İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

HAVA ÖNGÖRÜSÜNDE UYARLANABİLİR ENSEMBLE MODELLEMESİ

DOKTORA TEZİ

Sedef ÇAKIR

Anabilim Dalı : Meteoroloji Mühendisliği

Programı : Meteoroloji Mühendisliği

NİSAN 2012

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

HAVA ÖNGÖRÜSÜNDE UYARLANABİLİR ENSEMBLE MODELLEMESİ

DOKTORA TEZİ
Sedef ÇAKIR
(511042101)

Tezin Enstitüye Verildiği Tarih : 03 Kasım 2011
Tezin Savunulduğu Tarih : 19 Nisan 2012

Tez Danışmanı : Prof. Dr. Mikdat KADIOĞLU (İTÜ)
Diğer Jüri Üyeleri : Prof. Dr. Zafer ASLAN (İAÜ)
Prof. Dr. Kasım KOÇAK (İTÜ)
Prof. Dr. Ömer L. ŞEN (İTÜ)
Yrd. Doç. Funda SEZGİN (İÜ)

NİSAN 2012

Aileme,

ÖNSÖZ

Bu çalışmada değerli bilgileriyle yol gösterip danışmanlık yapan Prof. Dr. Mikdat KADIOĞLU'na öncelikle teşekkürü bir borç bilirim. Ayrıca hiçbir konuda katkılarını esirgemeyen Dr. Nihat ÇUBUKCU'ya çok teşekkür ederim.

Tez süresince yaptıkları eleştiri ve katkılarından dolayı tez izleme jürisinde yer alan Prof. Dr. Kasım KOÇAK ve Prof. Dr. Ömer Lütfi ŞEN'e, tez savunma sınavındaki katkılarından dolayı Prof. Dr. Zafer Aslan ve Yrd. Doç. Funda Sezgin'e tüm kalbimle teşekkür ederim.

Her türlü eleştiri ve katkılarından dolayı Meteoroloji Mühendisliği Bölümü öğretim üyelerinden Prof. Dr. Zerefşan KAYMAZ, Prof. Dr. Yurdanur S. ÜNAL, Doç. Dr. Sevinç SIRDAŞ ve Dr. Ahmet ÖZTOPAL'a teşekkür ederim.

Ayrıca TÜBİTAK BİDEB'e ve KKTC Milli Eğitim Bakanlığı'na eğitimim süresince ayrı ayrı zamanlarda verdikleri maddi desteklerinden dolayı minnet duyuyor ve teşekkür ediyorum.

Çalışmada kullanılan FSUGSM modeline ait tahminleri sağlayan Weather Predict Inc. kuruluşuna teşekkür ederim.

Her türlü maddi, manevi desteklerinden dolayı Aileme sonsuz şükranlarımı sunarım. Bana her türlü manevi desteği veren ve yardımlarını esirgemeyen E. Ceren KALAFATOĞLU ve Dr. Ceyhan KAHYA'ya katkılarından dolayı minnettarım. Ayrıca Dr. Filiz T. KATIRCIOĞLU, Özlem BAYDAROĞLU ve Serhat YILMAZ başta olmak üzere bana destek olan tüm araştırma görevlisi arkadaşlarıma, 211 numaralı odadaki güzel arkadaşlıklara teşekkür ederim.

Tezim süresince bana katlanan, yanımda olan Derya AKÇAN, Duygu AKTAŞ ve Elif KOÇ'a, katkılarından dolayı Volkan DİLER'e ve her zaman yanımda hissettiğim tüm arkadaşlarıma teşekkür ederim.

Nisan 2012

Sedef Çakır
Meteoroloji Y. Mühendisi

İÇİNDEKİLER

Sayfa

ÖNSÖZ ..... **v**
İÇİNDEKİLER ..... **vii**
KISALTMALAR ..... **ix**
ÇİZELGE LİSTESİ ..... **xi**
ŞEKİL LİSTESİ ..... **xiii**
ÖZET ..... **xvii**
SUMMARY ..... **xix**
1. GİRİŞ **1**
2. ÇALIŞMA ALANI VE KULLANILAN VERİ **11**
2.1 Çalışma Alanının Genel Özellikleri 11
2.2 Çalışmada Kullanılan Veriler 13
3. KULLANILAN YÖNTEMLER **17**
3.1 Ensemble Tahmini 17
3.1.1 Başlangıç koşulları belirsizlikleri 20
3.1.2 Model belirsizlikleri 22
3.1.3 Ensemble üyelerini birleştirme yöntemleri 29
3.2 Çoklu lineer regresyon – Süperensemble 30
3.3 Yapay Sinir Ağları 35
3.3.1 YSA Sınıflandırması 38
3.3.2 Temel YSA işlemcisinin çalışması 39
3.3.3 Çoklu tabaka algılayıcı modeli ve geri-yayılım algoritması 40
4. UYGULAMA VE ANALİZ **45**
4.1 Model Konfigürasyonları 45
4.1.1 Kontrol ensemble sistemi (KTRL) 46
4.1.2 YSA ensemble sistemi konfigürasyonu 47
4.2 Değerlendirme Kriterleri 50
4.3 Model Sonuçlarının Analizi 53
4.3.1 Ensemble üyesi modellerin analizi 53
4.3.2 Ensemble tahmin sistemlerinin (KTRL-YSA-SE) analizleri 59
5. SONUÇ VE ÖNERİLER **87**
KAYNAKLAR **91**
EKLER **99**
ÖZGEÇMİŞ **113**

KISALTMALAR

APEC : Asia Pacific Economic Cooperation
BRNSHR : Bulk Richardson Number Shear
CAPE : Convective Available Potential Energy
ÇTA : Çok Tabakalı Algılayıcı
DEMETER : Development of a European Multimodel Ensemble System for Seasonal - to - Interannual Prediction
ECMWF : Avrupa Orta Vadeli Hava Tahmin Merkezi/European Center for Medium-Range Weather Forecasting
EFAS : Avrupa Sel Uyarı Sistemi/The European Flood Alert System
EC-EPS : ECMWF Ensemble Tahmin Sistemi
EPS : Ensemble Öngörü Sistemi/Ensemble Prediction System
ERNN : Elman Recurrent Neural Network
FSUGSM : Florida State University Global Spectral Model
GDA : Güneydoğu Anadolu
GOT : Geciktirilmiş Ortalama Tahmini
HEPEX : The Hydrological Ensemble Prediction Experiment
HFM : Hopfield Model
İEO : İşaret Eşleşme Oranı
İY : İyileşme Yüzdesi
KTRL : Kontrol Ensemble Sistemi
LM : Levenberg Marquardt
LVQ : Learning Vector Quantization
MAE : Ortalama Mutlak Hata/Mean Absolute Error
MCM : Monte Carlo Metodu
MLPN : Multi-Layer Perceptron Network
MLR : Çoklu Doğrusal Regresyon/Multiple Linear Regression
MM5 : Mesoscale Model
MOS : Model Output Statistics
MSC : Kanada Meteoroloji Servisi/Meteorological Service of Canada
MSC-EPS : MSC Ensemble Tahmin Sistemi
MSE : Hataların Kareli Ortalaması/Mean Square Error
NCAR : National Center for Atmospheric Research
NCEP : National Centers for Environmental Prediction
ODF : Olasılık Dağılım Fonksiyonu
OH : Ortalama Hata (Bias)
PAC : Pattern Anomaly Correlation
PM : Partikül madde/Particulate matter
PMMA : Perturbed-Model Multi-Analysis
RBFN : Radial Basis Function Neural Network
RMSE : Hataların Kareli Ortalamalarının Karekökü/Root Mean Square Error
SDF : Stokastik Dinamik Tahmin
SHÖ : Sayısal Hava Öngörüsü
SMMA : Single Model Multi-Analysis
SREF : Short Range Ensemble Forecasting

SREH **:** Storm-Relative Environmental Helicity
SVD **:** Tekil Değer Ayrıştırılması/Singular Value Decomposition
UWME **:** University of Washington Mesoscale Ensemble
YSA **:** Yapay Sinir Ağları

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1: Verileri kullanılan FSUGSM versiyonları ile ilgili ayrıntılı bilgiler..... 14
Çizelge 4.1: Gözlemlerdeki anomali işaretinin tahminlerdeki işaretlerle eşleşme tablosu. 52
Çizelge 4.2: Gözlenen değerler ve ensemble üyesi modellerin test tahminleri için bölgelere göre mevsimlik ortalama ve varyans değerleri. 54
Çizelge 4.3: Gözlem ve ensemble tahminlerinin mevsimlik ve bölgesel olarak ortalama sıcaklık anomalisi ve varyans değerleri. 61
Çizelge 4.4: Ensemble sistemlerinin mevsimlik ortalama hata değerlerinin bölgesel ortalamaları. 67
Çizelge 4.5: Tüm istasyonlar genelinde İlkbahar mevsiminde (>1°C) ve (<-1°C) anomali test değerleri için ensemble sistemlerinin uyum sayıları. 85
Çizelge 4.6: Yaz mevsiminde (>1°C) ve (<-1°C) anomali gözlemleri için ensemble sistemlerinin uyum sayıları. 85
Çizelge 4.7: Sonbahar mevsiminde (>1°C) ve (<-1°C) anomali gözlemleri için ensemble sistemlerinin uyum sayıları. 85
Çizelge 4.8: Kış mevsiminde (>1°C) ve (<-1°C) anomali gözlemleri için ensemble sistemlerinin uyum sayıları. 86
Çizelge A.1: Sıcaklık gözlemleri kullanılan istasyonlara ait enlem, boylam, rakım bilgileri. 100

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1: NCEP'in uygulamalı hava tahmininindeki başarısının zamanla değişiminin S1 ölçüsü ile değerlendirilmesi: a) 500 hPa yatay basınç gradyanı, b) Deniz seviyesi basıncı için……..3
Şekil 1.2: Ensemble tahmin şeması……...……...5
Şekil 2.1: Sıcaklık gözlemleri kullanılan istasyonların dağılımı ve topografyası…..12
Şekil 2.2: Adana istasyonuna ait ensemble üyesi modellerin eğitim veri setine örnek ……... 15
Şekil 3.1: Ensemble tahmin şeması. 18
Şekil 3.2: Tipik ensemble'a ait bileşenler: (a) İyi ensemble, (b) Kötü ensemble örneği. 19
Şekil 3.3: Süperensemble tahmin şeması..... 31
Şekil 3.4: Biyolojik sinir hücresi. 36
Şekil 3.5: Yapay Sinir Ağları mimarisine örnek. 36
Şekil 3.6: Yapay Sinir Ağları çalışma süreci. 37
Şekil 3.7: Örnek işlemci yapısı. 39
Şekil 3.8: Aktivasyon fonksiyonlarına örnekler, a) Sigmoidal, b) Doğrusal, c) Tanjant hiperbolik, d) Adım fonksiyonu. 40
Şekil 4.1: Uyarlanabilir sistemde eğitim ve test verisi belirlenmesi. 46
Şekil 4.2: Uyarlanabilir ve uyarlamasız KTRL sistemin test periyodu için tahminlerinin istasyonlara göre MAE değerleri. 47
Şekil 4.3: YSA ensemble sisteminin akış diyagramı..... 50
Şekil 4.4: Her bir istasyon için ensemble üyesi modellerin (AORG, ANRG, KNRG, KORG) ve kontrol ensemble sisteminin (KTRL) test periyodu tahminlerinin ortalama mutlak hata (MAE) değerleri. 56
Şekil 4.5: Akdeniz Bölgesi istasyonları için ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri..... 57
Şekil 4.6: Ensemble üyesi modellerin KTRL sistemin ortalama mutlak hata (MAE) değerlerine göre iyileşme yüzdesi (İY). 58
Şekil 4.7: Kontrol ensemble (KTRL) sistemine ait 50 test tahmini için MAE'lerin yersel dağılımları. 63
Şekil 4.8: YSA ensemble sistemine ait 50 test tahmini için MAE'lerin yersel dağılımları..... 63
Şekil 4.9: Süperensemble sistemine ait 50 test tahmini için MAE'lerin yersel dağılımları..... 63
Şekil 4.10: KTRL sistemine ait RMSE dağılımları. 64
Şekil 4.11: YSA ensemble sistemine ait RMSE dağılımları. 64
Şekil 4.12: Süperensemble (SE) sistemine ait RMSE dağılımları..... 64
Şekil 4.13: Ensemble tahmin sistemlerinin bölgelere göre sıralanmış istasyonlar için RMSE değerleri. 65
Şekil 4.14: Ensemble sistemlerinin mevsimlik RMSE (°C) değerleri..... 66
Şekil 4.15: YSA tahminlerinin KTRL tahminlerine göre RMSE değerleri bakımından iyileşme yüzdelerinin (İY) yersel dağılımı. 68

Şekil 4.16: Süperensemble tahminlerinin KTRL tahminlerine göre RMSE değerleri bakımından iyileşme yüzdelerinin (İY) yersel dağılımı. 68
Şekil 4.17: YSA ensemble sistemi tahminlerinin Süperensemble sistemi tahminlerine göre RMSE değerlerindeki iyileşme yüzdesi (İY). 69
Şekil 4.18: Bölgelere ayrılmış her bir istasyon için YSA ve SE sistemlerinin KTRL tahminlerinin MAE değerlerine göre İY'leri. 70
Şekil 4.19: Bölgesel olarak YSA ve SE sistemlerinin KTRL tahminlerinin MAE değerlerine göre İY(MAE) değerleri. 71
Şekil 4.20: Bölgesel olarak YSA ve SE sistemlerinin KTRL tahminlerinin RMSE değerlerine göre İY(RMSE) değerleri. 71
Şekil 4.21: Adana istasyonu için gözlem ve ensemble tahminlerinin mevsimlere ayrılmış olan test örneği. 73
Şekil 4.22: İnebolu istasyonu için gözlem ve ensemble tahminlerinin mevsimlere ayrılmış olan test örneği. 74
Şekil 4.23: Adana istasyonu için ensemble tahminlerinin mevsimlere göre RMSE (°C) değerleri. 75
Şekil 4.24: İnebolu için ensemble tahminlerinin mevsimlere göre RMSE (°C) değerleri. 75
Şekil 4.25: KTRL ensemble test tahminlerinin gözlem verilerine göre işaret eşleşme oranı (%) dağılımları. 77
Şekil 4.26: YSA ensemble sisteminin test tahminlerinin gözlem verilerine göre işaret eşleşme oranı (%) dağılımları. 77
Şekil 4.27: Süperensemble metodunun test tahminlerinin gözlem verilerine göre işaret eşleşme oranı (%) dağılımları. 77
Şekil 4.28: Bölgeler ortalamasında ensemble tahminlerinin (YSA ve SE) gözlem değerlerine göre işaret eşleşme oranlarının (İEO) KTRL tahminlerinin İEO'larına göre iyileşme yüzdeleri. 78
Şekil 4.29: Bölgelere göre gözlemlerde görülen (>1°C) ve (<-1°C) anomali değerlerinin görülme oranı. 79
Şekil 4.30: Tüm istasyonlar genelinde anomali değerleri (>1°C) ve (<-1°C) olan testlerin toplam mevsim değerleri içerisinde sayıca yüzdeleri. 80
Şekil 4.31: Tüm istasyonlar genelinde anomali değerleri (>1°C) ve (<-1°C) olan; a) KTRL, b) YSA tahminlerinin mevsimler içindeki sayıca yüzdeleri. 80
Şekil 4.32: Gözlem test verilerindeki (>1°C) ve (<-1°C) anomali değerlerinin mevsimlik değerler içindeki sayıca yüzdelerinin bölgesel değerleri. 81
Şekil 4.33: Gözlem anomalileri (>1°C) ve (<-1°C) olan tarihlerde ensemble tahminlerinin bu kriterlere uyduğu toplam tahmin sayıları. 82
Şekil 4.34: Ensemble sistemlerinin tüm testler genelinde (>1°C) ve (<-1°C) eşik değerli gözlem verilerini bölgesel olarak toplamda yakalama yüzdeleri. 83
Şekil 4.35: YSA, KTRL ve Süperensemble tahminlerinin, gözlemlerde görülen (>1°C) anomali değerli testler için bu değerlerle eşleşme yüzdeleri. 83
Şekil 4.36: YSA, KTRL ve Süperensemble tahminlerinin, gözlemlerde görülen (<-1°C) anomali değerli testler için bu değerlerle eşleşme yüzdeleri. 84
Şekil 4.37: Gözlem anomalileri (>1°C) ve (<-1°C) olan testler dikkate alındığında ensemble tahminlerinin RMSE (°C) değerleri. 86
Şekil B.1: Karadeniz Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri. 102
Şekil B.2: Marmara Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri. 102

Şekil B.3: Doğu Anadolu Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri. 103
Şekil B.4: GDA Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri. 103
Şekil B.5: Ege Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri. 104
Şekil B.6: İç Anadolu Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri. 104
Şekil C.1: Akdeniz Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri. 105
Şekil C.2: Marmara Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri. 106
Şekil C.3: Karadeniz Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri. 107
Şekil C.4: Doğu Anadolu Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri. 108
Şekil C.5: GDA Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri... 109
Şekil C.6: Ege Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri... 110
Şekil C.7: İç Anadolu Bölgesi istasyonlarına ait gözlenen ve ensemble tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri... 111

HAVA ÖNGÖRÜSÜNDE UYARLANABİLİR ENSEMBLE MODELLEMESİ

ÖZET

Güvenilir ve doğru hava tahmini bilgisine ulaşmak gündelik hayatla beraber birçok çalışma alanı için önemlidir. Kısa, orta veya uzun vadeli hava durumu veya iklim tahminlerinin iyileştirilmesi için, atmosferik olayların simülasyonunda kullanılan sayısal modellerin gerek başlangıç koşulları gerekse modellerde kullanılan eşitliklerdeki kabuller, yaklaşımlar ve değişebilen parametrelerden kaynaklanan hatalarının giderilmesi gerekmektedir. Bu hataların giderilebilmesi amacıyla ortaya konulan ensemble metodu, atmosferin kaotik bir yapıya sahip olduğu ve başlangıç koşullarına bağlılığının Lorenz tarafından gösterilmesinden sonra yaygın olarak kullanılmaktadır.

Ensemble metodunda, başlangıç koşullarına bağlı hataların giderilmesi amacıyla, çok küçük değişikliklere sahip, farklı başlangıç koşulları ile çalıştırılan model tahminleri en basit şekilde ortalamaları alınarak bir araya getirilmektedir. Modelin kendisinden kaynaklanan hatalar önemlidir ve bunların azaltılabilmesi için modelin eşitliklerinde, parametrelerinde ve/veya kabullerinde yapılacak değişiklikler ile çalıştırılması sonucu elde edilecek tahminler veya tamamıyla farklı merkezlerde geliştirilmiş model tahminlerinin bir araya getirilmesi mümkündür. Ensemble üyesi olarak elde edilen her bir tahminin bir araya getirilirken direk ortalaması veya performanslarına göre ağırlıklandırılmış ortalamaları alınabilir.

Bu çalışmada sayısal hava öngörü modellerindeki yapısal, fiziksel hatalar dikkate alınmış ve fiziksel şemalarında değişiklikler yapılmış olan atmosfer-okyanus modelinin dört farklı versiyonundan elde edilen iki haftalık ortalama sıcaklık tahminleri kullanılmıştır. Bu verilerden hesaplanan anomali değerleri üç farklı yolla bir araya getirilerek ensemble tahminleri elde edilmiş ve performansları kıyaslanmıştır. Bunlardan ilki; bias-düzeltmesi yapılmış ensemble ortalamasıdır. Kontrol tahmin olarak belirlenmiştir ve diğer iki yöntemin başarısı bu metoda göre değerlendirilmiştir. İkinci yöntem ise; lineer regresyon metoduna bağlı olarak model versiyonlarını performanslarına göre ağırlıklandırıp birleştiren Süperensemble metodunun uyarlamalı olarak çalışacak şekilde uygulanmasıdır. Üçüncü ve esas performansı üzerinde durulan ensemble sistemi ise Yapay Sinir Ağları metoduna dayalı olarak geliştirilmiştir ve ağırlıklandırma süreci yine uyarlanabilir olarak çalışmaktadır.

Türkiye genelinde 50 istasyon için uygulanan ensemble tahminlerinin genel doğruluk ve başarı değerlendirmeleri sonucu, kontrol ensemble sistemi olarak kabul edilen bias-düzeltmesi yapılmış ensemble tahminlerin ortalamasına göre, Süperensemble ve YSA'ya dayanan ensemble tahminlerinin daha başarılı olduğu ortaya konmuştur. Özellikle Karadeniz ve Marmara bölgesindeki kontrol tahmininin yüksek hata verdiği istasyonlarda üye modelleri ağırlıklandırarak ensemble tahminleri elde etmek büyük başarı sağlamıştır. YSA metodu ile elde edilen ensemble tahminlerin Süperensemble yöntemi ile yakın sonuçlar verdiği, fakat çoğu istasyonda YSA'nın daha başarılı tahminler yaptığı görülmüştür.

ADAPTIVE ENSEMBLE MODELLING FOR WEATHER PREDICTION

SUMMARY

Getting reliable and accurate weather prediction information is essential not only for our daily lives, but also in many study areas. To improve short, medium or long term weather forecasting or climate prediction, errors coming from the assumptions and the approach used in deriving the equations, errors due to the changing parameters and occurring as a result of the initial conditions that are given to the models in the simulation of atmospheric events should be overcome. The ensemble method which was put forth to decrease the aforementioned errors has been widely used after Lorenz showed that the atmosphere has a chaotic structure, and is very sensitive to its initial state.

To get rid of the errors due to the sensitivity to the initial state of the system, ensemble method simply by taking averages, combines the forecast of models which were simulated with minor differences in their initial values. The errors that are coming from the model are important and it is possible to reduce those errors by combining the results of model runs with modified equations, parameters and/or assumptions and postulates or results of models that are developed and run in different modeling centers. During this combination process direct average or weighted average of every forecast that is a member of the ensemble can be taken.

In this study, we are concerned with the errors coming from the numerical weather prediction models. We used two-week mean temperature values from four different coupled atmosphere-ocean models with modified physical schemes. Ensemble forecast of anomalies calculated from those values were brought together in three different ways, and their performances are compared. The first is the bias removed ensemble mean, which is chosen as the control forecast, and the others are compared accordingly. The second method contains the adaptive application of superensemble method which combines the weighted average of model versions that were produced by looking at the performances using linear regression techniques. Third and the most important method in this study is the Artificial Neural Network ensemble method and the weighting of averages is again adaptive in this method.

According to the accuracy of the ensemble forecast results based on Turkey-wide 50 stations, Superensemble and Neural Network ensemble forecasts are found to be more successful relative to the average of the control system, which is bias removed ensemble mean. Especially in Black Sea and Marmara regions with the highest forecasting errors of the control system, weighting of the ensemble member models give superior results. Forecasting results of Superensemble and Neural Network methods are close to each other in general, Neural Network based ensemble is found to be more successful in Turkey.

