Lise : Atakent Anadolu Lisesi (1997 – 2001)

Lisans : Ankara Üniversitesi Mühendislik Fakültesi Kimya Mühendisliği
Bölümü (2001 – 2005)

Yüksek Lisans : Ankara Üniversitesi Fen Bilimleri Enstitüsü Kimya Mühendisliği
Anabilim Dalı (Eylül 2005 – Şubat 2008)

Çalıştığı Kurum/Kurumlar

PETKİM Petrokimya Holding A.Ş. Aliğa Kompleksi Alçak Yoğunluk Polietilen
(AYPE) Fabrikası (Staj; Temmuz 2004 – Ağustos 2004)