1. GİRİŞ

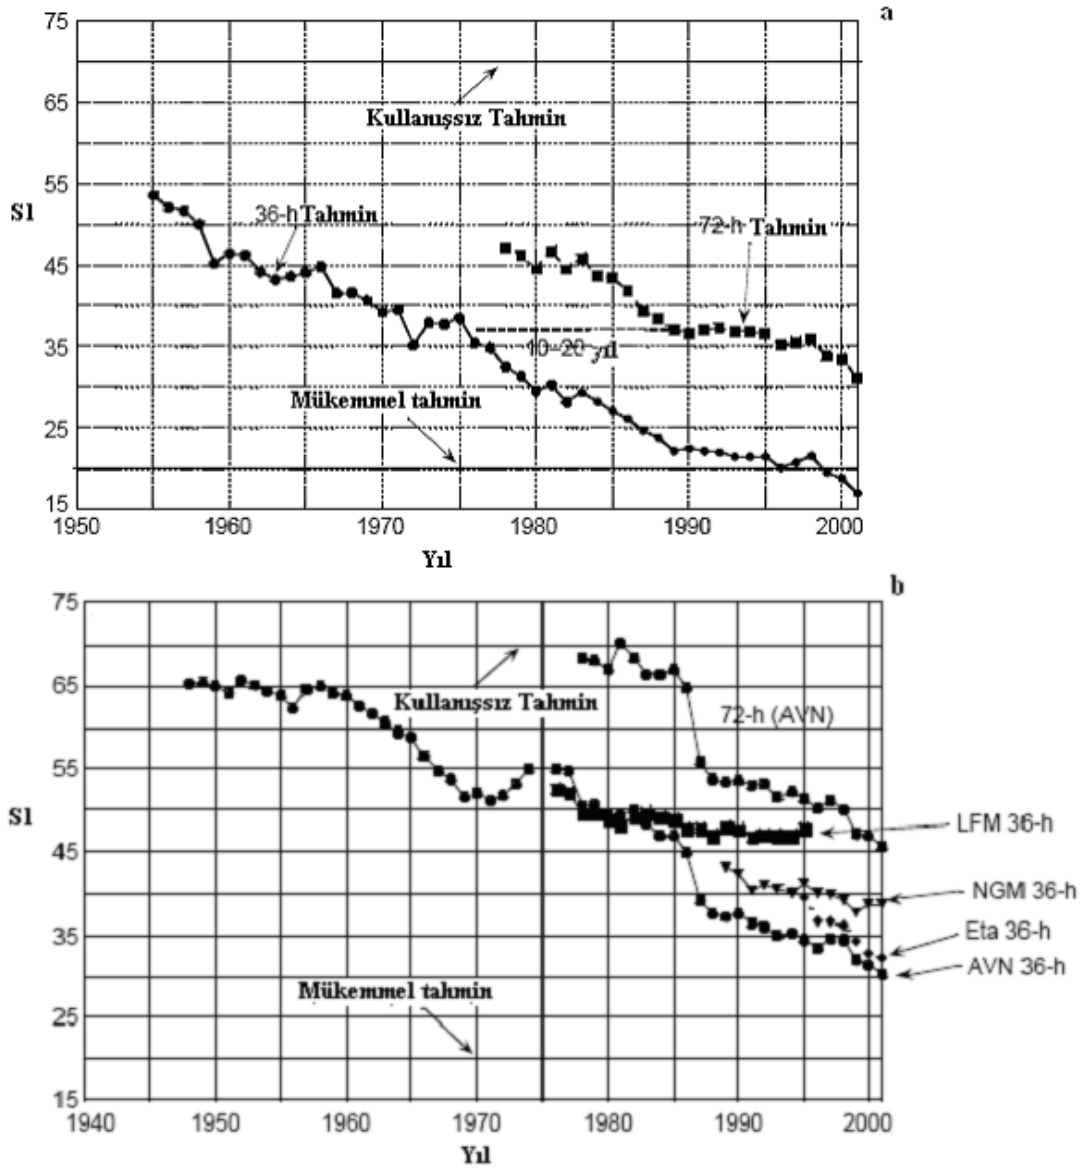
Üzerinde yaşadığımız Dünya'yı bir zarf gibi kuşatan ve "atmosfer" diye adlandırılan hava tabakasının herhangi bir zaman dilimi ve konumdaki durumu "hava durumu"dur. Atmosferik şartlar hayatın birçok alanını etkilediğinden (Buckley ve diğ., 2008), yapılan hava tahminlerinin doğru ve güvenilir olması gerekmektedir. Gerek kısa ve orta vadeli hava öngörüsü, gerekse uzun vadeli iklim tahminleri günümüzde giderek artan bir önem kazanmaktadır. Bu nedenle hava tahminlerinin iyileştirilmesi konusunda yıllardır süregelen çalışmalar yapılmaktadır. Küresel iklim değişikliği ile bağlantılı olarak sayılarının giderek arttığı öne sürülen, maddi ve manevi birçok kayba yol açan kuvvetli fırtınalar, sellere sebep olan şiddetli ve ani sağanaklar, sıcak hava dalgaları ve kuraklık gibi birçok şiddetli hava olayının öngörülmesi, gerekli ikazların zamanında yapılabilmesi için büyük önem taşımaktadır.

Eskiden elle çizilen haritalarla yapılan sinoptik hava öngörüsü, günümüzde gelişen bilgisayar teknolojileri sayesinde yerini sayısal hava analizi, vb modern tahmin modellerine bırakmıştır. Bilgisayarların gücünü kullanarak tahmin yapan sayısal hava öngörüsü (SHÖ) fikri 1922 yılında Lewis Fry Richardson'ın Weather Prediction by Numerical Process yayınıyla ortaya çıkmıştır (Buizza, 2003). Richardson, hareket eşitliklerini sayısal olarak bütünleştirmeyi amaçlamış ve bunun kesin olarak nasıl yapılabileceğini göstermiştir. Ancak metodunu test etmek için kullandığı gerçek tahmin başarısız olduğundan çalışmasını değerlendirememiştir (Kalnay, 2003). Hem başlangıç verilerindeki yetersizlik hem de yaklaşımındaki ciddi problemlerden dolayı elde ettiği sonuçlar oldukça başarısızdır (Buizza, 2002). Ayrıca o yıllarda tahmini yapılacak olan olay gerçekleşmeden önce, yapılması gereken çok sayıda hesaplamayı tamamlayacak güçte ve hızda bilgisayarlar mevcut değildi. 1970'lere gelindiğinde SHÖ dünya çapındaki birçok hava tahmin merkezinde uzun süredir kullanılmaktaydı. Örneğin, NCEP (National Centers for Environmental Prediction) 1950'den beri uygulamalı bilgisayar hava tahmini yapmaktadır ve

1955'ten 1973'e kadar sadece kuzey yarımküre için yapılan tahminler, 1973'ten itibaren küresel olarak yapılmaya başlanmıştır (Kalnay, 2003).

Tahmin modeli olarak da bilinen karmaşık bilgisayar programları, süper bilgisayarlarda çalıştırılarak elde edilen sıcaklık, basınç, rüzgar, özgül nem ve su buharı içeriğinin yersel dağılımları vasıtasıyla atmosferin durumu tanımlanır. Sistemin zamanla gelişimini tahmin etmek için kullanılan diferansiyel denklemler, Newton'un hareket yasasını, kütle ve enerjinin korunumu ve termodinamik kanunlarını içermektedir. Bu eşitlikler radyatif transfer, türbülanslı karışma, orografik zorlama ve nem süreçleri gibi fiziksel süreçlerin etkilerini temsil eden parametrizasyon şemaları da içermektedir. SHÖ modelleri bu sistem denklemlerini çözerek atmosfer durumundaki değişimleri tahmin etmektedir (Buizza, 2003; Taylor ve Buizza, 2006).

SHÖ'nün zaman içerisinde başarısındaki gelişmeyi gösteren en uzun kayıt Şekil 1.1.a'da yer almaktadır. Hava tahmin haritalarındaki hataların ilk ölçüsü olan S1 değeri (Teweles ve Wobus, 1954), Kuzey Amerika için yapılan 36 saatlik tahminlerde, 500 hPa sabit basınç seviyesi yüksekliklerinin yatay gradyanındaki bağıl hatayı ölçmektedir. %70 ve üzeri S1 değerleri tahminin kullanışsız olduğunu, %20 ve daha düşük değerler ise tamamıyla mükemmel bir tahmin olduğunu göstermektedir. Bilgisayar tahminleri, 36 saatlik tahmin içerisinde havanın genel gelişimini belirleyen büyük ölçekli atmosferik dalgalar, temel yüksek ve alçak basınç merkezlerinin yerlerini ve şiddetlerini genellikle çok iyi belirleyebilmektedir. Ayrıca şekilden görüldüğü gibi 2000 yılına gelindiğinde 72 saatlik tahminler, 10-20 yıl önceki 36 saatlik tahminler kadar doğrudur. Diğer taraftan, deniz seviyesi basıncı tahminleri, cepheler, yaz yağışlarını idare eden mezo-ölçekli konvektif sistemler gibi küçük ölçekli atmosferik olayların tahmininde önemlidir ve gelişimlerinin detaylı olarak izlenerek tahmin edilmesi, son yıllardaki büyük ilerlemelere rağmen hala zordur. Şekil 1.1.b'de görüldüğü gibi ortalama deniz seviyesi basıncı için S1 değeri 2000 yılında %20'lerin üzerindedir (Kalnay, 2003).



Şekil 1.1: NCEP'in uygulamalı hava tahminindeki başarısının zamanla değişiminin S1 ölçüsü ile değerlendirilmesi: a) 500 hPa yatay basınç gradyanı, b) Deniz seviyesi basıncı için (Kalnay, 2003).

Kalnay (2003), kitabında son 40 yılda sayısal hava tahminindeki başarının artmasını dört sebebe bağlamıştır. Bunlar:

1) Uygulamalı atmosferik modellerde daha hassas sayısal çözümler yapabilen ve daha az sayıda kabullere imkan sağlayan süper bilgisayarların geliştirilmesi,

2) Küçük ölçekli fiziksel süreçlerin (bulutlar, yağış, ısı, nem, momentumun türbülansla taşınımı ve radyasyon) ifade edilmesindeki gelişmeler,

3) Modeller için iyileştirilmiş başlangıç koşulları sağlayan daha doğru veri asimilasyonu metodları kullanılması,

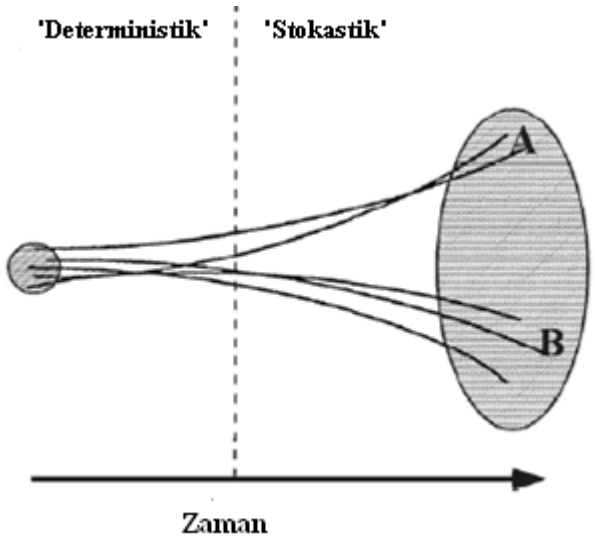
4) Veriye ulaşımın kolaylaşmasıdır.

Atmosferik modellerin entegrasyonu bir çeşit başlangıç değer problemi olduğundan başarılı bir tahmin yapmak için hem atmosferi gerçekçi bir şekilde tasvir eden bir bilgisayar modeli hem de hatasız başlangıç koşulları gereklidir (Kalnay, 2003; Mitra ve diğ., 2011). Sayısal modelleme son 30 yılda oldukça geliştirilmiş, tahminlerdeki doğruluk artmış ve orta vadede tahmin uzunluğu ile görülen sistematik hatalar azaltılmış olsa da hala global veya bölgesel ölçekli modellerde, hem kullanılan formüller, yatay-dikey çözünürlük, parametrizasyon şemaları gibi yapısal kaynaklı hem de başlangıç koşullarına bağlı hatalar mevcuttur (Mitra ve diğ., 2011).

Atmosferin kaotik bir sistem olması nedeniyle tahminin başlangıç koşullarındaki küçük bir hata hızla büyür ve tahmin edilebilirliği etkiler. Modeller için saptanmış başlangıç koşullarındaki belirsizlikler, gözlem aletleri (Stensrud ve diğ., 1999), uydu öngörüleri ve kullanılan veri asimilasyon metoduna bağlıdır (Mitra ve diğ., 2011). Ayrıca sayısal modelin atmosferik süreçleri yaklaşık olarak simule etmesine bağlı olan model hataları da tahmin başarısını sınırlamaktadır. Hatta bu hatalar tahminin tamamıyla yanlış olmasına ve tahmini atmosfer durumunun gerçek atmosfer durumuyla hiçbir bağlantısının kalmamasına neden olacak kadar büyüyebilir. Tek bir modelleme sisteminin tahmin başarısını arttırmak için modelleme ve veri asimilasyonu konusunda yapılacak olan araştırma/geliştirme çalışması oldukça uzun bir süreçtir (Mitra ve diğ., 2011). Bu nedenle günümüzde birçok meteoroloji servisi modellerdeki bu belirsizliklerin azaltılmasında oldukça başarılı bir yöntem olan ensemble metodunu kullanmaktadır.

SHÖ kapsamında ensemble tahmini fikri Lorenz (1965) ve Epstein (1969) tarafından ortaya çıkarılmıştır (Toth ve Kalnay, 1993) ve gelecekteki hava olayları ile durumlarının olasılığını hesaplama amacına sahiptir (Epstein, 1969; Leith, 1974; Stensrud ve diğ., 1999). Çünkü başlangıç koşulları kesin olarak bilinmemekle beraber tek bir deterministik tahmin başlangıç koşullarındaki küçük belirsizliklere karşı oldukça hassastır. Şekil 1.2, küçük bir aralıkta farklı başlangıç koşullarından başlatılan bireysel tahmin yörüngelerinin bir kaç gün sonra elipsle gösterildiği gibi çok daha büyük aralıkta sonuçlar vereceğini göstermektedir. Kısa vadede tahminler birbirlerine yakın oldukları için deterministik olarak düşünülebilirken bir süre sonra tahmin stokastik olmaktadır. Tahminler, benzer yörüngelere sahip gruplarda (Şekil 1.2'de A ve B gibi) toplanabilir. Tahminci, gelecekte gerçekleşebilecek hava

olaylarının olasılığını, her gruptaki tahmin sayısı ile ilişkilendirebilir (Tracton ve Kalnay, 1993; Bramer, 1998).



Şekil 1.2: Ensemble tahmin şeması (Tracton ve Kalnay, 1993).

Bir ensemble tahmini, sayısal hava tahmin modellerinin birçok kez (tipik olarak 5 ile 100 arasında) başlangıç koşullarına yapılacak küçük pertürbasyonlarla ve/veya model fiziğinde, parametrelerinde yapılacak değişiklikler ile çalıştırılması sonucu elde edilecek farklı tahminlerden oluşmaktadır (Gneiting ve Raftery, 2005). Ensemble 'üyesi' olarak adlandırılan her bir tahminin bir araya getirilmesiyle elde edilen yeni tahmin 'ensemble' tahmindir. 1960'lardan beri farklı tahminlerin birleştirilmesinden elde edilecek ortalama olasılık tahmininin, en başarılı kabul edilen tek bir olasılık tahmininden daha başarılı olduğu Sanders (1973), Bosart (1975) ve Gyakum (1986) tarafından yapılan çalışmalarla da doğrulanmıştır (Warner, 2011).

Ensemble tahmini ilk olarak başlangıç koşullarındaki kaçınılmaz hatalara bağlı olan tahmin belirsizliklerini öngörmek üzere geliştirilmiştir. Bu amaçla 1990'lardan itibaren operasyonel tahmin merkezleri Monte Carlo Metodu (MCM), tekil vektörleri, türetme vektörleri (Toth ve Kalnay, 1993) gibi yöntemlerle elde ettikleri kendi başlangıç pertürbasyonlarıyla çalışan küresel ensemble sistemlerine sahiptirler. Örneğin ECMWF (European Center for Medium-Range Weather Forecasting) tekil vektör yaklaşımıyla elde ettiği 32 üyeli ensemble sistemini geliştirerek, 2008 yılından itibaren 51 ensemble üyesi ile operasyonel olarak çalışırken (Buizza ve diğ., 2009) NCEP, türetme vektörü yaklaşımını kullanmaktadır.

İlk ensemble araştırmaları uzun ve orta-vadeli (> 2 gün) tahminlerin iyileştirilmesi üzerine odaklanmıştı fakat 1990'lı yılların ikinci yarısından itibaren kısa-vadeli ensemble tahminleri ile ilgili çeşitli çalışmalar da yapılmaktadır (Brooks ve diğ., 1996; Hamill ve Colucci, 1996; 1998; Stensrud ve diğ., 1998; 2000) ve ensemble tahminlerinin kullanımında son 10 yılda artış gözlenmiştir (Buizza ve diğ. 2009). Avrupa'da özellikle tarım ve sağlık sektörlerine yönelik bir ensemble sistemi geliştirmeyi amaçlayan Development of a European Multimodel Ensemble System for Seasonal to Interannual Prediction (DEMETER) projesi (Palmer ve diğ., 2004), İtalya'da Joint Research Center tarafından uygulanan ve ensemble tabanlı sel tahmin sistemi olan Avrupa Sel Alarm Sistemi (EFAS, European Flood Alert System) (Buizza ve diğ., 2009), Hidrolojik Ensemble Tahmin Çalışmaları (HEPEX, The Hydrological Ensemble Prediction Experiment) projesi (Thielen ve diğ., 2008) bu önemli çalışmalara örnek olarak verilebilir.

Başlangıç koşulları hava ve iklim tahminindeki belirsizliğin tek sebebi olmadığından, model kaynaklı hatalar üzerinde de durulması gerekmektedir. Fakat model hatalarının öngörülmesi hala analitik çözümlerin eksikliğinden dolayı oluşan bir problemdir (Palmer, 2001; Doblas-Reyes ve diğ., 2004). Bu problemle başa çıkmanın yolu çok-modelli veya çok-parametrizasyonlu ensemble (Houtekamer ve diğ., 1996; Stensrud ve diğ., 2000) ve parametrelerde yapılacak değişikliklere dayalı ensemble (Reynolds ve diğ., 2011) tahminleri geliştirilmesine bağlıdır.

Daha başarılı ve güvenilir bir tahmin olasılık yoğunluk fonksiyonu elde etmek için farklı tahmin sistemlerinin sonuçları çeşitli şekillerde bir araya getirilebilir. Dinamik tahmin durumunda birkaç farklı modeli ensemble üyesi olarak kullanmak iklim sisteminin simülasyonunda model belirsizliklerini hesaba katmanın bir yoludur. Ayrıca, bu modellerin her biri çok az farklı başlangıç koşulları ile çalıştırılırsa, bu çok-modelli ensemble sisteminde hem başlangıç koşulları hem de modellerdeki belirsizlikler dikkate alınmış olur (Doblas-Reyes ve diğ., 2004). Bir çok çalışmada tek ve çok-modelli ensemble tahmin başarısı ortaya konmuştur (Doblas-Reyes ve diğ., 2000; Graham ve diğ., 2000; Palmer ve diğ., 2004; Yun ve diğ., 2005). Eşit olarak ağırlıklandırılan tek modelli ensemble sisteminin basit bir çok modelli ensemble sistemine göre daha başarısız tahminler ürettiği de çeşitli çalışmalarla gösterilmiştir (Doblas-Reyes ve diğ., 2004).

Çok-modelli sistemler, farklı model tahminlerinin direk olarak ortalamalarının alınması yanında her bir modeli performanslarına göre ağırlıklandırarak da sisteme dahil etmektedir. Ağırlıklandırma yapılırken kullanılan yöntemler ve sistemin oluşturulması çeşitlilik göstermektedir ve hangi metotla birleştirilirse birleştirilsin çalışmalar çok-modelli ensemble sistemlerinin tahminin başarısını arttırdığını göstermektedir (Weigel ve diğ., 2008). Krishnamurti ve diğ.'nin (1999) geliştirdiği çoklu lineer regresyon metoduna dayalı Süperensemble ve tekil değer çözümlemesi (Kar ve diğ., 2006) bu yöntemlerden bazılarıdır Bu lineer yöntemlere alternatif olarak, lineer olmayan problemlerin çözümünde başarıyla uygulanan Yapay Sinir Ağları (YSA) metodunun kullanılması çeşitli çalışmalarda önerilmiştir (Krishnamurti ve diğ., 2000).

YSA genel anlamıyla beynin bir işlevi yerine getirirken izlediği yöntemleri modellemeye çalışan bir sistemdir ve günümüzde insanların ve bilgisayarların çözümlemesi zor olan problemler için geliştirilip birçok alanda kullanılmaktadır (Comrie, 1997). Tahmin, fonksiyon tanımlama ve sınıflandırma gibi problemlerde oldukça kullanışlıdır (Ul-Saufie ve diğ., 2011). Hava tahmini konusunda ilk kez Hu (1964) tarafından uygulanan YSA metodunun, atmosferin kaotik yapısının ortaya konulmasından sonra (Chattopadhyay ve Chattopadhyay, 2008) atmosfer bilimleri alanında çeşitli olayların modellenmesinde kullanılması giderek artmıştır (Diyankov ve diğ.,1992; Hsieh ve Tang, 1998; Yuval, 2000).

Maqsood ve Abraham (2006), YSA'ların iki sebepten ötürü hava tahmini problemlerinin çözümünde oldukça uygun olduğunu belirtmiştir. Bunlardan ilki, YSA'nın herhangi bir sürekli fonksiyonu sayısal olarak beklenen doğruluğa yaklaştırabilmesidir. Bu bakımdan çok değişkenli, lineer ve parametrik olmayan (Hornik ve diğ., 1989; Yuval, 2000) bir metot olarak görülebilir. Hava tahmini gibi karmaşık ve lineer olmayan ilişkileri, sıradan lineer modellere göre daha iyi modellemesi beklenebilir. İkincisi ise, YSA veriyle güdülen metotlardır, araştırmacının deneme modelleri önermesine ve parametrelerini tahmin etmesine gerek yoktur. Verilen bir girdi ve çıktı vektörleri arasındaki ilişki otomatik olarak oluşturulabilmektedir (Maqsood ve Abraham, 2006).

YSA'nın kendine özgü yapısı ve her bir gizli tabaka ve çıkış tabakası birimleriyle ilişkili olan lineer-olmayan aktivasyon fonksiyonları YSA'nın bir kabul yapmaksızın (Gardner ve Dorling, 1998; Ul-Sufie ve diğ., 2011) lineer-olmayan ilişkileri büyük

oranda yakalamasına imkan sağlamaktadır. Ayrıca diğer lineer teknikler bir fonksiyonel form kabul ederken YSA verinin bir fonksiyonel form belirlemesine imkan sağlamaktadır (Liu ve diğ., 2007).

Lineer regresyon ile YSA yöntemlerinin atmosfer bilimleri ile ilgili çeşitli konularda uygulanması ve kıyaslanması ile ilgili çalışmalar yapılmıştır (Rixen ve Coelho, 2007; Liu ve diğ, 2007; Ul-Saufie ve diğ., 2011). Örneğin, Liu ve diğ. (2007) tarafından yapılan çalışmada ensemble hava tahminleri için ölçek küçültme yapılmasında lineer regresyon metodu, genetik programlama ve yapay sinir ağları yöntemleri karşılaştırılmıştır. Lineer-olmayan ilişkileri de ortaya koyabilmesi açısından YSA'nın sıcaklık minimumları ve yağışların ölçek küçültmesinde istatistiksel yöntem olan lineer regresyon metodundan daha başarılı olduğu gösterilmiştir.

Tarım, havacılık, ulaştırma/ulaşım gibi birçok alan için gelecekteki hava durumu bilgisi oldukça önemlidir. Enerji sektörü de bunlardan birisidir ve gelecekteki günler, aylar ve hatta yıllarda hava koşullarının nasıl olacağını bilmek, ısıtma veya soğutmada kullanılacak yakıt ve elektrik enerjisi miktarını bu duruma göre belirlemek ekonomik açıdan da kritik rol oynamaktadır (Şen ve diğ., 2000; Taylor ve Buizza, 2002). Bu nedenle özellikle sıcaklıklarda meydana gelecek değişimlerin öngörüsü enerji politikalarını belirlemek açısından önemlidir. Örneğin, Durmayaz ve Kadıoğlu'nun (2001) çalışmalarında Adana için 1°C'lik sıcaklık artışının soğutma ihtiyacını %35 arttırdığı ortaya konulmuştur (Kadıoğlu, 2001). Ayrıca sıcak ve soğuk hava dalgalarının belirlenmesinde sıcaklık anomalilerinin hesaplanması önemlidir ve bu yönde çalışmalar yapılmaktadır (Schär ve diğ., 2004).

Bu çalışmanın amacı, Türkiye için uygulanabilecek başarılı bir ensemble sistemi ortaya çıkarmaktır. Bunu yaparken, sistemlerin performansını ortaya koymak ve başarıyı göstermek amacıyla kontrol sistemi olarak bias-düzeltmesi yapılmış ensemble ortalaması tahminleri kullanılmıştır. Lineer-regresyon yaklaşımına dayanan Süperensemble yöntemi de adaptif bir yol izlenerek Türkiye için uygulanmıştır. Ayrıca, lineer olmayan problemlerin çözümündeki başarısı ve uygulama alanları giderek artan YSA metoduna dayanan uyarlanabilir ensemble tahmin sistemi geliştirilerek performansları çeşitli ölçülerle/açılardan değerlendirilmiştir. Üç sistem arasında kıyaslamalar yapılarak en başarılı sistemin ortaya konulmasına çalışılmıştır.

Çalışmada kullanılan veriler, Florida State Üniversitesi'nde geliştirilmiş küresel atmosfer-okyanus modelinin farklı konveksiyon ve radyasyon şemalarına sahip 4 versiyonundan elde edilmiş, iki haftalık ortalama sıcaklık tahminleridir. Mevcut veri 1990-2005 yıllarını kapsamaktadır. Türkiye genelinde 50 farklı istasyonun enlem ve boylam bilgilerine göre interpole edilmiş bu model tahminleri diğer bir deyişle ensemble üyeleri girdi verisi olarak, işlenmiş NCEP/NCAR (National Centers for Environmental Prediction/National Center for Atmospheric Research) analiz verileri ise hedeflenen gözlem verisi olarak kullanılmıştır. Sıcaklık anomalilerinin tahmini daha büyük önem taşıdığından anomali değerleri sistemlerin girdi ve çıktı verileri olarak ele alınmıştır.

Çalışmada kullanılan veriler ve çalışma alanı ile ilgili bilgiler 2. Bölümde daha ayrıntılı olarak verilmiştir. Bölüm 3'de ilk yöntemlerden başlayarak günümüzde yaygın olarak kullanılan ensemble tahmin yöntemlerine değinilmiştir. Ayrıca çalışmada kullanılan esas yöntemler olan Süperensemble metodu ve Yapay Sinir Ağları ve çalışma prensipleri ile ilgili ayrıntılı bilgiler bu bölümde yer almaktadır. 4. Bölümde çalışmada kullanılan yöntemlerin konfigürasyonlarına ve yapılan çeşitli uygulama ve analizlere değinilmiştir. Sonuç ve öneriler Bölüm 5'de yer almaktadır.

2. ÇALIŞMA ALANI VE KULLANILAN VERİ

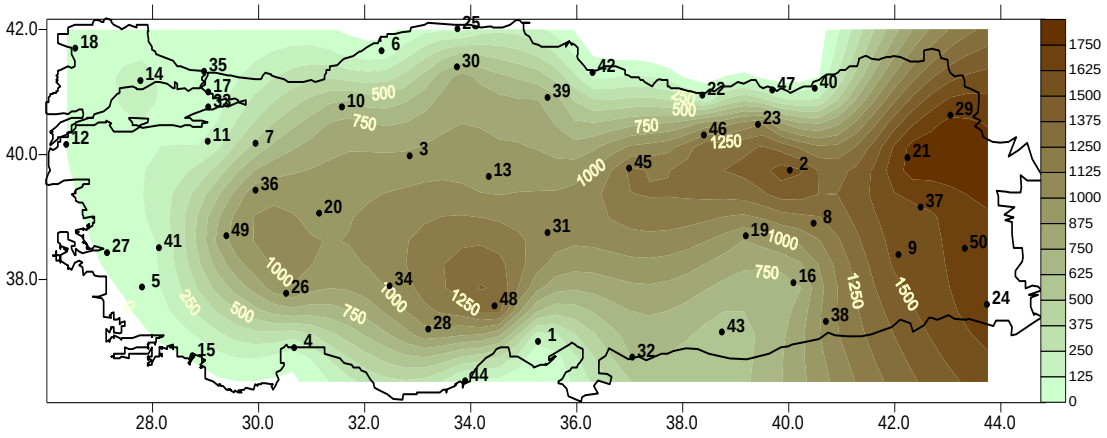
Bu çalışmada, Türkiye genelinde seçilen 50 istasyona ait sıcaklık tahminleri kullanılmış ve bu istasyonlar için adaptif bir ensemble sistemi geliştirilerek tahminlerin iyileştirilmesi hedeflenmiştir. Kullanılan istasyonların isimleri ile birlikte enlem boylam ve rakım bilgileri Çizelge A.1'de verilmiştir. Ülke genelinde birçok istasyon verisiyle çalışılarak ensemble sisteminin farklı topografik özelliklerdeki bölgelerde ortaya koyacağı performanslar değerlendirilmeye çalışılmıştır. Bu bölümde çalışma alanının genel iklimsel ve coğrafik özellikleri ile birlikte, çalışmada kullanılan verilere ait bilgiler verilmiştir.

2.1 Çalışma Alanının Genel Özellikleri

Türkiye, 36°-42° kuzey enlemleri ile 26°-45° doğu boylamları arasında, Asya ve Avrupa kıtalarında toprakları bulunan bir yarımadadır. Güneyinde Akdeniz, batısında Ege Denizi ve kuzeyinde Karadeniz ile çevrelenmiş topoğrafyada belirgin farklılıklar gözlenmektedir. Çok kısa mesafelerde ekolojik şartlar ani şekilde değişmektedir. Avrupa kıtasında engebeli araziler, Asya kıtasında ise kuzey ve güney kıyıları boyunca dağ sıralarıyla çevrelenmiş yüksek bir plato görülmektedir. 800 ile 1000 m aralığında yüksekliklere sahip bu plato doğudan Ege kıyılarına kadar çok daha yüksek dağlarla uzanmaktadır. Şekil 2.1'de bölgenin topografyasını gösteren haritada da bu yükseklikler görülmektedir. Kuzeyde Karadeniz'deki dağlar ve güneyde Toros Dağları oldukça diktir ve sahil şeridine paralel uzanmaktadırlar (Oğuz, 1999). Türkiye genelinde ortalama yükseklik yaklaşık 1132 metredir.

Çalışmada seçilen istasyonların dağılımları Şekil 2.1'de de görüldüğü gibidir. Alfabetik sıraya göre numaralandırılan istasyonlar 7 coğrafik bölgeyi de temsil edecek şekilde seçilmiştir. Sayısal olarak dağılımlara bakıldığında istasyonların 4'ü Akdeniz, 10'u Karadeniz, 9'u Marmara, 8'i Doğu Anadolu, 5'i Güneydoğu Anadolu, 7'si Ege ve 7 tanesi de İç Anadolu Bölgesi'nde yer almaktadır. Ayrıca Şekil 2.1'de çalışılan tüm bölgenin topografyasını genel olarak ortaya koymak amacıyla istasyonların rakım bilgilerinden elde edilen eş yükselti eğrileri görülmektedir. En

yüksek rakıma sahip bölge Doğu Anadolu Bölgesidir ve mevcut rakım bilgilerine göre çalışmada kullanılan istasyonların ortalama yüksekliği 691 metredir.



Şekil 2.1: Sıcaklık gözlemleri kullanılan istasyonların dağılımı ve topografyası.

Kompleks topografya, yeryüzündeki radyasyon akılarını, temel enerji kaynak ve kuyularını önemli şekilde etkilemektedir. Bu nedenle hava tahmininin iyileştirilmesi için radyasyon parametrizasyon şemaları, topografik etkileri en iyi şekilde temsil etmek üzere oluşturulmaya çalışılmaktadır. Mezo-ölçekli hava öngörü modelleri genellikle birkaç kilometre çözünürlükte çalışmaktadır ve büyük vadileri çözümleyebilmektedirler. Fakat eğimli yüzeyler düzleştirilmekte ve topografik ayrıntılar çözülememektedir, bu nedenle radyasyon hesaplarının etkisi burada küçüktür (Müller ve Scherer, 2005). Küresel modellerde ise çözünürlüğün azalmasıyla birlikte mevcut topografik etkilerin daha fazla gözden kaçtığı açıktır.

Kışın polar, yazın tropikal hava kütlelerinin etkisi altındaki Türkiye'de karasal ve denizsel alt hava kütleleri gözlenmektedir (Şensoy, 2004). Sahil kısımlarında Akdeniz iklimi hakimken iç ve doğu kısımları yarı kurak iklim kuşağında yer almaktadır. Akdeniz iklimi yazları sıcak ve kuru, kışın ise ılık ve yağışlı hava şartlarına sahiptir. Subtropikal yüksek basınç merkezlerinin karaların batı kısımlarına doğru hareketi mevsimsel farklılıklara yol açmaktadır. Yazları bu merkezler kutuplara doğru kaydığından doğudaki bölgeler kuru, ılık ve güneşli olarak kalmaktadır. Kışın bu yüksek merkezler tekrar ekvatora doğu hareket ederek yağmur taşıyan orta-enlem fırtınalarının farklı bir bölge yapmasına imkan vermektedir. Yarı-kurak iklim kuşakları yıllık 250 ile 760 mm yağış alan bölgelerdir (Buckley ve diğ., 2008).

Türkiye İklim Değişikliği Ulusal Bildirimi'nde (2007) Türkiye'nin özellikle batı ve güney batı bölgelerinde olmak üzere yaz sıcaklıklarında göze çarpan bir artış olduğu belirtilmiştir. Akdeniz şehirlerinin ise kentleşmeye bağlı olarak sıcaklık artışlarının en fazla etkili olduğu bölgeler olduğu çeşitli çalışmalarla ortaya konmuştur. Kış sıcaklıklarında ise özellikle kıyı bölgelerinde olmak üzere ülke genelinde bir sıcaklık azalışı tespit edilmiştir (UNDP, 2007)

2.2 Çalışmada Kullanılan Veriler

Çalışmada ensemble üyesi olarak kullanılan tahminler FSU'de geliştirilmiş okyanus-atmosfer modelinin (FSUGSM) 4 farklı versiyonuna aittir. Bu versiyonlar model konfigürasyonunda kullanılan kümülüs parametrizasyon ve radyasyon şemaları bakımından farklılık göstermektedir. Modellerle ilgili ayrıntılı bilgiler ve kullandıkları şemalar Çizelge 2.1'de verilmiştir. KNRG, KORG, AORG ve ANRG gibi isimlendirmede kullanılan ilk harfler Kuo veya Arakawa-Schubert kümülüs parametrizasyon şemalarını, ikinci harfler ise radyasyon şemasının yeni (N-new) versiyondaki band şeması veya eski (O-old) şema olan emssivity-absorbtivity olduğunu göstermektedir (Ross ve diğ., 2007). Gözlem verisi olarak ise NCEP/NCAR'ın işlenmiş verileri kullanılmıştır.

İşlenmiş NCEP/NCAR verisi, işlenmiş veriler arasında en yaygınıdır ve veri asimilasyon yöntemleri kullanılarak yaklaşık son 50 yıllık yeryüzeyi ve yukarı atmosfer ölçümlerinin/alet gözlemlerinin küresel modelleri beslemesi ile tüm troposfer ve aşağı stratosferdeki atmosfer durumu hakkında kapsamlı bilgi elde edilmesi işleminin ürünleridir. NCEP/NCAR işlenmiş verileri orta enlemlerde 200 km çözünürlüktedir ve 1948'den günümüze kadar olan dönemi kapsamaktadır (Kalnay ve diğ., 1996). Yaygın olarak karşılaşılan diğer bir işlenmiş veri ise ECMWF'in ERA 40 verileridir ve 100 km çözünürlükte, 1958'den günümüze kadar olan dönemi içermektedir (Widmann ve diğ., 2003).

Çizelge 2.1: Verileri kullanılan FSUGSM versiyonları ile ilgili ayrıntılı bilgiler.

	KNRG	**KORG**	**ANRG**	**AORG**
Atmosfer Bileşeni	FSUGSM	FSUGSM	FSUGSM	FSUGSM
Çözünürlük	T63/12 seviye	T63/12 seviye	T63/12 seviye	T63/12 seviye
Konveksiyon	Kuo	Kuo	Arakawa-Schubert	Arakawa-Schubert
Radyasyon	Band Model	Emissivity-absorptivity	Band Model	Emissivity-absorptivity
Okyanus Bileşeni	HOPE Global	HOPE Global	HOPE Global	HOPE Global

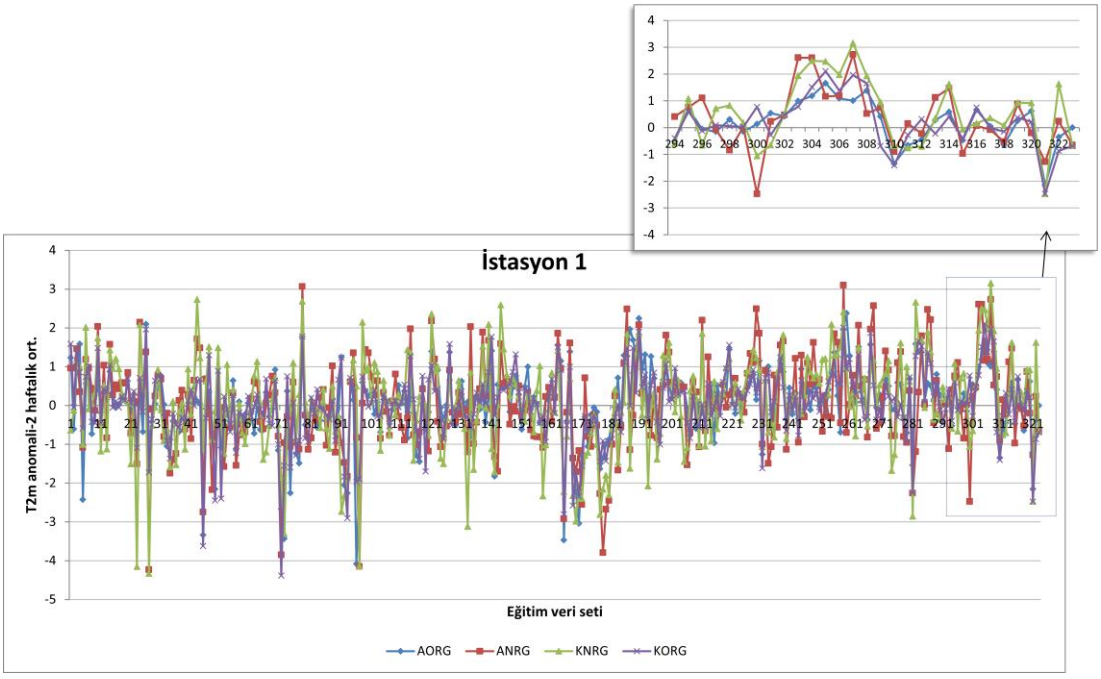
Uzun vadeli hava öngörüsü ve iklim çalışmalarında sıcaklık değerleri yerine sıcaklıklardaki değişimler yani anomaliler önem kazanmaktadır. Termometreden okunan ve günlük veya belirli dönemler için (örneğin aylık) ortalama olarak sunulan sıcaklık değerlerinin pek bir anlamı yoktur. Bu nedenle genel olarak 30 yıllık periyotlardaki ortalama sıcaklıklar temel alınmakta, bu ortalamalardan olan farklar hesaplanarak anomali değerleri elde edilmektedir. Fakat mevcut veri setine göre de ortalama değerleri hesaplanırken bu periyot değiştirilebilmektedir (Strangeways, 2010). Günümüzde kullanılan referans periyot 1981-2010 yıllarını kapsarken, 1980'lerde bu periyot 1946-1960 yılları arasındaydı.

Çalışmada kullanılan 2 haftalık ortalama sıcaklık anomalileri, sırasıyla model çıktısı ve gözlem verisi olarak kullanılan FSUGSM model versiyonlarının ve işlenmiş NCEP/NCAR sıcaklık tahminlerinden elde edilmiştir. Bu 2 metredeki 2 haftalık ortalama sıcaklık tahminleri Weather Predict Consulting Inc. kuruluşundan sağlanmıştır.

Bu veriler grid noktalarından enlem boylam bilgisi verilmiş olan istasyonlara interpole edilmiş tahminlerdir. Türkiye genelindeki 50 istasyona ait olan tahminler, model versiyonlarının değiştirilmeden çalıştırıldığı 1990-2005 yılları arasındaki periyodu kapsamaktadır. Bu nedenle 2005 sonrası veriler kullanılmamıştır. Bazı model çıktılarında tüm istasyonlarda olmak üzere eksik veriler gözlendiğinden, diğer modellerin da aynı dönemlere ait tahminleri kullanılmamış ve böylece toplam veri

sayısı tüm istasyonlar için 372'ye indirilmiştir. Veri, ayrıntısı ileriki bölümlerde verilmiş olan YSA ve lineer regresyona dayalı ensemble tahminleri oluşturmak ve gerekli ağırlıkları elde etmek üzere eğitim ve test verisi olarak ikiye ayrılmaktadır. Eğitim periyodundaki anomali verileri kullanılarak belirlenen ağırlıklar test periyodundaki verilere uygulanarak ensemble üyeleri bir araya getirilmekte ve elde edilecek ensemble tahminlerinin performansları değerlendirilmektedir. Bu çalışmada son 50 veri test için kullanılmıştır fakat eğitim verisi sayısı, adaptif bir sistem geliştirilmeye çalışıldığından, her test tahmini için değiştirilmekte ve anomali hesabı yapılırken ortalamalar/klimatolojiler güncellenmektedir.

Çalışmada YSA sisteminde girdi verisi olarak kullanılan ensemble üyelerine örnek olarak 1 numaralı Adana istasyonuna ait anomalilerin zaman serisi Şekil 2.2'de verilmiştir. Buradan fiziksel şemalarında değişiklik yapılarak elde edilen model versiyonlarının bu istasyon için birbirinden farklı sıcaklık tahminleri ürettiği anlaşılmaktadır.



Şekil 2.2: Adana istasyonuna ait ensemble üyesi modellerin eğitim veri setine örnek.

3. KULLANILAN YÖNTEMLER

3.1 Ensemble Tahmini

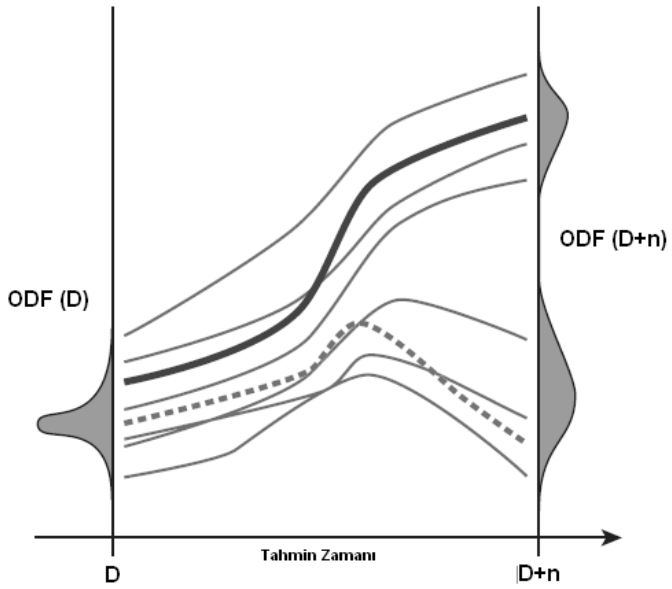
Başlangıçta SHÖ'nün temel felsefesi, atmosferin kesin olarak tahmin edilebilir, yani deterministik olduğuydu. Bu nedenle tüm bilgisayar kaynakları, olabilecek tek en doğru tahmini elde etmek amacıyla kullanılmaktaydı (Tracton ve Kalnay, 1993; Bramer, 1998). Her model kabuller ve yaklaşımlar içermektedir, bu nedenle model doğruluğu önemlidir ve modeldeki herhangi bir hata, tahminin doğrulanmasını engellemektedir. Bunun yanı sıra model %100 mükemmel olsa bile başlangıç koşulları için veri kaynağı %100 doğru olmayabilir (Bramer, 1998). Lorenz (1963), başlangıç koşullarındaki çok küçük değişikliklerin bile tek bir sonuç vermediğini fakat bir olası sonuçlar aralığının olduğunu göstermiştir. Ayrıca hava durumu tahminindeki doğruluğun, sonlu bir aralıkta tahmin edebilirliğe sahip olduğu sonucuna varmıştır (Lorenz, 1963). Hem doğal hem de insan davranışları için tipik bir davranış olan bu durum genellikle kaotik davranış olarak isimlendirilmektedir (Aguado ve Burt, 2007).

Başlangıç verisindeki hataların tamamıyla yok edilmesi mümkün olmadığından gelecekte bir noktada tahmin hatalı olacaktır. Bu nedenle havanın doğasında deterministik olmadığı stokastik-dinamik olduğu açık hale gelmiştir. Lorenz (1965) ve Epstein (1969) tarafından ortaya çıkarılan ensemble metodu (Toth ve Kalnay, 1993) atmosfere doğasında olasılıksal olduğu kanısıyla yaklaşmaktadır (Bramer, 1998). Çünkü, özetle;

- Başlangıç koşulları,
- Sınır koşulları,
- Kara/su yüzeyi koşulları,
- Dinamik merkezde kullanılan sayısal yaklaşımlar,
- Fiziksel süreçlerde kullanılan parametrizasyonlar (Warner, 2011),

gibi hata kaynaklarından bir/birkaçı bakımından çok küçük farklılıklara sahip olan model simülasyonlarının tahminleri ensemble üyesi olarak belirli bir aralıkta farklı

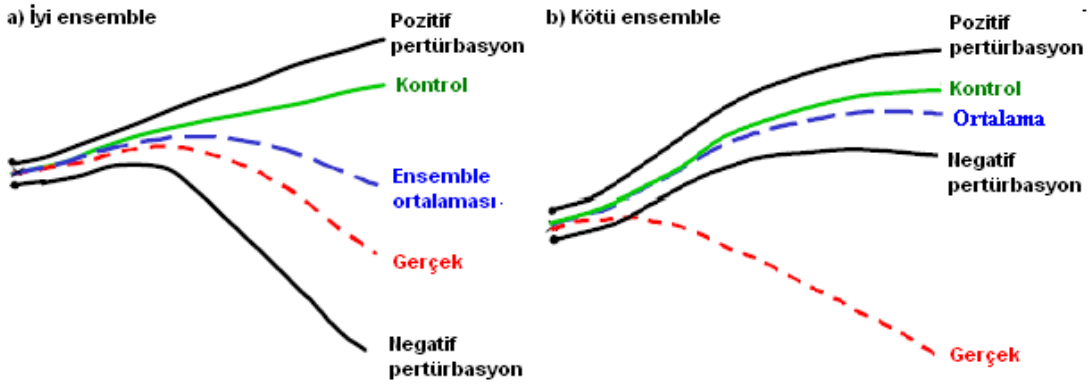
sonuçlar vermektedir. Şekil 3.1'de görüldüğü gibi farklı başlangıç değerlerine sahip model tahminleri zaman içerisinde giderek büyüyen aralıkta değerler vermektedir. Bu nedenle sistem durumunun doğru şekilde tanımlanması, bir durum uzayı bölgesinde durumun yer alma olasılığını tanımlayan bir Olasılık Dağılım Fonksiyonudur (ODF) (Hansen, 2000). Diğer bir deyişle, hava tahmini problemi, atmosferin faz uzayında uygun bir olasılık yoğunluk fonksiyonunun zamanla değişimi olarak ifade edilebilir. ODF'nin hem başlangıç hem de model belirsizliklerini göstermek üzere oluşturulmuş sonlu sayıda deterministik entegrasyonla örneklenmesine dayanan ensemble tahmini, ODF tahmini için en uygun metottur (Buizza ve diğ., 2001).



Şekil 3.1: Ensemble tahmin şeması (Buizza ve diğ., 2001).

Bir ensemble için en basit şekliyle gerekli bileşenler, Kalnay (2003)'ın kitabında belirtildiği gibi; x ile gösterilen analizden (atmosferin başlangıçtaki durumunun en iyi öngörüsü) başlatılan bir kontrol tahmini, analizin pertürbe edilmesiyle elde edilen tahminler, ensemble ortalaması ve atmosferin gerçek gelişimidir. Şekil 3.2.a'da, atmosferin gerçek gelişimi, ensemble üyelerinin uygun olduğunu gösterdiğinden 'iyi' bir ensemble'a örnektir, fakat Şekil 3.2.b'de başlangıç hatalarındaki büyümeden ziyade tahmin sistemindeki (örneğin modeldeki eksiklikler) problemlerden dolayı olan tahmin hataları baskındır ve 'kötü' ensemble'a bir örnektir. Burada ensemble üyeleri ile gerçek gelişim tamamen birbirinden farklıdır fakat bu ensemble, sistemdeki eksikliklerin varlığını gösterdiği için yine de kullanışlıdır. Çünkü tek bir tahminle bu hataları başlangıç koşullarındaki hataların büyümesinden ayırmak

mümkün değildir (Kalnay, 2003). Modelin normal konfigürasyonu ile ilklendirilen kontrol tahmin elde edilirken; model fiziğindeki parametrizasyonlar, sayısal olarak sabitlerin ayarlanmaları ve en uygun başlangıç koşullarının elde edilmesine çalışılmaktadır. Bu nedenle kontrol tahmine uygulanacak pertürbasyonlar bazen daha az başarılı olabilmektedir (Warner, 2011).



Şekil 3.2: Tipik ensemble'a ait bileşenler: (a) İyi ensemble, (b) Kötü ensemble örneği (Kalnay, 2004).

İstatistiksel olarak güvenilir bir ensemble sistemi için, ensemble üyesi modellerin tahminleri arasındaki farklılık yani ensemble ortalamasından olan sapmaların (ensemble spread-standart sapma) boyutu ile ensemble ortalamasının hata değerlerinin (örneğin ortalama hata, hataların kareli ortalamalarının karekökü) boyutu birbirine yakın ve uyumlu olmalıdır (Buizza ve diğ., 2005).

Başlangıçta, orta vadeli tahminler için ensemble öngörü sistemlerinin (EPS) çoğu modelin kusursuz olduğu hipotezine dayanarak tek bir modelin pertürbe edilmiş başlangıç koşulları setiyle çalıştırılmasıyla elde edilen ensemble üyelerinin ortalamasını alarak hatayı gidermeye çalışmaktaydı. Tek modele dayalı bu sistemlerdeki model hatalarını dikkate almak için ise model fiziği ve dinamiklerinde pertürbasyonlar yapılması gerekliliği ortaya çıkmıştır (Arpal, 2005). Çünkü model fiziği de doğasında stokastiktir, örneğin kümülüs konveksiyonu ve atmosferik sınır tabaka şemaları değiştirilebilir ve/veya ampirik sabitler kullanmaktadır ve bu durum büyük aralıkta farklı tahminler elde edilmesine sebep olabilmektedir (Bramer, 1998). Özellikle iklim gelişimi simülasyonları için kullanılan eşitlikler, kısmi diferansiyel denklemlerle en iyi şekilde açıklanabilmesine rağmen bilgisayarlarda adi diferansiyel denklemler şeklinde sonlu boyutlu olarak yer almaktadır. Bu da kaçınılmaz hatalara

yol açtığından (Palmer ve diğ., 2004) mevsimsel ensemble tahminlerinde de model belirsizliklerinin dikkate alınması önem kazanmaktadır (Krishnamurti ve diğ., 2000).

Başlangıç koşullarının ve/veya bunların dışında kalan tüm modelleme hatalarını kapsayan model hatalarının dikkate alınmasına bağlı olarak ensemble üyeleri elde edilmesi iki ayrı kategoride incelenebilir.

3.1.1 Başlangıç koşulları belirsizlikleri

Sayısal öngörü modellerindeki sistematik olmayan hatalardan biri olan başlangıç koşullarındaki hatalar gözlemlerdeki hatalardan etkilenmektedir. Gözlem hataları ise alet kalibrasyon hataları, aletin uygunsuz yerleştirilmesi ve veri aktarımındaki hatalardan kaynaklanmaktadır. Başlangıç koşulları hatalarının diğer bir nedeni kullanılan modeldeki veri asimilasyon sistemidir. Gözlemler direkt olarak modelleri başlatmak için kullanılamazlar ancak, kullanışlı bir veri seti elde etmek için dinamik olarak uygun bir metotla değiştirilirler. Bu sürece veri asimilasyonu denir (Buizza, 2002). Modellerin veri asimilasyon süreçlerinde yapılacak iyileştirmelerin başlangıç koşullarını da iyileştirmesi beklenmektedir (Warner, 2011). Veri asimilasyon metotları ile ilgili günümüzde oldukça önemli ve ayrıntılı çalışmalar yapılmaktadır ve geliştirilmiş olan çeşitli yöntemler arasında optimum interpolasyon, 3D-VAR, 4D-VAR (Three and Four-dimensional variational assimilation), Kalman filtresi sayılabilir (Kalnay, 2003).

Ensemble tahmin metotları çoğunlukla başlangıç pertürbasyonlarını oluşturmada izlenen yollara göre farklılık göstermektedir ve esasen iki sınıfa ayrılabilirler: Rastgele başlangıç pertürbasyonlarına sahip olanlar ve temeldeki akışın dinamiklerine bağlı olan pertürbasyonlara sahip olanlar. Birinci sınıfta yer alan metotlar ilk geliştirilen ve günümüzde uygulamalı sayısal hava öngörü merkezlerinde kullanılan metotların geliştirilmesine zemin hazırlayan metotlardır. Sırasıyla Stokastik Dinamik Tahmin (SDF) (Epstein, 1969), SDF'nin basitleştirilmesiyle ortaya çıkan Monte Carlo Metodu (MCM) (Leith, 1974), Geciktirilmiş Ortalama Tahmini (GOT) (Hoffman ve Kalnay, 1983) ve Ölçeklendirilmiş GOT bunlardan bazılarıdır. Epstein'in SDF yaklaşımına pratik ve hesaplanabilir bir yaklaşım sergilediği öne sürülen MCM'de pertürbasyonlar 'gerçekçi' olarak seçilmektedir. Örneğin yatay ve düşey koordinat özellikleri tahmin hatasına istatistiksel olarak benzerdir ve genlikleri tahmin edilen analiz belirsizlikleri ile uyumludur, fakat

pertürbasyonlar rastgele seçildiği için o günün dinamikleri dikkate alınmamaktadır ve birbirine yakın sonuçlar veren ensemble üyeleri ortaya çıkabilmektedir. Başlangıç koşullarındaki rastgele hataların büyüyen 'günlük hatalara' dönüşmesinin çok uzun sürdüğü, bunun da MCM'yi ensemble tahmin için yetersiz bir yaklaşım kıldığı ortaya konmuştur (Hollingsworth, 1980; Kalnay, 2004).

İkinci sınıfta yer alan, o güne ait hataları da içeren 'türetme vektörü' ve 'tekil vektör' yaklaşımları çeşitli operasyonel tahmin merkezlerinde (NCEP, ECMWF) geliştirilmiş, test edilmiş ve Aralık 1992'den beri uygulanmaktadırlar (Toth ve Kalnay, 1993; Molteni ve diğ., 1996; Buizza ve Palmer, 1998). Bu metotlar rastgele eklenen pertürbasyonların tersine dinamik olarak istikrarlı olan pertürbasyonlar üretmektedir (Warner, 2011). Bu iki merkezde kullanılan türetme vektör ve tekil vektör yaklaşımlarına kısaca değinilecek olursa;

Türetme vektörü yaklaşımı: Toth ve Kalnay (1993)'ın öne sürdüğü bu metot sırasıyla şu basit adımları içermektedir:

a) Verilen bir günde t_0 anında atmosfer analizine (başlangıç durumu) küçük, keyfi bir pertürbasyon eklenir,

b) $t_1 - t_0$ periyodu için pertürbe edilmiş ve edilmemiş (kontrol tahmin) başlangıç koşulları ile model çalıştırılır,

c) kontrol tahmini pertürbe edilmiş tahminden çıkarılır,

d) başlangıç pertürbasyonuyla aynı normda (boyutta, örneğin hataların kareli ortalaması (MSE) açısından) olması için fark küçültülür. Elde edilen bu pertürbasyon,

e) bir sonraki 6-saatlik analize eklenir veya çıkarılır ve aynı prosedürler a'dan başlayarak tekrarlanır. a adımında başlangıç pertürbasyonu ortaya konulduğu zaman, pertürbasyon alanının gelişimi, dinamik olarak atmosferik akışın gelişimi ile belirlenmektedir (Toth ve Kalnay, 1993).

Bu metodun uygulanması ile çevrim süresince hızlı büyüyen hatalar seçilmektedir. Bir türetme çevriminin başlatılmasından 3 veya 4 gün sonra pertürbasyonların büyüme oranı doymaya ulaşır ve bu noktada büyüme artık başlangıç hatalarına bağlı olmamaktadır (Toth ve Kalnay, 1993; Bramer, 1998).

Tekil vektör yaklaşımı:Aralık 1992'de ECMWF'te geliştirilen ve uygulamalı olarak kullanılan bu metod Optimal pertürbasyonlar olarak da bilinmektedir. Bu metod geliştirilirken Lorenz (1965)'den esinlenilmiştir. Lorenz'e göre bozulma dinamiklerinin lineer kabul edildiği bir sonlu zaman aralığında kararsızlığın maksimum olduğu eksen, bir simetrik operatörün özvektörleri gibi hesaplanabilir. Bu simetrik operatör ise bir gelişim operatörünün kendi ekleniği (adjoint matrisi) ile çarpılması sonucu elde edilmektedir. Lineer cebir dilinde bu vektörler lineer gelişimin tekil vektörleridir (Molteni ve diğ,, 1996; Bramer, 1998). ECMWF'in hedefi bu uygun vektörleri, ensemble tahmin sistemleri için başlangıç koşullarına uygulamaktır. Her ensemble tahmin sisteminde pertürbasyon, hesaplanan tekil vektörlerin bir lineer kombinasyonudur.

Tahminin başlangıç koşullarına hassasiyeti akışa bağlıdır. Örneğin yazın Akdeniz iklim tipinde sinoptik ölçekli koşullar yarı-daimi büyük antisiklonların etkisindedir. Atmosfer koşulları genel sirkülasyon ve kara yüzeyinin durumuyla ilişkili olan büyük ölçekli planeter kuvvetlerin etkisindedir bu nedenle tahmin başlangıç koşullarındaki hatalardan çok etkilenmemektedir. Tersi olarak kararsızlık sınırına yakın olan atmosfer koşullarında küçük başlangıç koşulları hataları farklı tahminlere yol açabilmektedir (Warner, 2011). Reynolds ve diğ. (1994), orta enlemlerdeki çoğu tahmin hatasının başlangıç koşullarından kaynaklandığı sonucuna varılan bir çalışma yapılmıştır (Bramer, 1998).

Bir tahmin modeli için başlangıç koşullarının belirlenmesi çok önemli ve karışıktır, bu nedenle başlı başına bir bilim halini almıştır. Mükemmel olmayan modellerin varlığında doğru olasılıksal tahminler yapmak mümkün değildir. Olasılıksal veri asimilasyonunda ve hava tahmini yaparken model hatalarını da dikkate alacak metodların geliştirilmesi de günümüzde aktif bir araştırma alanıdır. Başlangıç koşullarına bağlı hatalar, bunların giderilmesi için başlangıç pertürbasyonu elde etme yöntemleri ve veri asimilasyon yöntemleri ile ilgili daha ayrıntılı bilgiler için Kalnay (2003) ile Warner (2011)'dan yararlanılabilir.

3.1.2 Model belirsizlikleri

Doğasında stokastik olduğu için model ve model fizikleri belirsizlik/hatalar içermektedir. Başlangıç koşullarına bağlı hatalar dışındaki yukarıda sıralanan modelleme hataları ele alınacak olursa (Warner, 2011):

*"*Yanal sınır-koşullarındaki belirsizlik: Sınırlı alan modelleri için önemli olan bir model hatasıdır ve hem büyük-ölçekli modelin tahmin hatalarına hem de iki gridi ilişkilendirirken kullanılan algoritmadan kaynaklanan hatalara bağlıdır (Bramer, 1998). Eğer büyük ölçekli model bir ensemble ise, bu ensemble'ın üyeleri sınırlı alan modeli için yanal sınır koşulları sağlamak üzere kullanılabilir, ensemble değilse yanal-sınır koşullarının pertürbe edilmesi gerekmektedir.

Yeryüzü sınır-koşullarındaki belirsizlik: Tahmin sırasında yeryüzü özelliklerinin hesaplanmasındaki hatalar başlangıç koşullarından veya model hatalarından kaynaklanabilir (Warner, 2011).

Sayısal algoritmalardaki hatalar: Zaman ve uzay türevlerindeki sayısal yaklaşımlar fiziksel süreçlerdeki parametrizasyonlarla birlikte model hatalarına sebep olmaktadır. Bu hatalar başlangıçta, küçük ölçeklerde modelin yuvarlatma limitleri yakınında en büyüktür. Model entegrasyonun bir kaç gününde lineer olmayan etkileşimler aracılığıyla orta enlem yüksek ve alçak basınç sistemlerini etkileyebilmektedirler. Bu dinamik merkezle ilgili olan belirsizlikler için en uygun ensemble yöntemi tamamen farklı modellerin tahminlerinin birleştirildiği çok-modelli ensemble metodudur. Farklı model sayıları sınırlı olduğundan ensemble üyesi sayısı 10'la sınırlı olacaktır. Ensemble tahmininde model hatalarını dikkate almak için yeni yöntemlerden biri, çözülmemiş alt-grid ölçekli süreçlerden kaynaklanan üst ölçeğe yayılan enerjileri gösteren stokastik kinetik-enerji geriyayılma metodudur (Warner, 2011).

Fiziksel süreçlerdeki parametrizasyon hataları: Fiziksel süreçlerin parametrizasyonlarındaki hataların dikkate alınması için çok-modelli ensemble metodu yanında parametrizasyonlarda yapılacak farklı kombinasyonlarla da tek modele dayalı ensemble üyeleri ve ensemble tahminleri elde edilebilmektedir (Warner, 2011).*"*

Tamamen farklı modellerin ensemble üyesi olarak kullanıldığı ve tahminlerin birleştirildiği durum çok-modelli ensemble metodudur. Tek bir modelin başlangıç koşulları ve/veya model fiziği veya parametrelerinde küçük pertürbasyonlar yapılarak elde edilmiş birden çok tekli-model ensemble'larının birleştirilmesi ise çok-modelli Süperensemble (Krishnamurti ve diğ., 1999; Palmer ve diğ., 2004; Warner, 2011) olarak adlandırılmaktadır. Çok-modelli ensemble tahminin, bireysel model tahminleri, ensemble ortalaması veya bias düzeltmesi yapılmış ensemble

ortalaması ile elde edilen tahminlerine göre, daha düşük bias, daha az hata ve gözlemlerle yüksek korelasyonlara sahip olduğu çeşitli çalışmalarla ortaya konmuştur (Krishnamurti ve diğ., 1999; 2000; 2001; Mutemi ve diğ., 2007; Sirdas ve diğ., 2007; Bhowmik ve Durai, 2010).

Houtekamer ve diğ. (1996) ile Houtekamer ve Mitchell (1998), başlangıç koşulları oluşturmak için veri asimilasyon sistemleri ensemble'ı çalıştırmaya dayanan bir sistem geliştirmişlerdir. Diğer bir deyişle bu sistemde pertürbe edilmiş gözlemler kullanılmıştır. Farklı veri asimilasyon sistemlerinde gözlemlere rastgele hatalar eklenmiş (orjinal gözlem hatalarına ilave olarak) ve model fiziksel parametrelerine farklı parametreler dahil edilmiştir. Bu türetme ile ilişkili fakat daha genel olan önemli bir yaklaşımdır ve farklı model versiyonları elde edilmesine dayanmaktadır. Modellerin çeşitli yönleri, örneğin konvektif parametrizasyon veya orografinin düzeltilmesi, model versiyonları elde etmek için değiştirilmektedir. İlginç olarak bu yaklaşım, aynı model versiyonunu kullanmanın tersine, başlangıç pertürbasyonlarının boyutunda artmaya yol açmaktadır. Farklı model versiyonlarının kullanılması modelin sistematik davranışı bakımından farklılığa neden olabilmektedir. Temel parametrizasyonlarda dikkatle yapılacak değişimlerin kombinasyonu sayesinde önemli parametrizasyonların etkisinden kurtulmak mümkün olmaktadır. Ensemble varyansının arttırılması için model pertürbasyonlarının yararlı olduğu Houtekamer ve diğ. (1996) tarafından ortaya konulmuştur ve bu metot Kanada Meteoroloji Merkezi (MSC) ensemble tahmin sisteminde uygulamalı olarak kullanılmıştır (Toth ve Vannitsem, 2002). Ramamurthy ve Jewett (1998) ile Stensrud ve diğ. (1998) farklı konveksiyon ve planeter sınır tabaka parametrizasyonları şemalarında değişiklikler yaparak ensemble tahminleri ortaya koymuşlardır (Bramer, 1998).

Buizza ve diğ. (1999), SHÖ modellerindeki fiziksel parametrizasyonların net etkisi ile ilişkili olan model hatalarını göstermek için bir teknik ortaya koymuştur. SHÖ modellerinin, alt-grid ölçekli süreçlerin parametrizasyonu ile ilişkili belirsizliklerinin farkına varılmış ve bunları ensemble tahmininde göstermek için bir yol izlenmiştir. Tüm parameterize edilmiş süreçlerin toplamı olarak hesaplanan diyabatik kuvvetlerin, ortalaması 1 standart sapması 0.2 olan rastgele sayılarla çarpılmasıyla elde edilecek rastgele pertürbasyonlar ortaya konulmuştur. Bu model pertürbasyonları ensemble pertürbasyonlarının boyutunda bir artmaya imkan

vermektedir (yine de tahmin hatasındaki büyümeyle eşit olacak kadar yeterli değildir) ve uygulamalı ECMWF ensemble tahmin sisteminde yer almıştır (Toth ve Vannitsem, 2002; Kalnay, 2003; 2004).

Stensrud ve diğ. (2000), çalışmalarında biri MCM yaklaşımı kullanılarak elde edilmiş farklı başlangıç koşullarına sahip tahminlerin ensemble sistemi, diğeri ise aynı başlangıç koşulları kullanan, farklı fiziksel parametrizasyon şemaları olan model konfigürasyonlarından elde edilen tahminlerin ensemble sistemi olmak üzere iki sistem ortaya konulmuştur. Uzun ömürlü, büyük mezo ölçekli konvektif sistemlerin geliştiği süre olan 48 saatlik periyotlarla bu ensemble sistemlerinin simülasyonları incelenmiştir. Yapılan değerlendirmeler sonucunda yukarı doğru hareket için büyük ölçekli kuvvet zayıf olduğu zaman model fiziğine bağlı ensemble tahminlerinin başlangıç koşulları ensemble'ından daha başarılı olduğu gözlenmiştir. Yukarı doğru hareket için büyük ölçekli kuvvet güçlü olduğu zaman ise başlangıç koşulları ensemble'ı model fiziği dikkate alınan ensemble'dan daha başarılı tahminler yaptığı vurgulanmıştır. Ayrıca bu iki ensemble sisteminin varyanslarına bakıldığında model fiziğine bağlı ensemble sisteminde 2-6 katı hızlı varyans elde edilmiştir. Bu nedenle, 12 saatlik gibi kısa periyotlarda bu ensemble sistemlerinin başlangıç koşullarına bağlı ensemble sistemlerinden daha fazla varyansa sahip olduğundan, model fiziğindeki değişimlerin bir ensemble tahmini elde etmede daha güçlü bir metot olduğu sonucuna varılmıştır (Stensrud ve diğ., 2000).

Stensrud (2001), ayrıca şiddetli hava olaylarının tahmini için kısa vadeli ensemble tahmininin kullanılması ile ilgili bir çalışma yapmıştır. Ensemble tahmin sistemlerinde hem başlangıç koşulları hem de modeldeki eksikliklerin yer alması gerektiğine değinilmiştir fakat model fiziğindeki belirsizlikler hassas hava olaylarının tahmininde daha önemli rol oynadığından (Stensrud ve diğ., 2000) bu çalışmada başlangıç koşullarındaki belirsizlik ihmal edilerek model fiziğindeki belirsizliklere odaklanılmıştır. Çalışmalarında MM5 modeli kullanılarak farklı fiziksel parametrizasyon şemaları ile değişik versiyonlar elde edilmiştir ve aynı başlangıç koşullarından başlatılan simülasyonlardan bir ensemble tahmini ortaya konmuştur. 3'ü farklı konvektif parametrizasyon şemalarına sahip, 3'ü de farklı sınır koşullarına sahip olmak üzere 6 model versiyonunun ensemble ortalamaları hesaplanmıştır. CAPE (Convective Available Potential Energy, konveksiyonun gelişmesine uygun bölgeleri belirlemekte kullanılır), SREH (Storm-relative

Environmental Helicity, gök gürültülü fırtınaların muhtemelen süper hücre olacağı bölgeleri belirlemekte kullanılır) ve BRNSHR (Bulk Richardson Number Shear, aşağı-seviye mezo-siklojenezlerinin bulunabileceği bölgeleri belirlemekte kullanılır) gibi şiddetli konvektif aktivitelerin tahmininde kullanılan parametreler 24-25 Haziran 1967 periyodunda MM5 ensemble simülasyonu ile elde edilmiş ve bunun sonucunda bu üç parametrenin hortum gelişimine uygun süper hücrelerin geliştiği bölgelerde kullanışlı olduğuna değinilmiştir. Model sonuçları iyi olsa da bazı belirsizlikler şiddetli hava durumlarının tahmininde mevcuttur ve şiddetli hava durumu parametrelerinin model fiziğindeki belirsizliklere hassasiyeti gösterilmiştir. Örneğin, 24 Haziran'da SREH ve BRNSHR'nin ensemble ortalamasından standart sapmaları küçük (ensemble ortalamasının 20%'si) iken CAPE'in standart sapması ensemble ortalamasının yaklaşık 50%'si kadardır ve bu da CAPE'in sınır tabakadaki ısınma ve nemlenme nedeniyle model fiziğinden ve konvektif şemada, düşey termodinamik profildeki değişimlerden direkt olarak etkilendiğini göstermektedir. Analizleri sonucunda, model içerisinde derin konveksiyonun gelişimi yanlış tasvir edilirse şiddetli hava olaylarına ilişkin parametrelerin, tahmini olumsuz yönde etkileneceği belirtilmiştir. Tek bir tahmin modelinin tüm tahmin senaryolarını iyi şekilde yapması zordur ve bu nedenle farklı fiziksel parametrizasyonlara sahip birden çok modelin sonuçlarının bir araya getirilmesiyle daha doğru sonuçlar elde edilebileceği sonucuna varılmıştır. Ayrıca model belirsizliklerine hassasiyet yanında model başlangıç koşullarının da hesaba katılmasının önemli olduğu vurgulanmıştır.

Eckel ve Mass (2004), tarafından yapılan çalışmada mezo-ölçek kısa vadeli ensemble tahmin sistemi (SREF short-range ensemble forecasting) geliştirilmeye çalışılmıştır. Analiz hatalarının ve model eksikliklerinin nasıl hesaba katılacağı ve model bias'ının (sapma) SREF sistemini nasıl etkileyeceği ve bunun düzeltilip düzeltilemeyeceği sorularına yanıt aranmıştır. 4 farklı yolla geliştirilmiş ensemble sistemleri arasında kıyaslamalar yapılmıştır. Bu 4 sistemden ikisi, tek bir modelin (MM5-Mesoscale Model) başlangıç koşullarının pertürbasyonu ile elde edilmiş, sırasıyla 17 ve 8 üyelidir (SMMA, Single Model Multi-Analysis), diğeri yine MM5 modelinin fiziksel parametrelerinin pertürbe edilmesiyle (8 üyeli, PMMA, Perturbed-Model Multi-Analysis) elde edilmiştir. Dördüncüsü ise farklı modellerin tahminlerini kullanarak (Multi-Model Multi-Analysis) ortaya konulmuş sistemlerdir. Çok-modelli sistemde 8 farklı büyük ölçekli model kullanılmıştır. SREF sistemlerinin 500-mb jeopotansiyel

yükseklik, ortalama deniz seviyesi basıncı, 10-m rüzgar hızı ve 2-m sıcaklık analizleri yapılmıştır. Fiziksel parametrizasyonlarında pertürbasyonlar yapılmış model tahminleri (UWME+, University of Washington Mesoscale Ensemble), bias düzeltmesi yapılmış ve yapılmamış olarak ensemble sisteminde kullanıldıklarında elde edilen tahminlere göre, RMSE ve ortalama hata (bias) değerleri 12, 24, 36 ve 48 saatlik tahminler için hesaplanıp kıyaslanmıştır. Elde ettikleri sonuçlara göre bias düzeltilmesi yapılmış sistemin daha başarılı olduğu gösterilmiştir. Çok-modelli sistemi (Poor Man's Ensemble) ile pertürbe edilmiş model fiziği şemaları karşılaştırıldığında, bias düzeltmesi yapılmış sistemlerde başarı artarken farklı modellerle elde edilmiş sistem tek bir modele bağlı pertürbasyonlara dayalı sistemden daha başarılı bulunmuştur (Eckel ve Mass, 2004).

Kuzey Atlantik ve Avrupa bölgesi için DEMETER'in mevsimsel çok-modelli ensemble tahminlerinin performansı Doblas-Reyes ve diğ. (2004) tarafından incelenmiştir. Buna göre tek-modelli ensemble'lar pozitif olsa bile hemen hemen her mevsim düşük başarı göstermiştir. Adım aralığı arttıkça başarı da azalmaktadır, yine de modeller arasında başarıdaki uyumu artmaktadır. Bu durum, daha uzun adım aralıklarında, on senelik değişimlerin başlangıç koşullarıyla daha ilintili olmasına bağlanmıştır. Eşit olarak ağırlıklandırılmış basit bir çok-modelli ensemble, tek-modelli ensemble'dan daha başarılı/yetenekli bulunmuştur. Fakat bu basit çok-modelli sistemin yeteneği her zaman en başarılı modelden yüksek çıkmamıştır. Tüm değişkenler için tutarlı bir şekilde en üstün başarıyı gösteren hiç bir model bulunamamıştır. Bu durum, basit bir çok-modelli sistemin, ortalamada, rastgele seçilen bir modele göre daha başarılı olduğunu göstermektedir. Bu sistemlerin tek-modelli ensemble sistemlerine göre üstünlüğü olasılıksal tahminlerde açıkça kanıtlanmıştır. Çalışmada, çok-modelli sistemlerin yeteneğini arttırmak için modelleri bir araya getirme yollarının hala araştırılmakta olduğu belirtilerek ve modellerin geçmiş yıllardaki performanslarına göre ağırlıklar atayan şemalara bağlı olarak sistemin başarısının arttırılabileceğini savunmaktadırlar (Doblas-Reyes ve diğ., 2004).

Buizza ve diğ. (2005), ECMWF, NCEP ve MSC (Kanada Meteoroloji Servisi, Meteorological Service of Canada) ensemble tahmin sistemlerinde (EC-EPS, NCEP-EPS, MSC-EPS) kullanılan başlangıç koşulları ve modellere bağlı hataları belirleme yöntemleri (sırasıyla tekil vektör, türetme vektörü, pertürbe edilmiş gözlemler)

arasında kıyaslama yapmışlardır. NCEP sadece 10 üyeli bir sistem kullandığından karşılaştırma ve yorumlama yapabilmek için 3 sistem de 10 üye ile sınırlandırılmıştır. 3 aylık Mayıs-Temmuz 2002 dönemi için bu üç sistemin karakterleri karşılaştırılmış ve özetle şu sonuçlar elde edilmiştir: Bir ensemble tahmin sisteminin performansı, pertürbe edilmemiş (en iyi) başlangıç durumunu belirlemede kullanılan veri asimilasyon sisteminin kalitesine ve tahmin üreten sayısal modele oldukça bağlıdır. Başarılı bir tahmin sistemi, hem başlangıç koşulları hem de modelle ilişkili belirsizliklerin tahmindeki hatalar üzerine etkisini göz önünde bulundurmalıdır ve üç global sistem için de ensemble tahminlerinin standart sapması (ensemble spread) gerçeği sistematik olarak yakalamakta yetersiz bulunmuştur. Çalışmalarında genel performans değerlendirmeleri için RMSE (hataların kareli ortalamasının karekökü), ve PAC (patern anomali korelasyonu), olasılıksal tahminler için, BSS (brier skill score) vb gibi ölçütler kullanılmıştır. Elde ettikleri sonuçlara göre genelde EC-EPS en başarılı performansı göstermiştir. Pertürbasyonlarla tahmin-hatası paternleri arasındaki ilişki açısında EC-EPS en iyi performansı göstermemektedir. Kısa zamanda, küçük ölçekli hata paternleri düşünüldüğünde NCEP-EPS, büyük ölçek düşünüldüğünde MSC-EPS hataları daha iyi ortaya koyabilmektedir. EC-EPS'nin üstün başarısının çoğunlukla kullanılan modelin ve veri asimilasyon sisteminin daha iyi olmasına bağlanabileceği ve tekil vektöre dayalı başlangıç pertürbasyonlarının üstün performansına kanıt olarak düşünülmemesi gerektiği belirtilmektedir. Diğer bir deyişle MSC ve NCEP ensemble'larının performansı, veri asimilasyon sistemlerinin düşük kaliteli ensemble'ı nedeniyle kısa vadede ve oldukça düşük model çözünürlükleri nedeniyle uzun vadede negatif olarak etkilenmektedir. MSC-EPS'nin ayrık değer istatistiklerinin çok iyi olmasının birden çok model versiyonları kullanılmasına bağlı olabileceği belirtilmiştir. ECMWF-EPS'de rastgele model hatası şemalarının uygulanmasının tahminlerin istatistiksel güvenilirliğini arttıracağına dair sonuçlar elde edilmiştir (Buizza ve diğ., 2005).

Weigel ve diğ. (2008), tarafından çok-modelli ensemble tahmininin performansını ortaya koymak, hangi koşulda bu tahminin en iyi performanslı tek model tahmininden daha başarılı olabileceğini göstermek amacıyla sentetik tahminler üreterek "Toy Modeli" uygulanmıştır. Çok-modelli ensemble tahminleri ağırlıklandırılmış ve ağırlıklandırılmamış olarak tekli-model ensemble tahminlerinin bir araya getirilmesi ile elde edilmiştir. Çok-modelli ensemble tahminleri, en iyi

tahmini veren tek bir modelin farklı başlangıç koşullarına bağlı tahminlerinin bir araya getirilmesinden elde edilen ensemble tahmininden daha başarılı olduğu ortaya konmuş, bu durumun da tekli-model tahminlerini çok iyi olduğu durumlarda elde edildiği belirtilmiştir.

Reynolds ve diğ. (2011), çalışmalarında Deniz Kuvvetleri Operasyonel Global Atmosferik Tahmin Sisteminin ensemble tahmin performansları değerlendirilmiştir. Modellere bağlı hataların azaltılması amacıyla, tek bir modelin farklı şemalarındaki parametrelerde yaptıkları küçük değişikliklerle elde edilecek farklı ensemble üyesi tahminlerle çalışmışlardır. İki farklı ensemble setinden birincisinde sadece konveksiyon şemasındaki parametrelerde çeşitlilik yaparken, ikinci sette hem konveksiyon hem sınır tabaka şemasındaki değiştirilebilen ve tahminlere etkisi önceki çalışmalardan bilinen parametrelerin farklılaştırılması sonucu ortaya çıkacak ensemble üyeleri elde edilmiştir. Tropiklerde sıcaklık ve rüzgar alanlarında ensemble standart sapmalarının belirgin şekilde arttığı ve tropiklerdeki siklon yörüngelerinin tahmininde de küçük fakat önemli ilerlemelerin olduğu ortaya konulmuştur. İkinci sette yapılan parametre değişiklikleri birinci sete göre daha başarılı olarak değerlendirilmiştir.

3.1.3 Ensemble üyelerini birleştirme yöntemleri

Ensemble üyeleri bir araya getirilirken kullanılan yöntem/algoritma bakımından ensemble sistemleri farklılık gösterebilmektedir. Kısaca bu yöntemler:

Ensemble ortalaması

En basit ensemble tahmini elde etme yolu olarak ensemble üyelerine ait tahminlerin direk ortalaması alınmaktadır (Eşitlik 3.1). Burada en başarılı ensemble üyesinden daha yüksek başarı beklemek yanlış olur (Krishnamurti ve diğ., 1999; 2000; Hagedorn ve diğ., 2005) fakat bu ensemble ortalaması tipik olarak, ensemble üyeleri arasından gelişigüzel seçilecek bir model tahmininden daha başarılı olmaktadır (Warner, 2011).

$$E = \frac{1}{N}\sum_{i=1}^{N} F_i \qquad \textbf{(3.1)}$$

$$E = \frac{1}{N}\sum_{i=1}^{N} (F_i - \overline{O}) \qquad \textbf{(3.2)}$$

Burada N farklı başlangıç koşullarından veya farklı modellerden elde edilmiş tahmin sayısı, F_i, i. model tahmini ve $\overline{O}$, gözlem klimatolojisini (ortalaması) göstermektedir. Birçok uygulamalı hava öngörü merkezinde başlangıç pertürbasyonları ile elde edilen ensemble üyeleri bu yolla bir araya getirilmektedir. Palmer (1993), ensemble ortalamasının sadece meteorolojik rejim değişene kadar tahmini iyileştirebileceğini, bu noktalarda ensemble üyelerinde çatallanma olacağını belirtmiştir (Warner, 2011).

Bias düzeltmesi yapılmış ensemble ortalaması

Modellerin bias düzeltmesi yapılmış ortalamaları da bir diğer birleştirme yöntemidir ve modellerin mevcut sistematik hatalardan kurtulması başarıyı arttırmaktadır.

$$E_{bd} = \frac{1}{N}\sum_{i=1}^{N}(F_i - \overline{F_i}) \qquad \textbf{(3.3)}$$

Ağırlıklandırılmış ensemble ortalaması

Çok-modelli ensemble tahmininde en basit yol olarak ensemble üyelerinin basitçe ortalamasının alınması yanında daha kompleks yollar geliştirilmiştir (Clemen, 1989; Robertson ve diğ., 2004; Stephenson ve diğ., 2005; Warner, 2011).

Uygun ağırlık fonksiyonlarının elde edilmesi oldukça önemlidir. Ağırlık faktörlerini hesaplamak için kullanılan yollar arasında; çoklu lineer-regresyon (Krishnamurti ve diğ., 1999, 2000), Gauss-Jordan metodu, tekil vektör çözümlemesi (Yun ve diğ., 2003) ve yapay sinir ağları metodu (Kang ve Shukla, 2004), Bayesian model ortalaması (Raftery ve diğ., 2003; Regonda ve diğ., 2006) sıralanabilir. Yaygın olarak birçok çalışmada kullanılan çoklu lineer regresyona dayalı Süperensemble metodu ve YSA metodu bu çalışmanın temel yöntemleri olduğu için bu yöntemlerin ayrıntılarına değinilmiştir.

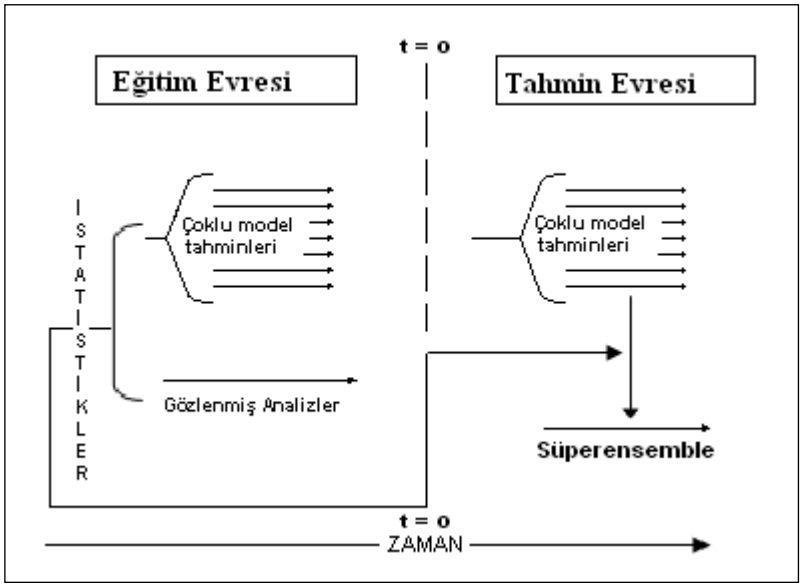
3.2 Çoklu lineer regresyon – Süperensemble

Süperensemble, birden çok modelin tahminlerini ağırlıklandırıp kullanarak mevsimsel iklim ve hava tahmini yapan yaklaşımlardan biridir ve Krishnamurti ve diğ. (1999; 2000) tarafından geliştirilmiştir. Hem deterministik hem olasılıksal tahminler yapmak için kullanılan (Yun ve diğ., 2005) Süperensemble algoritmasında, zaman, eğitim ve test süreci olmak üzere ikiye bölünür ve eğitim süresince farklı

model tahminleri çoklu-lineer regresyon kullanılarak istatistiksel olarak birleştirmektedir (Krishnamurti ve diğ, 1999; 2000; 2001; Yun ve diğ., 2005). Süperensemble metodunun basit bir şeması Şekil 3.3'de görülmektedir.

$$S = \overline{O} + \sum_{i=1}^{N} a_i \left(F_i - \overline{F_i} \right) \qquad \textbf{(3.4)}$$

Süperensemble tahmini elde edilmesini gösteren 3.4 eşitliğinde F_i, i. model tahmini, $\overline{F_i}$, eğitim periyodunda i. model tahminlerinin ortalaması, $\overline{O}$, eğitim periyodunda gözlenen değerlerin ortalaması, a_i, i. modelin ağırlık faktörü ve N kullanılan model sayısını göstermektedir.



Şekil 3.3: Süperensemble tahmin şeması (Krishnamurti ve diğ., 1999).

İlk kez 1908 yılında Pearson tarafından kullanılan **çoklu regresyonun** genel amacı, birçok bağımsız veya tahmin edici değişkenin bir bağımlı değişken veya ölçüt değişken arasındaki ilişkiyi analiz etmektir. Çoklu regresyon analizinde çözülmesi gereken hesaplama problemi, birçok noktaya göre bir düz bir çizgi veya n değişken sayısı olmak üzere n-boyutlu uzay uydurmaktır (Statsoft, 2003). Y bağımlı değişken, $X_1, X_2, \ldots, X_n$ bağımsız değişkenler, $\beta_0, \beta_1, \ldots, \beta_n$ katsayılar ve ε hata olmak üzere:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \ldots + \beta_n X_n + \varepsilon \qquad \textbf{(3.5)}$$

N tane Y gözlem değeri için, i=1,2, ..., n olmak üzere:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + ... + \beta_n X_{in} + \varepsilon_i \quad \textbf{(3.6)}$$

Bu eşitliklerin matris formunda gösterilişi;

$$\begin{vmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_N \end{vmatrix}_{N\times 1} = \begin{vmatrix} x_{10} & x_{11} & ... & x_{1n} \\ x_{20} & x_{21} & ... & x_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ x_{N0} & x_{N1} & .. & x_{Nn} \end{vmatrix}_{N\times n} \times \begin{vmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_n \end{vmatrix}_{n\times 1} + \begin{vmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_N \end{vmatrix}$$

Burada $X_{10}= X_{20}=...=X_{N0}=1$'dir. Buradaki yeni (ilk sütunu 1'lerden oluşan) X değerler matrisi kullanılarak,

$A = \left(X^T \times X\right)^{-1}$ ve $B = \left(X^T \times Y\right)$ olmak üzere katsayılar matrisi $R = A \times B$'den elde edilmektedir.

En küçük kareler metodu, $\sum_{i=1} \varepsilon_i$ değerlerini β'lara göre minimize etmeye çalışır. $\hat{\beta}$, β'ların öngörülen değerleri olacak şekilde en küçük kareler kriterinin matematiksel ifadesi:

$$Q = \sum_{i=1}^{n} \left(y_i - f(\vec{x}_i, \vec{\hat{\beta}}) \right)^2 \quad \textbf{(3.7)}$$

Yun ve diğ. (2005), de modellere bias-düzeltmesi uygulayarak ensemble ortalamasını hesaplamanın da Süperensemble yaklaşımıyla kıyaslandığı zaman daha düşük başarıya sahip olduğunu göstermiştir.

Chien ve Jou (2004), MM5'ın mikrofiziksel ve Kain-Fritsch şemalarını değiştirerek elde edilmiş 6 farklı ensemble üyesini 4 farklı yöntemle bir araya getirerek 2000, 2001, 2002 Doğu Asya yaz musonu ile ilgili Mei-yu dönemlerinde yağışı tahmin etme performansları incelenmiştir. Amaçları, yağışı en iyi tahmin edecek ensemble sistemini belirlemek ve Mei-yu dönemlerinde Tayvan bölgesine uygun simülasyonları gerçekleştirmesi için MM5'ın en iyi fiziksel kombinasyonunu elde etmektir. Üyeleri bir araya getirirken 6 üyenin tahminlerinin ortalaması alınarak basitçe hesaplanan ensemble ortalaması yanında, 4 farklı yöntem uygulamışlardır. 1.'si WT1: A (0-12saat) periyodunda üyelerin yağış tahmini performanslarına bakılarak, her üye kendinden bir adım gerideki üyeye göre iki katı ağırlığa sahip

olacak şekilde ağırlıklandırılırlar ve daha sonra ağırlıklar, toplamı 1 olacak şekilde normalleştirilir. Elde edilen değerler, B (12-24 saat) ve C (24-36 saat) periyotlarındaki tahminlerini hesaplamakta kullanılır. 2. metot WT2: WT1'e benzer fakat B ve C periyotlarında kullanılacak ağırlıkları belirlerken, her üyenin bir yıl önceki aynı tahmin periyodundaki performansları dikkate alınmıştır. 3. MLR1: Her noktadaki ağırlıklar için çoklu doğrusal regresyon (MLR-Multiple Linear Regression) tekniği kullanılır. Gözlenen yağışla üyelerin tahmin ettiği yağış arasındaki ilişkiye göre ağırlıklar belirlenir, 4. MLR2: Bir önceki yıla ait çoklu doğrusal regresyon değerlerine göre elde edilen ağırlıklar kullanılarak ensemble yağış tahmini oluşturulur. Elde ettikleri sonuçlara göre, B periyodu için WT2, WT1'den daha kötü sonuç verirken her ikisi de ortalama ensemble tahmini ve bireysel tahminlere göre daha üstün bulunmuştur. C periyodunda ise WT1, WT2'den biraz daha kötü sonuçlar vermiştir. MLR1'le elde edilen başarı performansı bir önceki yıla ait MLR değerlerini kullan MLR2'de gözlenememiştir. Bu çalışmada, Krishnamurti ve diğ. (2001)'nin çoklu doğrusal regresyon metodunun gerçek-zamanlı olarak yağış tahmininde kullanışlı olduğu sonucundan farklı sonuçlar elde etmişlerdir. Bu durumun da ağırlıklar belirlenirken, Krishnamurti ve diğ. (2001)'nin çalışmasında birden çok meteorolojik parametre kullanılırken burada sadece yağış parametresi kullanılmasına bağlanmıştır.

Chaves ve diğ. (2005), çalışmalarında FSU'nun çok-modelli sentetik Süperensemble algoritması Güney Amerika'nın mevsimlik iklim tahmini için kullanılmıştır. Daha önce belirtildiği gibi sentetik algoritma fikri, tahmin edilmiş model veri setlerinden yeni bir veri seti elde etmektir. Sentetik veri seti, geçmiş gözlem ve tahminlerin bir kombinasyonundan elde edilmektedir. Bu çalışmada, sentetik veri seti ile elde edilmiş Süperensemble yaklaşımına dayalı mevsimsel tahminlerin uygulanabilirliği değerlendirilmekte ve bu yaklaşımın Güney Amerika üzerindeki mevsimsel iklim tahminindeki hataları azaltabildiğini göstermektedir. Çalışmada FSU'da geliştirilmiş okyanus-atmosfer modelini 4 farklı versiyonu kullanılmıştır. Model versiyonları, kullandıkları konveksiyon ve radyasyon şemalarına göre farklılık göstermektedir.

Stensrud ve Yussouf (2006), New England bölgesi üzerinde kısa-vadeli ensemble tahmini için çoklu doğrusal regresyon yaklaşımına (MOS-Model Output Statistics) alternatif olarak geliştirilen, bias'ı düzeltilmiş çok-modelli ensemble sistemine değinmişlerdir. MOS'un uygulanmasındaki dezavantajlardan biri olan model

fiziğinin ve parametrelerinin değişmeden kaldığı birkaç sezonluk veriye gereksinim duyulmasından dolayı bu metoda alternatif bir metot olarak geliştirilmiştir. Uygulama merkezlerinde modeller sık sık güncellenmektedir ve MOS yaklaşımının uygulanması için uzun veri arşivi gerektiğinden kullanılmaları zorlaşmaktadır. Bu nedenle modeldeki değişiklikleri ihmal eden yaklaşımlar kullanılmaktadır (Hart ve diğ., 2004; Stensrud ve Yussouf, 2006). Ortalama hatası (bias)-düzeltilmiş çok-modelli ensemble sisteminde, modellere tek tek istatistiksel düzeltmeler yapıldıktan sonra tahminleri birleştirilmektedir. İstatistiksel düzeltmeler, model hatalarını azaltan bir süreçtir. Her modelin sistematik olmayan hatalarının büyük bir kısmı, tahmin ve gözlem anomalileri arasındaki istatistiksel ilişki ile düzeltilebilmektedir. Kullanılan en yaygın metotlardan bazıları, tekil değer ayrıştırılması (SVD) analizi ve doğal korelasyon analizine dayanan ikili patern tekniğidir (Kang ve Shukla, 2004).

Dias ve diğ. (2006), 2003'te SALLJEX Intercomparison Programı tarafından desteklenen ve Güney Amerika için bir süpermodel ensemble sistemi kurulmasını amaçlayan THORPEX destekli çalışmalarını sunmuşlardır. Bölge üzerinde birçok modele ait tahmin bulunduğunu ve problemin bunların nasıl bir araya getirileceği olduğunu vurgulamışlardır. Çalışmalarında, kullandıkları yöntemin, veri asimilasyonunun temel fikrine dayandığını ve buradaki amacın, maliyet fonksiyonuna dayalı optimizasyon problemiyle tahminlerin birleştirilmesi olduğunu belirtmişlerdir. Kullanılan maliyet fonksiyonu:

$$T = \sum_{i}^{N} \left(T_i - B_i \right) / MSE_i \qquad \textbf{(3.8)}$$

Burada, T_i, i. model tahmini, B_i, i. model biası, MSE_i, modelin ortalama hata kare değerlerini göstermektedir. Model biasları ve hata hesabı için gereken ortalama periyot ne kadar uzun olmalıdır şeklinde bir soru daha ortaya atılmış ve model çıktısı istatistikleri için tipik olarak iki yıl kullanıldığını belirtmişlerdir. Fakat pratik uygulamalar açısından bakıldığında daha kısa periyotlar ele alınması gerektiği, bunun da model bias'ında, belirlenmiş mevsimler içinde güçlü sinyaller varsa mümkün olabileceği öne sürülmüştür. Güney Amerika için mevcut modellerin deneyimlerine dayanarak 15 günün kararlı istatistiksel ölçümler verdiği belirtilmiştir. Elde edilen sonuçlara göre, modellerin uygun kombinasyonu ile elde edilen 2 metre sıcaklık ve deniz seviyesi basıncı tahminleri, en küçük bias ve MSE değerlerine sahiptir. Normalleştirilmiş ortalama kare hatası ise ürünün 7 güne kadar oldukça

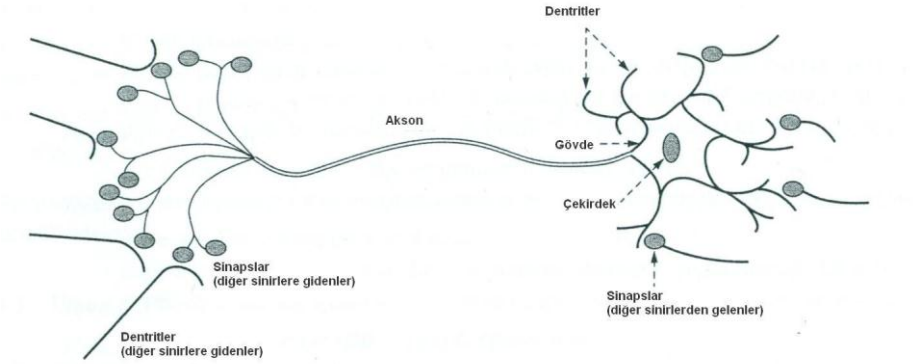
kullanışlı olduğunu göstermektedir. Dias ve diğ. (2006), ileriki uygulamalarının, Kalman Filtresi ve sinir ağları kullanılarak belirlenecek optimum ortalama periyotlar ile bias ve MSE hesaplamasına dayanacağını ve yağış için olasılıksal tahminlerin kullanılacağını belirtmişlerdir.

3.3 Yapay Sinir Ağları

Bilim insanları, beynin üstün özelliklerinden etkilenerek yaptıkları çeşitli çalışmalar sonucunda beynin matematiksel modelini ortaya koymaya çalışmışlardır ve genel anlamıyla YSA, beynin bir işlevi yerine getirirken izlediği yolları modellemeye çalışan bir sistemdir. Tüm sinir ağları çalışmalarının kökeni sinir sistemi biyolojisi çalışmalarına kadar gitmektedir. Farklı elektrik akımları verildiğinde sinirlerin nasıl davranacağı, siniri aktif hale getirmek için gerekli minimum akım değerine ihtiyaç olup olmadığı, farklı sinir hücrelerinin tepkilerinin farklı olmasının sebeplerinin ne olduğuna dair sorulara 20. yüzyılın ortalarına kadar mantıklı cevaplar bulunamamıştır. Psikologların öğrenme, hatırlama, unutma gibi hayvanların yapabildiği çeşitli yetenekleri tam olarak anlayabilmek için yaptıkları çeşitli deneyler bireysel ve grup olarak sinirlerin nasıl çalıştığını anlamamızı sağlamıştır. Tek bir sinirin ilk matematik modeli 1943 yılında McCulloch ve Pitts tarafından geliştirilmiştir ve daha sonraki çalışmalara temel oluşturmuştur (Mehrotra ve diğ., 1997).

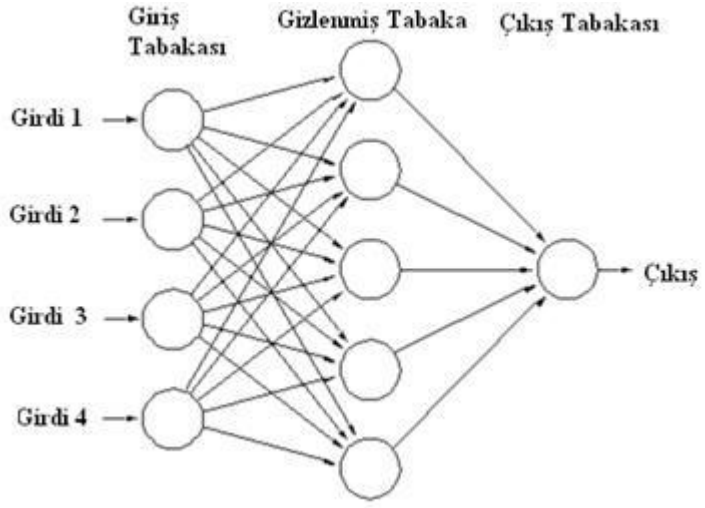
Bir sinirin çok fazla hesaplama yüküne ihtiyaç duymadan her türlü fonksiyonu öğrenebilmesi amacıyla Hebb (1949), Rosenblatt (1958), Minsky ve Papert (1969) ve Widrow ve Hoff (1960) gibi isimler tarafından çeşitli öğrenme kuralları geliştirilmiştir. Yapay sinir ağları konusundaki gelişmelerle ilgili daha detaylı bilgiler Mehrotra ve diğ. (1997)'de bulunabilir.

Merkezi sinir sisteminde, dış ortamdan veya organizmadan alıcı sinirler (receptor/dentrit) tarafından alınan uyarılar elektriksel sinyallere dönüştürülerek beyine iletilmektedir. Tepki sinirleri beynin ürettiği elektriksel darbeleri uygun davranışlara dönüştürür. Şekil 3.4'de biyolojik sinir hücresinin şematik gösterimi görülmektedir. Milyonlarca sinir hücresinden oluşan beyinde bu hücrelerin her biri oldukça büyük kapasiteli bir bilgisayar gibi davranmaktadır.



Şekil 3.4: Biyolojik sinir hücresi (Mehrotra ve diğ., 1997).

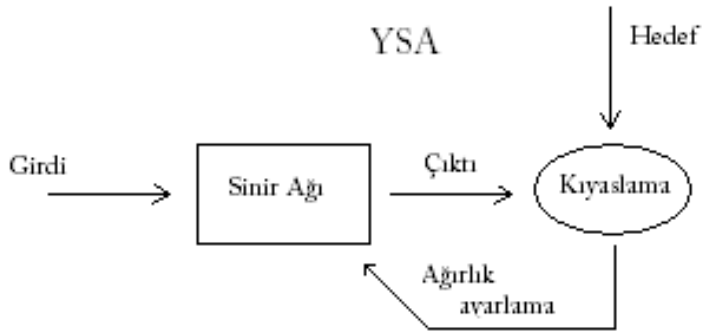
YSA da çok sayıda birbirine bağlanmış işlemci elemanı içermektedir. Biyolojik sinir hücrelerine benzer şekilde işlemciler birbirlerine genellikle katmanlı olmak üzere çeşitli şekillerde bağlanabilmektedir. Şekil 3.5'de en yaygın YSA tiplerinin sahip olduğu üç tabaka görülmektedir. Bunlar; giriş tabakası, bu tabakaya bağlanan gizlenmiş tabaka ve gizlenmiş tabakanın bağlı olduğu bir çıkış tabakasından meydana gelmektedir.



Şekil 3.5: Yapay Sinir Ağları mimarisine örnek.

YSA, insanlar gibi programlamadan değil deneyimlerden öğrenir. Performansını artırmak için deneyimlerden öğrenme yeteneği ve değişen çevre şartlarına göre adapte olma yeteneğine sahiptir. Ayrıca eksik bilgi ve gürültülü veri ile de çalışabilir. Kuralları ve adımlarının tanımlanması çok zor olan problemlerin çözümlerinde de oldukça etkili olabilmektedir (Makhfi, 2004). Tanıma, genelleme ve trend tahmini alanlarında oldukça iyidir (Gupta ve diğ., 2003).

Her bir işlemci kendi biyolojik karşılığını -nöron, sinir hücresi- simgelemek üzere tasarlanmaktadır. Şekil 3.6'da YSA'nın kabaca çalışma prensibine ait akış diyagramından da görüldüğü gibi belirli bir giriş verisinin, özel bir hedef çıktıyı vermesi için sinir ağları eğitilmekte ve ayarlanmaktadır. Çıktı ile hedef arasında belirlenen hata oranına ulaşıncaya kadar ağda işlemciler arasındaki ağırlık denen bağlantılarda ayarlama yapılmaktadır.



Şekil 3.6: Yapay Sinir Ağları çalışma süreci (Demuth ve Beale, 1998).

Farklı sayılarda gizli tabaka kullanılması farklı sonuçlar vermektedir ve kullanılacak en uygun tabaka sayısı ve tabakalardaki nöron sayıları ağ geliştirirken dikkat edilmesi gereken hususlardır. Başarılı bir öğrenme için kaç tane eğitim örneğinin kullanılacağını ve ağın ne kadar büyük olması gerektiğini belirlemek pratikte deneme yanılma yoluyla yapılmaktadır (Zhang ve Trimble, 1996; Mehrotra ve diğ., 1997). Öztopal (2007) çalışmasında işlemci elemanı sayıları belirlenirken kabaca giriş sayısı n olmak üzere (n+1)/2 veya 2n'den biraz fazla sayıda nöron kullanılabileceğine değinmiştir. Chattopadhyay ve Chattopadhyay (2008), muson yağışlarının tahmini için üç tabakalı YSA yapısında kullanılacak uygun işlemci sayısı belirlemek üzere bir çalışma gerçekleştirmişler ve 3 muson yaz ayının yağış verilerini giriş verisi olarak kullanmışlardır. Birçok farklı işlemci sayıları ile yaptıkları uygulamalar sonucunda bu 3 giriş verisi için en uygun ve başarılı ağ yapısının 11 işlemcili tek tabakalı bir YSA modeli olduğunu ortaya koymuşlardır.

3.3.1 YSA Sınıflandırması

YSA'ların yapıları ve öğrenme algoritmalarına göre sınıflandırması (Pham ve Liu, 1995) aşağıda görüldüğü şekildedir:

Öğrenme algoritmalarına göre:

Eğitmenli Öğrenme: Verilen bir girdiye karşılık gerçek ağ çıktısı ile arzu edilen ağ çıktı arasındaki farka göre işlemciler arası bağlantıların ağırlıklarını ayarlar (Principe ve diğ., 2000). Eğitmenli öğrenme algoritmaları, delta kuralı, genelleştirilmiş delta kuralı veya geri yayılım algoritması gibi algoritmalar içerebilir. Sınıflandırma eğitmenli öğrenme için örnek bir problemdir.

Eğitmensiz Öğrenme: Bu tip ağlarda arzu edilen çıktının bilinmesine gerek yoktur. Eğitim sürecinde sadece girdi paternleri yer alır. Ağ, girdileri benzer özelliklerine göre gruplandırmak için bağlantıların ağırlıklarını otomatik olarak ayarlar (Pham ve Liu, 1995). Kümeleme ise sınıflandırmadan farklı olarak eğitmensiz öğrenme için tipik bir problemdir. Çünkü kümelemede önceden sınıfların tanımlanmasına gerek yoktur. Sınıflandırmada ise her bir objenin özel bir sınıfa yerleştirilmesine çalışılır (Principe ve diğ., 2000).

Takviyeli Öğrenme: Eğitmenli öğrenmenin bir çeşididir. Hedef çıktıları vermesi için bir eğitmen kullanmak yerine bir takviye öğrenme algoritması, verilen bir girdiye göre ağ çıktısının doğruluğunu değerlendirmek için kritik yapmaktadır. Örnek olarak Genetik Algoritma verilmektedir.

Yapılarına göre:

İleri Yönlü Besleme Ağları: Nöronlar genellikle tabakalara ayrılır ve giriş tabakasından çıkış tabakasına doğru benzer yönlü bağlantılarla işaretler ilerler. Çoğunlukla bir girdi uzayı ile çıktı uzayı arasında statik haritalama gerçekleşir; verilen bir andaki çıktı sadece o andaki girdinin bir fonksiyonudur. Yaygın olarak örüntü tanımada kullanılmaktadırlar. Çoklu-Tabaka Algılayıcı (Multi-Layer Perceptron, MLPN), Öğrenen vektör niceleme ağı - LVQ Network (LVQ), Cerebellar Model Articulation Control Network, Group Method of Data Handling, bu yapıya örnek ağlardır.

Yinelenen Ağlar: Bazı işlemcilerin çıktıları aynı işlemci ya da bir önceki tabakadaki işlemcilere doğru ilerlemektedir. Böylece sinyaller hem ileri hem geri yönlerde

akabilir. Bu tip ağlara örnek olarak, Hopfield Ağı (HFM-Hopfield Model), Elman Ağı (ERNN, Elman Recurrent) ve Jordan ağı verilmektedir. Yinelenen ağlar dinamik bir hafızaya sahiptir, verilen bir andaki çıktılar, bir önceki girdiler ve çıktılar yanında geçerli girdiyi de yansıtmaktadır (Principe ve diğ., 2000).

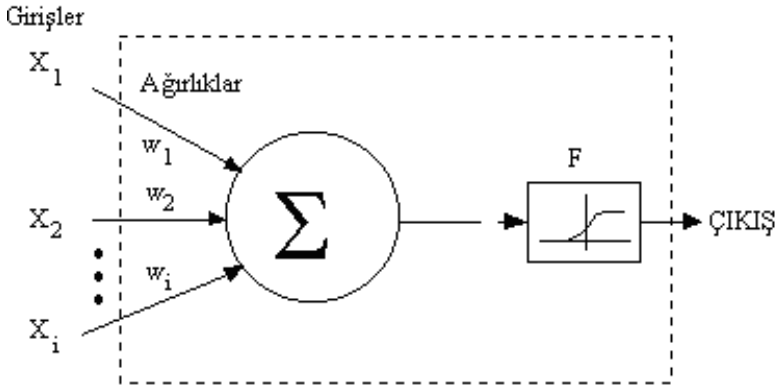
3.3.2 Temel YSA işlemcisinin çalışması

Gizlenmiş tabaka ile giriş tabakası arasındaki ağırlıklar ve giriş verileri, her gizlenmiş tabakadaki aktiviteleri belirlemektedir. Ağın lineer olmadığını belirtmek için gizlenmiş tabakalarda türevlenebilen (Ul-Saufie, 2011) aktivasyon fonksiyonu kullanılmaktadır (Gardner ve Dorling, 1998; Chattopadhyay ve Chattopadhyay, 2008). İlk tabakada sisteme sokulan girdiler, belirli ağırlıklar ile çarpılarak sonuçları toplanır ve elde edilen sonuç gizlenmiş tabakadaki aktivasyon fonksiyonuna aktarılmaktadır (Şekil 3.7). Girdilere her bir tabakada uygulanan işlem ve fonksiyonları sırasıyla:

1. Adım: Her bir X_i girdi değeri j işlemcisi için belirlenmiş w_{ji} ağırlık değeri ile çarpılır.

2. Adım: $\sum X_i w_{ji}$ ile elde edilen sonuçlar işlemci elemanının çıkış verisidir. Ağırlık matrisi (jxi) boyutundadır.

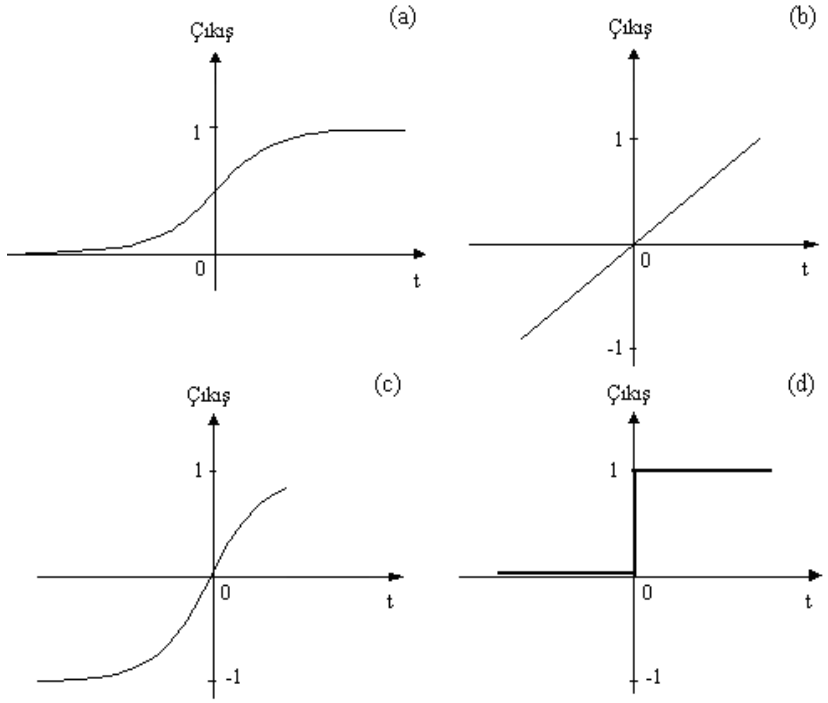
3. Adım: İlk tabakadan çıkan işlemci elemanı çıktıları, gizlenmiş tabakadaki ilgili j işlemcisinde aktivasyon fonksiyonuna girerek, çıktılar elde edilir.



Şekil 3.7: Örnek işlemci yapısı.

YSA modellerinde, işlemcinin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir (Chattopadhyay ve Chattopadhyay, 2008). Aktivasyon fonksiyonları kullanılırken parametreler sabit ya da uyarlanabilir olarak

seçilebilmektedir. Şekil 3.8'de işlemcilerde yaygın olarak kullanılan çeşitli aktivasyon fonksiyonları verilmiştir.



Şekil 3.8: Aktivasyon fonksiyonlarına örnekler, a) Sigmoidal, b) Doğrusal, c) Tanjant hiperbolik, d) Adım fonksiyonu.

3.3.3 Çoklu tabaka algılayıcı modeli ve geri-yayılım algoritması

İleri yönlü besleme ağlarından biri olan çoklu tabaka algılayıcısının (ÇTA) yapısı Şekil 3.5'de görülen YSA örneği ile benzerdir. Bu ağ yapısında giriş verileri, gizli ve çıkış tabakalarındaki işlemcilerde yukarıda verilen işlem sıraları ile eşitlik 3.9 ve 3.10'daki ağırlıklandırma işlemlerinden geçmektedir.

P girdi matrisinin elemanları P_{jk} (j=1, ..., N, N girdi değişkenlerinin sayısı, k=1, ..., L, L girdi serisinin uzunluğu), T satır vektörü elemanları T_k, k=1, ..., L ile çıktı serisidir. P'nin k. sütunu ile T'nin ilgili k. elemanı bir tahminci-tahmin edilen çifti oluşturmaktadır. Seçilen mimariye göre P_k ve T_k'lar i= 1, . . ., M olmak üzere aşağıdaki formla birleştirilmektedir:

$$h_i = F\left(\sum_j \hat{W}_{ij} P_{jk} + \hat{\mathbf{b}}_\mathbf{i} \right) \qquad \textbf{(3.9)}$$

$$T_k = \sum_i \tilde{W}_i h_i + \tilde{\mathbf{b}} \qquad \textbf{(3.10)}$$

$\hat{W}_{ij}$, bir $\hat{W}$ (M x N) matrisinin elemanlarıdır. $\hat{\mathbf{b}}$ (M x 1) sütun vektörüdür. $\tilde{W}_i$, $\tilde{W}$ (1xM) matrisinin elemanlarıdır ve $\tilde{\mathbf{b}}$ skaler bir değerdir. YSA terminolojisinde $\hat{W}$ ve $\tilde{W}$ girdi ağırlıklarıdır, $\hat{\mathbf{b}}$ ve $\tilde{\mathbf{b}}$'nin elemanlarına sapmalar (eğilimler) denir ve girdileri ile ilişkili ilave ağırlıklardır (istatistiksel eğilim terimi ile ilişkisi yoktur). M gizlenmiş tabakadaki işlemcilerin sayısı, F fonksiyonu gizlenmiş tabakadaki aktivasyon fonksiyonudur. 3.10 eşitliği, modelin lineer çıkış tabakasını düzenlemektedir. Gizlenmiş tabaka herhangi bir non lineerlik derecesindeki etkileşimleri çalıştırabilir fakat tanjant hiperbolik aralığına bağlı olarak değerleri (-1, 1) arasında verir. Çıkış tabakası, gizlenmiş tabakanın sonuçlarını lineer olarak istenen değere ölçeklemektedir.

Geri yayılım (backpropagation) algoritması:

1980'lerde yaygınlaşan metot, çoklu tabaka ağları ve lineer olmayan diferansiyellenebilir aktivasyon fonksiyonları için, Widrow-Hoff öğrenme kuralının genelleştirilmesi ile elde edilmiştir (Mehrotra ve diğ., 1997; Ul-Saufie, 2011). Lineer, sigmoid, tanjant hiperbolik, üstel fonksiyon gibi aktivasyon fonksiyonları ile birlikte kullanılabilmektedir.

Bu algoritma, en küçük kareler hatası öğrenme algoritması ile benzerdir ve gradyanlı azalmaya dayanmaktadır, yani ağırlıklar bir hata ölçüsünün negatif gradyanına uyacak yönde değiştirilmektedir (Ul-Saufie, 2008). Geri yayılma algoritması, ağ çıktısı ile hedef çıktı arasındaki arzu edilen farka ulaşana kadar ağırlıklarda değişiklik yapar. Hata hesaplanırken kullanılan fonksiyon, y_i ağ çıktısı, h_i hedef çıktı olmak üzere 3.10 eşitliğinde görüldüğü şekilde hesaplanmaktadır.

$$E = \frac{1}{2}\sum_i \left(y_i - h_i\right)^2 \qquad \textbf{(3.11)}$$

Geri yayılım algoritmasında, i ve j nöronları arasındaki bağlantı ağırlığındaki değişim, Δw_{ji} hesaplanırken; t adımındaki η öğrenme oranı ve δ_j, gizlenmiş ve çıkış tabakasına göre değişen delta faktörü ve x_i i işlemcisinden çıkan değer, α momentum katsayısı, olmak üzere 3.11 eşitliği kullanılmaktadır. Burada η ve δ öğrenme parametreleridir.

$$\Delta w_{ji}(t) = \eta(t)\delta_j(t)x_i(t) + \alpha\Delta w_{ji}\left(t-1\right) \qquad \textbf{(3.12)}$$

Delta faktörünün hesaplanması ise; net_j, j işlemcisi için ağırlıklandırılmış girdilerin toplamı, y_j^t, j işlemcisi için hedef çıktı olmak üzere, çıkış tabakası için:

$$\delta_j = \frac{\partial f}{\partial net_j}\left(y_j^{(t)} - y_j\right) \qquad \textbf{(3.13)}$$

Gizlenmiş tabaka için:

$$\delta_j = \left(\frac{\partial f}{\partial net_j}\right)\sum w_{qj}\delta_q \qquad \textbf{(3.14)}$$

LM algoritması bir çeşit lineer olmayan en küçük kareler metodudur. Hızla azalma (steepest descent) metodunu kullanmaktadır. Yapay sinir ağlarının eğitilmesi için LM algoritması en etkili öğrenme algoritmasıdır ve başlıca avantajı yakınsama hızıdır (Freiwan ve Cigizoglu, 2005). LM algoritması ile ilgili ayrıntılı bilgi için Principe ve diğ. (2000)'den yaralanılabilir.

YSA ile ilgili literatür özeti

Hsieh ve Tang (1998) meteoroloji ve oşinografi alanlarında tahmin ve veri analizi konusunda YSA modellerinin kullanılması ile ilgili bir çalışma yapmışlardır ve YSA'nın meteoroloji ve oşinografiye uygulanmasındaki zorluklar 3 sebebe bağlanmıştır. Bunlardan birincisi kısa veri kayıtlarında lineer olmayan kararsızlığın var olmasıdır. Verideki lineer olmayan ilişkileri modellemeye çalışırken YSA birçok serbest parametreye sahiptir ve veri kaydı kısaysa çoğu parametrenin çözülmesi problemi zorlaşmaktadır. Bu durumda YSA'nın çok gürültülü veya tamamıyla hatalı tahminler vereceği ve basit bir lineer istatistiksel modelden kötü performans göstereceği belirtilmiştir. YSA modellerinin üstünlüğü, oldukça kısa veri kaydıyla lineer olmayan ilişkileri nasıl kontrol edebileceği hususunda ortaya çıkmaktadır. İkinci problem ise çok büyük bir alandaki veriyle çalışmaktır. Meteorolojik ve oşinografik veriler genellikle çok sayıda grid noktası veya istasyona aittir. Her bir istasyon YSA'da bir girdi olarak kullanıldığında ve kısa zaman kayıtları mevcutsa yine çözmesi zor bir problem ortaya çıkmaktadır. Diğer bir problem ise YSA tarafından ortaya konulan lineer olmayan ilişkilerin yorumlanmasındaki zorluklardır. YSA tarafından belirlenen ağırlıklar hemen hemen anlaşılmazdır. Bu üç problemin üstesinden gelmek amacıyla yapılan çalışmaları sonucunda şunları elde etmişlerdir: Birinci problemin çözümü için, eğitim ve test verileri olarak tahminler çeşitli şekillerde bölünmüş ve her bir veri seti için eğitilmiş YSA'ların ensemble ortalaması

alınmıştır. Bu şekilde lineer olmayan karasızlığın daha iyi modellenebildiğini belirtmişlerdir. İkinci problemin çözümü içinse temel bileşen analizi kullanılarak çok sayıda istasyona ait veriyi filtrelemeyi önermişlerdir. Son problemin de üstesinden gelmek için yeni ölçü ve görselleştirme teknikleri öne sürülmüştür. Ayrıntılar ilgili çalışmada yer almaktadır (Hsieh ve Tang, 1998).

Taylor ve Buizza (2002), ensemble hava tahminlerini giriş verisi olarak YSA metodunda kullanarak İngiltere için elektrik yükü tahmini yapmaya çalışmışlardır. Daha çok lineer yöntemlerle yapılan bu tahminler için YSA'nın yararlı bir metod olacağı öne sürülmüştür.

Freiwan ve Cigizoglu (2005), Ürdün bölgesinde aylık toplam yağış tahmini için YSA metodunu kullanmışlar ve uygun ağ yapısını belirleyerek performansını daha geleneksel bir yöntem olan AR metodu ile kıyaslamışlardır. YSA uygulamaları yapılırken eğitim verisi olarak farklı dönemler de seçilmiştir. Elde ettikleri 4 en başarılı ağın AR metoduyla kıyaslanması sonucu 4 YSA modelinin de AR modeline göre daha başarılı olduğu ortaya konmuştur. Ancak YSA tahminlerinin bazılarında negatif yağış değeri ürettiği ve yağış değerlerinin pik yaptığı durumlarda daha düşük tahminler ürettiği de ortaya konmuştur.

Maqsood ve diğ., (2004) hava tahmininde kullanılmak üzere bir YSA'lar ensemble'ı elde etmeye çalışmışlardır. 4 farklı YSA modeli (MLPN, ERNN, HFM, RBFN (Radial Basis Function Neural Network/Radyal tabanlı fonksiyon ağı)) kullanılmış ve sıcaklık, rüzgar hızı ve bağıl nem verileri ile bu sistemler eğitilmiştir. Deneme yanılma yoluyla model yapıları belirlenmiştir. Ensemble değeri, her bir ağ çıktısının ağırlıklı ortalamasıdır. Bu ağırlıklar, her bir ağın eğitim periyodunda belirlenen bağıl hatasının bir fonksiyonudur. Çalışmayı yapmaktaki amaç, sinir ağları ensemble'ı kullanmanın tatmin edici doğrulukta sınıflandırmalar sağladığını kanıtlamak ve amaçlanan birleştirme metodunun performansını bireysel metotlarla karşılaştırmaktır. "Kazanan hepsini alır" (winner take all) yaklaşımıyla birleştirilen YSA'ların daha başarılı olduğu ortaya konmuştur.

Ul-Saufie ve diğ., (2011) çoklu doğrusal regresyon ve YSA metodlarını kullanarak hava koşullarından etkilenen PM_{10} (Partikül Madde) konsantrasyonu tahmininde hangisinin daha başarılı olduğunu ortaya koymaya çalışmışlardır. Basitçe uygulanabilir ve kolay hesaplanabilir olması lineer regresyon metotlarının avantajı

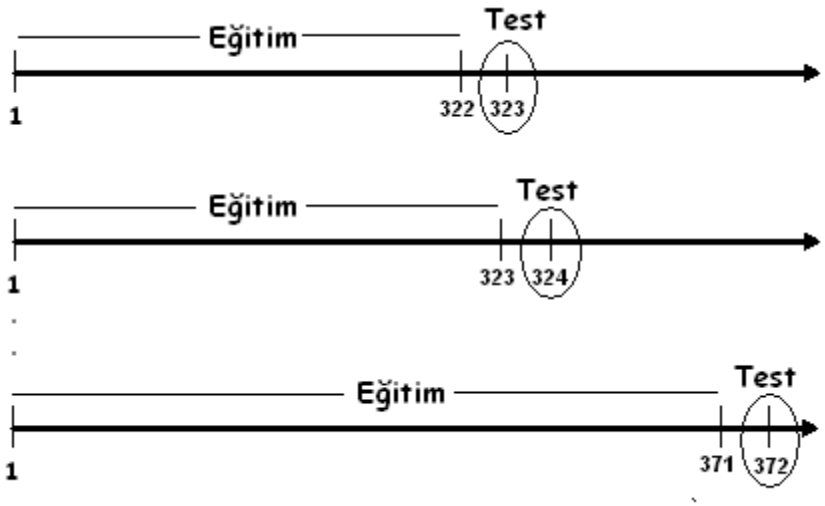
olarak gösterilirken parametreler arasında doğrusal ilişkiler kurmasından dolayı bazı kompleks durumlar ve ekstrem değerler karşısında başarısız tahminler yapabileceği, ayrıca bağımlı ve bağımsız değişkenler arasındaki mevcut eş-lineerliğin (co-linearity) regresyon modelinin yetersiz kalmasına neden olabileceği belirtilmiştir. Yapılan analizler ve değerlendirmeler sonucu YSA'nın lineer regresyona göre daha başarılı bulunduğu belirtilmiştir.

4. UYGULAMA VE ANALİZ

Bu çalışmada uygulanan bias-düzeltmesi yapılmış ensemble ortalaması (kontrol tahmini-KTRL) ve YSA temelinde geliştirilen adaptif ensemble sistemi (YSA) ile adaptif lineer regresyona dayalı olarak uygulanan Süperensemble (SE) sisteminin performansları çeşitli ölçütlerle değerlendirilmiştir. Ensemble sistemlerinin analizlerine değinmeden önce model konfigürasyonları ve çalışmada kullanılan değerlendirme kriterleri ile ilgili genel bilgiler verilmiştir.

4.1 Model Konfigürasyonları

Türkiye genelinde başarılı bir ensemble tahmini elde etmek için çeşitli YSA ağ yapıları denenmiş, farklı öğrenme algoritmaları ve parametre değerleri ile birçok çalışma yapılmıştır. YSA sistemini kıyaslamak üzere kontrol tahmini olarak kabul ettiğimiz bias-düzeltmesi yapılmış ensemble ortalaması ile Süperensemble konfigürasyonları da YSA sisteminin çalışmasına benzer olarak adaptif olarak düzenlenmiştir. Bu adaptif sistemler ile ilgili ayrıntılar bu bölümde verilmiştir. Sistemlerin adaptif olmasını sağlayan, çalışmada test tahmini olarak ayrılmış her bir veri için ensemble sistemin ağırlıklarını yeniden güncellemesidir. Böylece Şekil 4.1'den görüldüğü gibi her adımda eğitim verisi sayısı artmakta bu da anomaliler elde edilirken kullanılan klimatoloji (ortalama) değerlerinin de güncellenmesini sağlamaktadır.



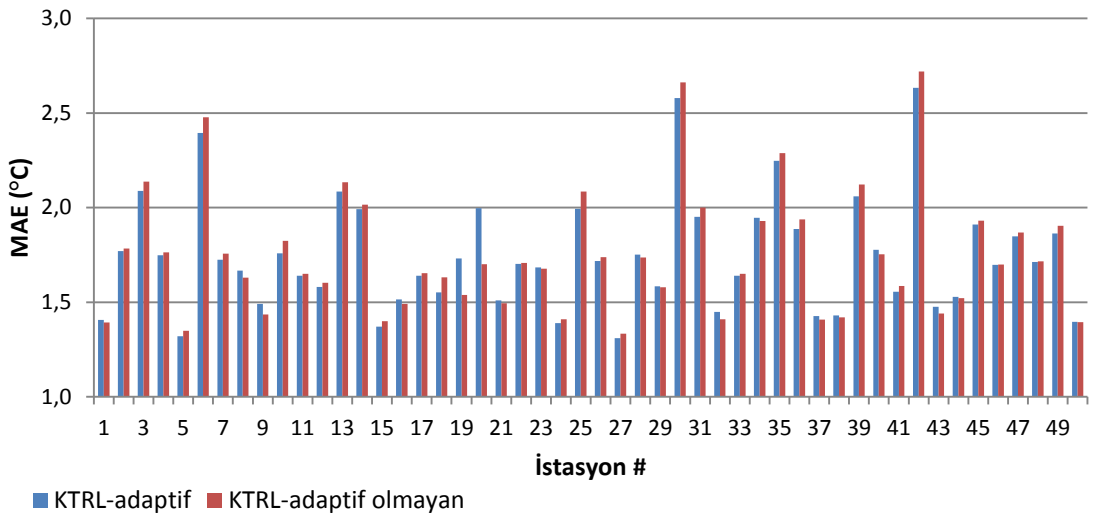
Şekil 4.1: Uyarlanabilir sistemde eğitim ve test verisi belirlenmesi.

4.1.1 Kontrol ensemble sistemi (KTRL)

Farklı modellerin direk tahmin ortalamasını almak yerine bias düzeltmesi yapılmış tahmin ortalamaları kontrol tahmini olarak seçilmiştir. Eşitlik 3.3 ve 4.1'den görüldüğü gibi model tahminin (F) kendi uzun yıllar ortalamalarından ($\overline{F_i}$) olan farkları (anomali) eşit ağırlıklı olarak bir araya getirilir ve elde edilen ortalama değere gözlem ortalaması ($\overline{O}$) ilave edilerek yeni sıcaklık tahminleri ortaya konmaktadır.

$$KTRL_{ens} = \overline{O} + \frac{1}{N}\sum_{i=1}^{N}(F_i - \overline{F_i}) \qquad \textbf{(4.1)}$$

YSA konfigürasyonunda da uygulandığı gibi adaptif bir yol izlendiği zaman, her bir test verisi için kendinden önceki veriye kadar olan tüm veriler anomali hesabında uzun yıllar ortalamasına katılmaktadır. Adaptif olmayan yöntemde ise veri eğitim ve test setleri olarak ikiye bölünmektedir ve eğitim veri setindeki ortalamalar hesaplanıp anomali değerleri bu ortalamalardan hesaplanmaktadır. Bu iki sistemden elde edilen sonuçlar kıyaslandığında sadece 19 ve 20 numaralı istasyonlar dışında çoğu istasyonda az farkla da olsa MAE bakımından adaptif olan yöntem daha başarılı görünmektedir (Şekil 4.2).



Şekil 4.2: Uyarlanabilir ve uyarlamasız KTRL sistemin test periyodu için tahminlerinin istasyonlara göre MAE değerleri.

4.1.2 YSA ensemble sistemi konfigürasyonu

Kullanılacak gizli tabaka sayısı daha önce belirtildiği gibi probleme bağlı olarak deneme yanılma yoluyla belirlenmektedir. Ancak ileri doğru beslenen ağlarda fazla sayıda gizli tabakanın karmaşıklık yarattığı, 3 tabakalı ağların tüm lineer olmayan ilişkileri çözebilecek kadar yeterli olduğu da savunulmaktadır (Dayhoff ve DeLeo, 2001; Mcnelis, 2005). Ayrıca evrensel yaklaşım teoremine dayalı olarak da tek gizli tabaka önerilmektedir (Pei ve Mai, 2008).

Bu çalışmada farklı gizlenmiş tabaka sayıları ve nöron/işlemci sayılarıyla ağlar oluşturulmuş ve uygun işlemci sayısı belirlenmeye çalışılmıştır. Ayrıca Levenberg Marquardt (LM) ve gradyanlı azalma algoritmaları kullanılarak performansları incelenmiştir. Ağ yapısının özellikleri ve değiştirilebilen parametrelerin görülmesi açısından yazılan Matlab kodundan bir kısım aşağıdaki gibidir.

```
net = newff(minmax(pn),[5 1],{'tansig' 'purelin'},'trainlm');
net.trainParam.epochs = 1000;
net.trainParam.goal = 0;
net.trainParam.mu_max = 1e1000;
net.trainParam.minstep = 0;
net.trainParam.bmax = 56;
net.trainParam.min_grad = 0;
net.trainParam.maxstep = 100;
net.trainParam.lr = 0.08;
```

newff komutu, yeni bir feed-forward ağının oluşturulduğunu göstermektedir. Parantez içerisinde ilk verilen eğitimde kullanılacak girdi matrisi tanımlanır. Köşeli parantez içerisindeki değerler her bir gizli tabaka ve çıkış tabakasındaki nöron sayılarını temsil etmektedir. Bizim için tek bir hedef değer olduğu için çıkış tabakasındaki birim sayısı 1 olarak belirlenmiştir. Bir sonraki kısım ise gizlenmiş ve çıkış tabakalarında kullanılacak aktivasyon fonksiyonlarını göstermektedir. En son satırda ise eğitimde kullanılacak algoritma (trainlm=levenberg-marquadt, traingd=gradient descent) ifade edilmektedir.

Bu çalışma gerçekleşirken erken durdurma sürecinin kullanılıp kullanılmaması, sistemin adaptif olup olmaması, ağırlıkların başlangıçta belirlenip belirlenmemesi gibi değişikliklerle birçok uygulama yapılmıştır. En başarılı performansı sergileyen ve ileride de analizleri sunulan ağın ayrıntıları verilmiştir.

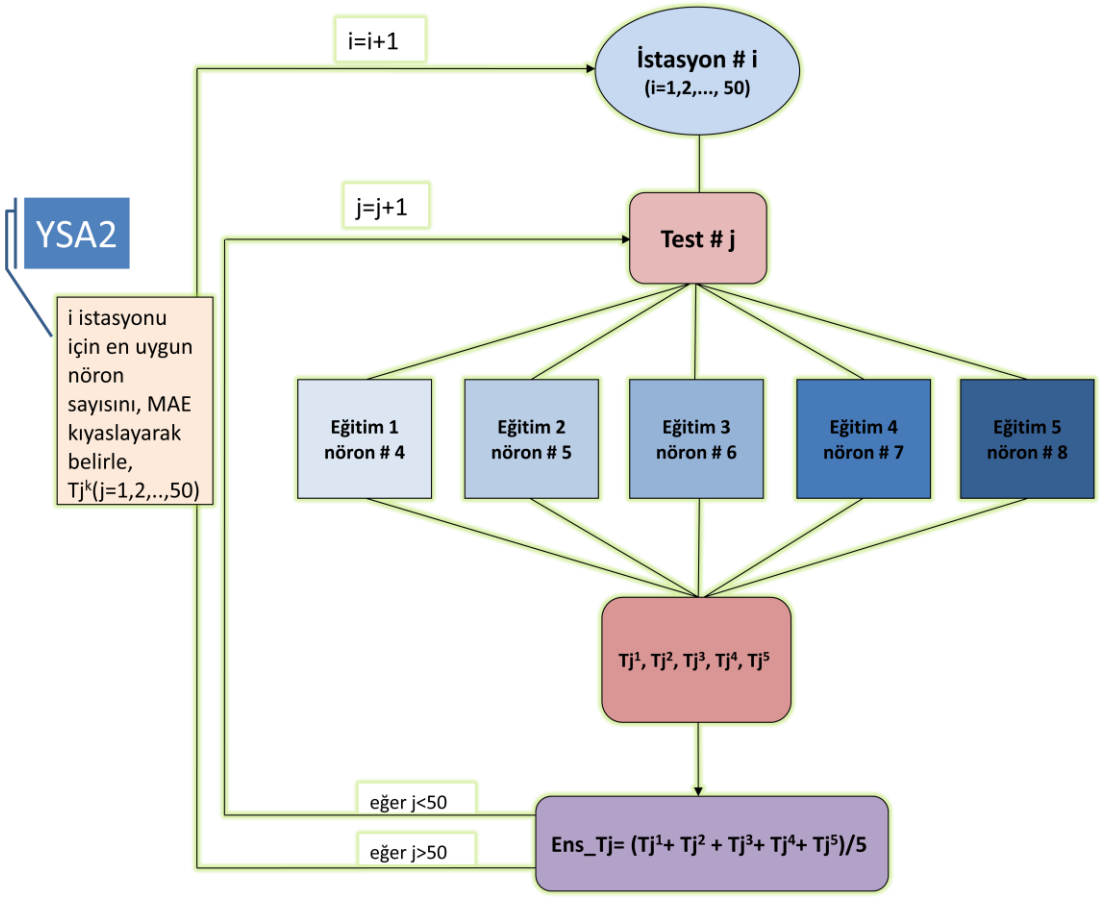
Şekil 4.3'de akış diyagramında görülen YSA temelindeki ensemble sisteminde her bir test verisi için gizli tabakadaki nöron sayısı birer arttırılarak (4-8 nöron arası) ağ eğitilmektedir. Böylece her test verisi için farklı nöron sayıları ile yapılandırılmış ağdan 5 tane farklı sonuç elde edilmektedir. Her istasyon için bu yolla toplam 50 test verisi için yapılmaktadır. Her test verisi için eğitim yapılırken adaptif bir sistem oluşturulmaya çalışıldığından eğitim verisinin değiştiği bir önceki kısımda Şekil 4.1'de gösterilerek açıklanmıştır.

Her bir nöron sayısı ile elde edilmiş 50 test tahminin NCEP/NCAR test verilerine karşılık ortalama mutlak hata (MAE) değerleri hesaplanmaktadır (her istasyon için 5 farklı MAE değeri). Her bir istasyon için minimum MAE'ye sahip olan nöron sayısı belirlenmekte ve o nöron sayısı ile eğitilmiş ağın test sonuçları dikkate alınmaktadır ve diğer performans ve başarı değerlendirmeleri de bu test tahminlerinden elde edilmektedir.

Farklı YSA mimarilerinden elde edilecek tahminlerin tek bir ağ elde edecek şekilde birleştirilmeleri tekniği yapay sinir ağlarının bir ensemble'ı şeklinde düşünülebilir ve bu konuda çeşitli çalışmalar yapılmaktadır. Elde edilen ağın genellikle bireysel ağlara göre daha doğru sonuçlar verdiği gözlenmiştir (Jimenez ve Walsh, 1998). Yaygın olarak kullanılan yapay sinir ağları teknikleri arasında MLPN, ERNN, RBFN ve HFM (Maqsood ve diğ., 2004).

Bu çalışmada farklı YSA modelleri değil de farklı nöron sayısı ile eğitilen tek tip ağdan (ileri doğru beslenen çoklu tabaka algılayıcı) elde edilen test tahminlerinin ortalaması hesaplanmaktadır ve bir nevi YSA'ların ensemble'ından elde edilmiş tahminler de sunulmaktadır. Şekil 4.3'de bu test tahminleri YSA1, yukarıda açıklandığı şekilde belirlenmiş tek bir nöron sayısına bağlı olarak elde edilen tahminler ise YSA2 diye adlandırılmaktadır. Bu sistemden ortaya konan 2 farklı tahmin kontrol ensemble (KTRL) tahminleri ile kıyaslandığı zaman YSA2 olarak adlandırılan tahminlerin daha başarılı olduğu görülmüştür. Bu nedenle bu tahminlere ait doğruluk değerlendirmeleri çeşitli grafik ve haritalarla sunulmuş diğer sistem tahminleri ile kıyaslamaları yapılmış ve analizler kısmında YSA kısaltmasıyla sunulmuştur.

Geliştirilen YSA ensemble sisteminde başlangıç tabakası ve gizli tabaka ağırlıklarının rastgele belirlenmesi yerine KTRL tahmini ile aynı değerleri verecek şekilde ve bu koşullarda eğitime başlanması amacıyla ilk başta eşit olarak ağırlıklandırılmışlardır. Bu da giriş tabaksı ağırlıklarının 0.25 gizli tabaka ağırlıklarının ise kullanılan işlemci sayısına göre n/4 olacak şekilde belirlenmiştir.



Şekil 4.3: YSA ensemble sisteminin akış diyagramı.

4.2 Değerlendirme Kriterleri

Buizza ve diğ. (2005)'ne göre ensemble tahmin sistemlerinin performansı değerlendirilirken üç açıdan katkısı dikkate alınmaktadır, bunlar: istatistiksel güvenilirlik (tutarlılık), istatistiksel ayırt edicilik (resolution) ve ayrım yapabilmedir (discrimination). İstatistiksel güvenilirlik, bir tahmin örneğinin istatistiksel olarak ilgili gözlemler örneğinden farksız olmasını gerektirmektedir. Güvenilirlik, bazı istatistiksel işlem-sonrası tekniklerle geliştirilebilmektedir. İstatistiksel ayırt edicilik, tahmin sisteminin gelecekteki olayları önceden ayırt edebilme yeteneği, ayrım yapabilme ise tahmin edilen olayların gerçekleşme ve gerçekleşmemesini ayırt edebilme yeteneğidir.

Tahmin performansını değerlendirirken bilinmesi gereken bazı temel kavram ve kriterler ise şöyledir:

Doğruluk: Tahmin ve gözlem çiftlerinin ortalama olarak ne kadar benzeştiğini ortaya koyan ölçüdür ve doğruluk için elde edilen skaler değer, tahminlerin genel

kalitesini özetlemektedir. Ortalama mutlak hata (MAE), hataların kareli ortalaması (MSE) ve hataların kareli ortalamalarının karekökü (RMSE) ve ortalama hata (OH) doğruluk değerlendirilmesinde kullanılabilen ölçülerden bazılarıdır (Warner, 2011).

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|T - O| \tag{4.2}$$

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(T - O)^2 \tag{4.3}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(T - O)^2} \tag{4.4}$$

T ensemble tahmini, O hedeflenen gözlem, n toplam tahmin sayısı olmak üzere MAE, MSE ve RMSE sırasıyla 4.2, 4.3 ve 4.4 eşitlikleri ile hesaplanmaktadır.

RMSE hataların karesini hesaba kattığından büyük hatalar için MAE'ye göre daha hassastır. Fakat her ikisi de sistematik veya rastgele hataları da içermektedir. MAE ve RMSE'nin 0'a yakın değerleri tahminlerin doğruluğunu göstermektedir (Katz ve Murphy, 1997; Warner, 2011).

Ortalama Hata (OH, bias), sistematik hata olarak da bilinir ve 4.5 eşitliğinden görüldüğü gibi tahminlerin ortalaması ($\overline{T}$) ile gözlemlerin ortalaması ($\overline{O}$) arasındaki farkı ortaya koymaktadır.

$$OH = \frac{1}{n}\sum_{i=1}^{n}(T - O) = \overline{T} - \overline{O} \tag{4.5}$$

OH'ların pozitif değerleri tahminlerin gözlemlerden yüksek sonuçlar verdiğini, negatif değerleri ise düşük tahminler verdiğini, modellerde bu şekilde sistematik hataların mevcut olduğunu göstermektedir (Katz ve Murphy, 1997). OH'ın 0 değeri tahminlerin başarılı olduğunu gösterir.

İşaret ve eşik değer uyum oranları: Anomali değerlerini sürekli değil de ayrık bir veri seti olarak düşünebiliriz. Bu durumda yapılan her bir anomali tahmini ile gözlenen anomali değerinin her ikisinin de pozitif veya negatif olma uyumlulukları, İşaret Eşleşme Oranı (İEO) değeri ile belirlenebilir (Eşitlik 4.6). Bu da bir çeşit doğruluk hesabı olarak kabul edilebilir. Çizelge 4.1'de verilen ihtimal tablosundan İEO değerleri hesaplanırken dikkate alınacak değerlendirmeler görülmektedir.

Aynı tablodan hareketle önceden belirlenecek eşik değerlerinin tahminlerde gözlenip gözlenmemesi (Doğru/Yanlış), bunların gözlemlerle uyumlu olma oranı (Hit rate) ortaya konulabilir. Bu çalışmada 1°C üstü ve -1°C altı anomali değerleri eşik değerler olarak belirlenip bunların uyum oranları değerlendirilmiştir.

Çizelge 4.1: Gözlemlerdeki anomali işaretinin tahminlerdeki işaretlerle eşleşme tablosu.

		GÖZLEM		
		pozitif	negatif	
TAHMİN	pozitif	a	b	a+b
	negatif	c	d	c+d
		a+c	b+d	n

Burada a+b+c+d=n tane toplam tahmin olmak üzere İEO, 4.6 eşitliğinde görüldüğü gibi hesaplanmaktadır:

$$İEO = \frac{a+d}{n} \tag{4.6}$$

Başarı: Belirli bir referans tahmine göre yeni tahminin performansında ne kadar ilerleme olduğunu ortaya koymaktadır. Daha kolay elde edilebilen, basit, ortalama başarıya sahip bir tahmin referans tahmin olarak belirlenebilir (Warner, 2011). Bu çalışmada kontrol tahmin olarak adlandırılan referans tahmin, bias-düzeltmesi yapılmış ensemble ortalamalarıdır. İyileşme yüzdesi (İY) başarının ortaya konmasında kullanılan ölçütlerden birisidir. Eşitlik 4.7'de MAE bakımından referans veya kontrol tahmine göre iyileşme oranının elde edilmesi görülmektedir. Aynı hesaplama RMSE veya İEO gibi ölçütler için de yapılabilir.

$$İY(MAE) = \frac{MAE_{KTRL} - MAE_{YSA}}{MAE_{KTRL}} \tag{4.7}$$

İY'nin pozitif değerleri geliştirilen sistemin referans sisteme göre daha başarılı olduğunu göstermektedir. Tam tersi negatif değerler referans sistemin başarısını

ortaya koyduğu gibi, 0'a yakın değerler kıyaslanan sistemlerin başarısının birbirine yakın olduğunu gösterir.

Bu çalışmada bazı istatistiksel değerlendirmeler üzerinde durulmuş, doğruluk ve başarı analizleri yapılmıştır. MAE, RMSE, OH (bias), İY, İEO hem genel, hem de bölgesel ve mevsimsel olarak değerlendirilmiştir.

4.3 Model Sonuçlarının Analizi

"Ensemble üyesi olarak kullanılan tahminlerin ensemble tahmine katkısı nedir? En iyi performanslı ensemble üyesinden daha başarılı bir tahmin elde edilebiliyor mu? En kötü tahmin ensemble başarısını düşürmeyecek mi?" (Weigel ve diğ., 2008) gibi sorulara yanıt bulmak amacıyla ensemble üyesi modeller arasında hep en iyi veya en kötü performansı sergileyen bir model olup olmadığını ortaya koymak önemlidir. Hagedorn ve diğ. (2005)'e göre en iyi veya en kötü modeli belirlemek genellikle mümkün değildir, çünkü bireysel olarak güçlü ve zayıf oldukları yanlar, bölgeye, tahmin edilen değişkene göre vs. değişmektedir.

Geliştirilen ensemble tahmin sistemlerinin performanslarını ortaya koymadan önce ensemble üyesi modellerin (AORG, ANRG, KNRG, KORG) bazı istatistiksel özellikleri ve bireysel hataları incelenmiştir.

4.3.1 Ensemble üyesi modellerin analizi

Ortalama ve varyans istatistikleri:

Ensemble sistemlerinde girdi verisi olarak kullanılan model versiyonlarının 50 test tahmini için ortalama ve varyans bilgileri bölgesel ve mevsimlik ortalamalar olarak Çizelge 4.2'de verilmiştir. Analizleri yapılan 50 test verisi, 2003 yılı ekim ayının 2. yarısından başlamak üzere 2 haftalık ortalama anomaliler şeklinde 2005 yılı sonuna kadar devam etmektedir. Ensemble üyesi modellerin tahminleri arasındaki farklılığı ortaya koymak amacıyla hazırlanan bu çizelgede bölgesel ortalamalar alındığından istasyonlar arasındaki farklar görülememektedir. Gözlemlere ait ortalama ve varyans bilgileri de çizelgede yeralmaktadır.

Çizelge 4.2: Gözlenen değerler ve ensemble üyesi modellerin test tahminleri için bölgelere göre mevsimlik ortalama ve varyans değerleri (Gözleme en yakın değerler renklendirilmiştir).

		İlkbahar		Yaz		Sonbahar		Kış	
		Ort	Var	Ort	Var	Ort	Var	Ort	Var
Akdeniz	AORG	-0.003	0.734	-0.136	0.174	0.135	1.937	0.447	1.069
	ANRG	0.087	1.463	-0.544	0.660	0.282	2.253	0.272	1.263
	KNRG	-0.081	0.746	-0.366	0.509	0.134	2.086	0.375	1.298
	KORG	-0.175	0.691	-0.059	0.264	-0.056	1.813	0.325	1.127
	Gözlem	**0.745**	**1.689**	**0.155**	**0.710**	**0.422**	**3.862**	**0.417**	**6.343**
Marmara	AORG	-0.396	0.742	-0.381	0.294	0.415	2.518	1.137	1.221
	ANRG	-0.289	1.117	-0.815	0.624	0.513	2.785	0.920	1.004
	KNRG	-0.401	0.894	-0.765	0.522	0.603	2.607	1.026	1.498
	KORG	-0.504	0.887	-0.356	0.322	0.343	2.318	0.938	1.794
	Gözlem	**0.186**	**2.405**	**0.040**	**1.007**	**0.037**	**5.093**	**0.111**	**5.584**
Karadeniz	AORG	-0.776	1.294	-0.465	0.446	0.539	3.400	1.465	0.894
	ANRG	-0.692	1.279	-0.916	0.909	0.564	3.764	1.450	1.395
	KNRG	-0.654	0.969	-0.811	0.940	0.616	3.711	1.703	1.479
	KORG	-0.883	0.995	-0.370	0.609	0.396	3.486	1.430	1.000
	Gözlem	**0.215**	**1.802**	**0.268**	**1.060**	**0.382**	**4.716**	**0.385**	**6.071**
Doğu A.	AORG	-0.045	3.119	0.033	0.232	0.382	0.801	0.605	2.021
	ANRG	0.269	3.068	-0.600	1.791	0.260	2.365	0.726	3.356
	KNRG	-0.122	1.768	-0.228	1.406	0.255	1.725	1.114	3.528
	KORG	-0.167	1.942	0.272	0.573	-0.105	1.055	0.608	1.671
	Gözlem	**0.039**	**4.538**	**0.078**	**0.794**	**0.096**	**3.185**	**0.026**	**9.285**
GDA	AORG	0.029	2.262	-0.030	0.189	0.245	0.675	0.498	1.619
	ANRG	0.342	3.543	-0.561	1.831	0.210	1.936	0.499	3.280
	KNRG	-0.079	1.418	-0.345	1.490	0.106	1.427	0.864	2.460
	KORG	-0.145	1.566	0.096	0.547	-0.087	0.768	0.383	1.550
	Gözlem	**0.301**	**1.496**	**0.048**	**0.836**	**0.111**	**3.663**	**0.673**	**8.018**
Ege	AORG	0.019	0.798	-0.142	0.178	0.201	1.633	0.547	0.897
	ANRG	-0.001	1.009	-0.771	0.836	0.404	1.718	0.363	0.711
	KNRG	-0.097	0.883	-0.592	0.488	0.397	1.485	0.413	1.073
	KORG	-0.103	0.725	-0.069	0.249	0.088	1.412	0.405	1.291
	Gözlem	**0.270**	**1.468**	**0.043**	**0.916**	**0.226**	**5.646**	**0.005**	**6.827**
İç A.	AORG	0.118	2.028	-0.004	0.178	0.268	0.964	0.498	0.941
	ANRG	0.337	2.659	-0.768	1.302	0.438	1.413	0.108	2.133
	KNRG	0.201	1.533	-0.656	1.318	0.428	1.242	0.405	1.814
	KORG	-0.127	1.438	0.135	0.377	0.063	0.995	0.248	1.555
	Gözlem	**0.562**	**1.606**	**0.458**	**0.757**	**0.733**	**5.575**	**0.084**	**11.373**

Çizelge 4.2'den görüldüğü gibi gözlemlerin kış mevsimi varyasyonlarının tüm bölgelerde oldukça yüksek değerlerde olduğu dikkati çekmektedir. İkinci en yüksek varyasyon görülen mevsim Doğu Anadolu Bölgesi dışındaki tüm bölgelerde sonbahar mevsimidir. En düşük varyasyonlar ise yaz aylarında gözlenmiştir. Üye modellerin varyans değerlerinin de bölgeler içinde mevsimsel olarak birbirlerinden farklılık gösterdiği görülmektedir. Yaz mevsimi varyansları tüm bölgesel ortalamalarda en düşük değerlerdedir.

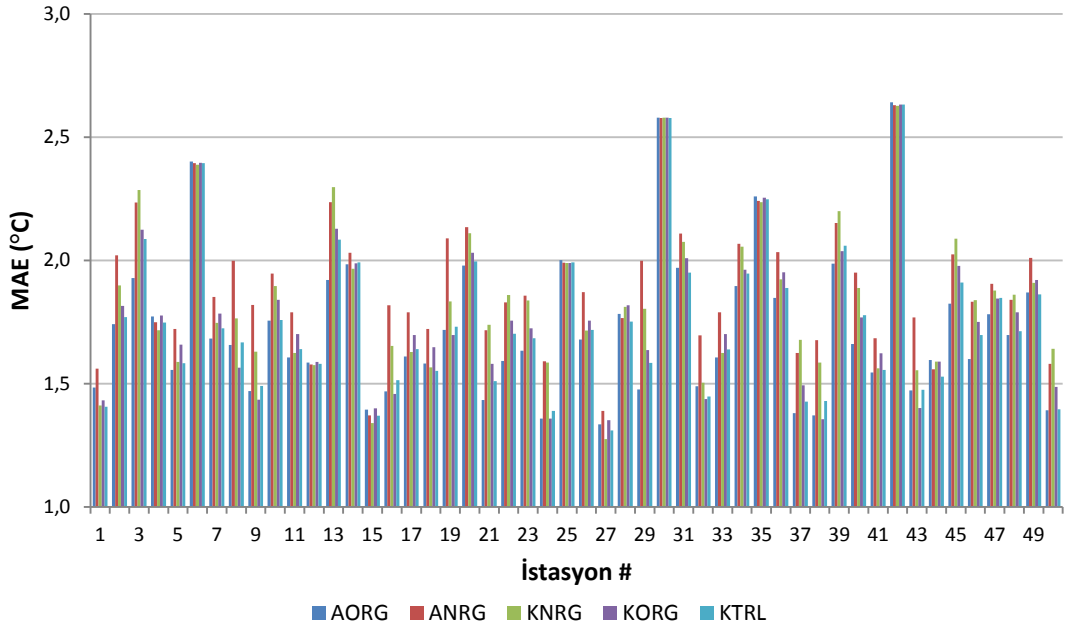
Üye modellerin tahminlerinde sonbahar mevsimi varyasyonları özellikle Karadeniz Bölgesinde olmak üzere Akdeniz ve Marmara'da diğer mevsimlere göre yüksek değerlerdedir. Bu bölgenin ilkbahar mevsimi ve Marmara Bölgesinin yaz mevsimi varyansları yine tüm versiyonların sonuçlarına ve diğer bölgelerin değerlerine göre daha yüksek görülmektedir. Doğu Anadolu, Güneydoğu Anadolu ve İç Anadolu Bölgelerinde ise sonbahar varyanslarının diğer mevsimlerden yüksek olduğu görülmektedir.

Her bir model versiyonunun istasyon tahminlerinden elde edilen bölgeler ortalamasında, birbirlerinden farklı ortalama değerlerine sahip oldukları ve gözlenen ortalamalara göre Karadeniz ve Marmara'da kış mevsiminde yüksek, yaz mevsiminde ise düşük değerler verecek tahminler yaptıkları açıktır. Bu da model versiyonlarında mevcut sistematik hataların mümkün olabileceğini göstermektedir. Sonbahar ortalama değerlerinde ise Akdeniz ve İç Anadolu Bölgeleri dışında model versiyonlarının gözlemlere göre yüksek değerleri vardır.

Elde edilen sonuçlara göre hem gözlem ortalamalarına hem de varyanslarına yakın sonuçlar verecek tek bir üye model olmadığı görülmektedir. Bölgeler arasında da mevsimine göre başarılı sayılabilecek yani istatistiksel açıdan gözlemlere yakın tahminler yapacak model versiyonu görülmediğinden bu modellerin ensmeble'ından daha doğru tahminler elde edilmesi beklenmektedir. Ensemble tahminleri elde edilmesinde kullanılan her bir modelin kontrol ensemble tahminleri ile kıyaslanarak doğruluk analizlerinin yorumlanması da ensemble sistemlerin başarısının ortaya konması açısından önemlidir.

Ensemble üyesi modeller için doğruluk analizi:

Her bir üye modelin ve kontrol ensemble tahminlerinin gözlem verilerine göre hesaplanan MAE değerleri Şekil 4.4'de görüldüğü gibidir. Burada en yüksek hata değerlerine sahip istasyonlar sırasıyla Karadeniz Bölgesinde yer alan 6, 30 ve 42 numaralı Bartın, Kastamonu ve Samsun istasyonlarıdır. Üye model performanslarının KTRL tahminleri performansları ile oldukça yakın değerlere sahip olduğu görülmektedir.



Şekil 4.4: Her bir istasyon için ensemble üyesi modellerin (AORG, ANRG, KNRG, KORG) ve kontrol ensemble sisteminin (KTRL) test periyodu tahminlerinin ortalama mutlak hata (MAE) değerleri.

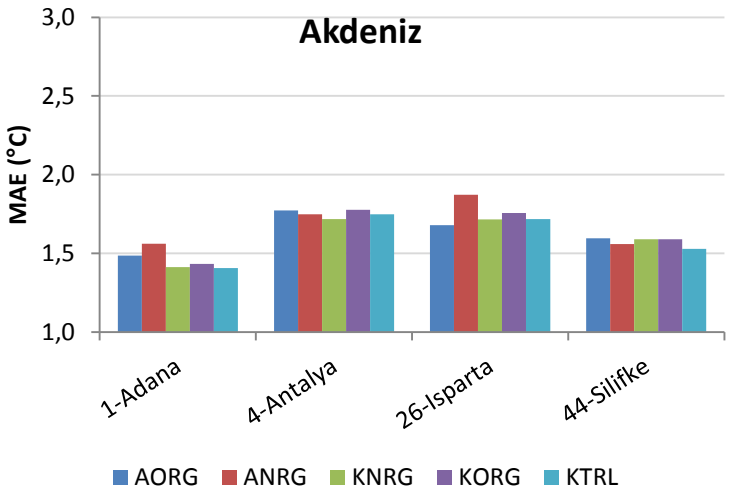
Burada çoğu istasyon için ensemble üye modellerin performanslarının farklılık gösterdiği ve KTRL tahminle kıyaslandıkları zaman özellikle belli başlı istasyonlarda KTRL ve üye modellerin çok yakın hata değerlerine sahip olduğu görülmektedir. Bu nedenle istasyonların ait oldukları coğrafik bölgelere göre ayrılarak sonuçların daha net görülmesi amaçlanmıştır (Şekil 4.5 ve Şekil B.1-B.6).

Kullanılan ensemble üyesi modellerin bireysel hataları özellikle Karadeniz Bölgesinde (Şekil B.1) Bartın, İnebolu, Kastamonu ve Samsun'da, Marmara Bölgesinde (Şekil B.2) ise Çanakkale ve Kumköy istasyonlarında hemen hemen aynı değerlerdedir. Bu durumda model fiziğinde yapılmış olan konveksiyon ve radyasyon şemalarındaki değişikliklerin, bu istasyonlar için model performanslarını çok fazla etkilemediği şeklinde bir kanıya varılmaktadır. Fakat birçok istasyonda modellerin

MAE değerleri değişkenlik göstermektedir, en yüksek ve en düşük hata değerlerine sahip olan model değişmektedir. Örneğin Doğu Anadolu Bölgesinde (Şekil B.3) çoğu istasyonda ANRG modeli en yüksek hata değerlerine sahipken Güneydoğu Anadolu'daki (GDA) istasyonlarda AORG modeli en yüksek MAE değerlerine sahiptir (Şekil B.4).

Kara-deniz-dağ etkileşiminin çok yüksek olduğu Karadeniz Bölgesinde karmaşık topografik yapının modellerde çok iyi tasvir edilememesinden kaynaklanabileceği düşünülen yüksek hata değerleri görülmektedir. GDA ve Akdeniz Bölgeleri'nde ise hem üye modeller hem de KTRL ensemble tahminleri en düşük MAE değerlerine sahiptir. Doğu Anadolu Bölgesi'nde model versiyonlarının doğrulukları diğer bölgelere göre daha fazla değişmektedir.

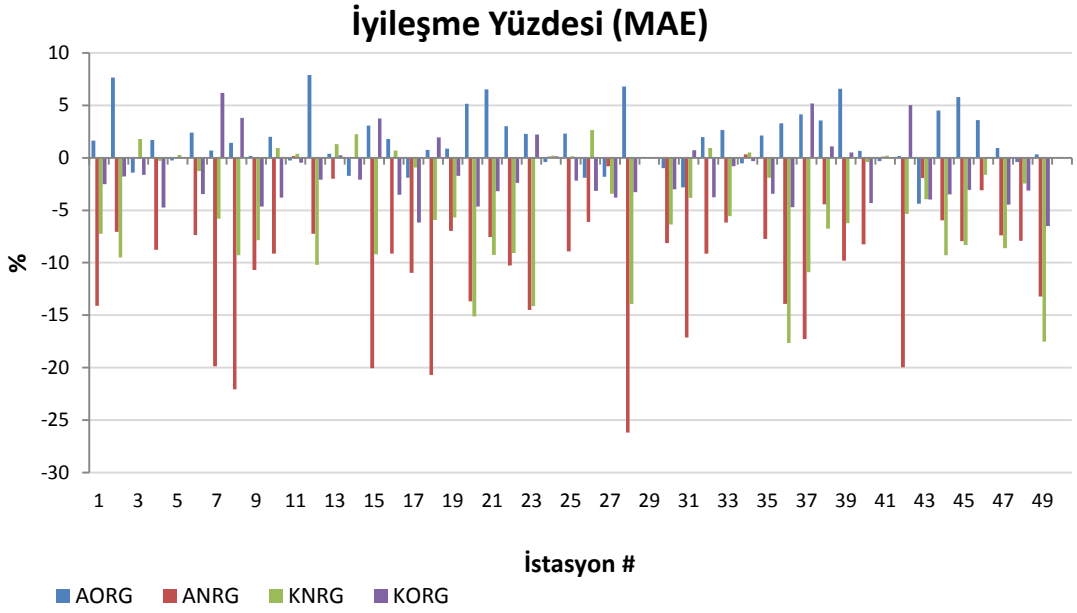
KTRL ensemble sistemi, en düşük MAE değerlerine sahip olduğu bazı istasyonlarda en doğru tahminleri verirken bazılarında bireysel model versiyonlarının daha doğru tahminler yaptığı görülmektedir. Bireysel üye modellerinden performansı KTRL ve diğer modellere göre daha iyi olan Erzurum, Kars, Ankara, Şebinkarahisar, Giresun Rize gibi istasyonlarda AORG versiyonunun üstünlüğü görülmektedir. İç Anadolu (Şekil B.6), Doğu Karadeniz ve Doğu Anadolu'da bulunan bu istasyonlar Rize ve Giresun sahil bölgeleri dışında rakımları yüksek olan istasyonlardır. Eski radyasyon şeması (emissivity/absorbtivity) kullanılan bu model versiyonunun tüm istasyonlarda aynı başarıyı sergilemediği açıktır.



Şekil 4.5: Akdeniz Bölgesi istasyonları için ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri.

Üye modellerin KTRL ensemble'a göre başarı analizi:

Her bir üye modelin, KTRL ensemble referans model alınarak tüm test tahminleri için MAE değerlerindeki iyileşme yüzdeleri (İY) Şekil 4.6'da görülmektedir. Buradan ANRG ve KNRG modellerinin birçok istasyonda KTRL sisteme göre MAE bakımından değerlendirildiğinde başarılarının düşük olduğu anlaşılmaktadır. Fakat bazı istasyonlarda bu modellerin pozitif değerleri de gözlenmektedir. AORG modelinin ise diğer modellerden daha fazla sayıda istasyon için KTRL ensemble sistemine göre MAE değerleri daha düşüktür yani doğruluğunun daha fazla olduğu söylenebilir.



Şekil 4.6: Ensemble üyesi modellerin KTRL sistemin ortalama mutlak hata (MAE) değerlerine göre iyileşme yüzdesi (İY).

İyileşme yüzdesi analizleri, doğruluk analizi ve üye modellerin ortalama-varyans değerlerinin versiyonlar arasındaki farklılığı, radyasyon ve kümülüs şemalarında yapılan değişikliklerle elde edilen bu üye modellerinin, performanslarında da farklılıklar olduğunu göstermektedir. Bu modellerin ensemble üyesi olarak kullanılmasıyla ortaya daha başarılı tahminler çıkarmaları beklenmektedir ve buradaki referans model olan KTRL ensemble tahminlerinin birçok istasyondaki performansında da bu sonuçlar gözlenmiştir. Karadeniz ve Marmara Bölgesi'ndeki toplam 6 istasyonda ise her bir üye model ve KTRL tahminlerinin hata değerleri birbirleriyle çok yakın ve diğer istasyonlara göre yüksek değerlerdedir. Bu

istasyonların yüksek hata değerlerinin diğer ensemble sistemleri ile giderilip giderilemeyeceği önemlidir.

4.3.2 Ensemble tahmin sistemlerinin (KTRL-YSA-SE) analizleri

Öncelikle tüm istasyonlar için kontrol ensemble sistemi (KTRL) ile adaptif YSA ve SE sistemlerinin 50 test tahmini gözlem değerlerine göre bazı istastistikleri verildikten sonra genel doğrulukları, KTRL sisteme göre başarıları, belirli eşik değerleri tahmin edebilmeleri bakımından değerlendirilmişlerdir.

Ortalama ve varyans istatistiklerine veya hata değerlendirmelerine bakmadan önce, gözlemlere karşılık ensemble sistemlerin nasıl bir profil sergilediğinin anlaşılması için, bölgelere göre her bir istasyonun gözlem ve ensemble sistemlerinden elde edilen sıcaklık anomalilerinin mevsimlik ortalamaları (Şekil C.1-C.7) ortaya konmuştur. Gözlem verilerine göre Akdeniz Bölgesinde sonbahar mevsimi dışında tüm istasyonlarda pozitif anomali değerleri mevsim ortalamalarında 1°C'den düşüktür. Sonbahar mevsiminde ise negatif ve 0.5°C'den küçük değerlerdedir. Adana istasyonunda kış mevsimi ortalama anomali değeri 0.7°C'lerde, Antalya'da ise ilkbahar mevsimi ortalama anomali değeri 1°C olarak gözlenmiştir. KTRL, YSA ve SE tahminlerine göre ise bu mevsimlik anomali değerleri özellikle ilkbahar mevsiminde gözlemlere göre oldukça düşük değerlerdedir. Gözlem anomalilerine en yakın değerler kış mevsimi ortalamalarında YSA ensemble sisteminin tahminlerine aittir.

Marmara Bölgesi'nde KTRL tahminleri tüm istasyonlarda gözlenen anomali değerlerinden daha düşük veya daha büyük anomali değerlerine sahiptir. Gözlenen anomali değerleri hemen hemen tüm istasyonlarda ve mevsimlerde 0°C'ye çok yakın değerlerde iken KTRL tahminleri ilkbahar ve yaz mevsimlerinde bazı istasyonlarda -1°C'ye varan değerlerde anomali ortalamalarına sahiptir. Sonbahar ve kış mevsimlerinde tam tersi pozitif anomali değerleri ile gözlemlerden oldukça ayrılmaktadır. KTRL tahminleri elde edilirken ortalamaları alınan dört ensemble üye modelinin analizleri yapıldığında, bölgesel olarak anomalilerin yaz mevsimi ortalamasının dört modelde de negatif olduğu ve sonbahar mevisimindeki yüksek varyasyon değerleri göze çarpmaktadır. Bu özelliklerin KTRL tahminlerini de etkilediği açıktır. YSA ve SE tahminleri KTRL tahminlerine göre gözlemlere daha yakın anomali değerleri göstermektedir. "YSA ve SE, modellerin sistematik

hatalarını öğrenerek bu tahminleri iyileştirmiştir midir?" Sorusu akla geldiğinden bu üç sistemin ayrıntılı olarak analizleri yapılmıştır.

Karadeniz Bölgesi'nde özellikle daha önce bahsedilen Bartın, İnebolu, Kastamonu ve Samsun istasyonlarında KTRL tahminlerinin gözlemlere göre oldukça yüksek sonbahar ve kış anomali değerleri, ilkbahar ve yaz mevsimlerinde ise ortalama anomali değerlerinin negatif ve gözlemlere göre farkın büyük olduğu Şekil C.3'den tespit edilmiştir.

Gözlemlere göre KTRL tahminlerinin en yakın değerler verdiği istasyonlar genelde GDA Bölgesindedir. Özellikle kış mevsimi anomali ortalamaları bu istasyonlarda hem işaret bakımından hem de değerler bakımından daha uyumlu görünmektedir. İç Anadolu Bölgesinde de negatif olan yaz ve sonbahar ortalaması anomalilerini KTRL ensemble'ları tüm istasyonlarda pozitif değerlerde tahmin etmiştir.

Genel olarak bakıldığında YSA ve SE tahminlerinin KTRL kadar gözlemlerden uzaklaşan mevsimsel anomali ortalaması değerleri vermediği tespit edilmiştir.

Ensemble tahmin sistemlerinin ortalama-varyans istatistikleri:

Çizelge 4.3'de gözlemlere bakıldığında tüm bölgelerde kış mevsimi varyansları diğer mevsimlere göre en yüksek değerlerdedir. Özellikle İç Anadolu ve Doğu Anadolu Bölgeleri'ndeki kış varyansları 11.4 ve 9.3'lük değerlerle oldukça yüksektir. Bu yüksek varyans değerlerine en yakın sonuçların çok yüksek farklarla da olsa KTRL tahmin sistemine ait olduğu görülmektedir. YSA ve SE tahminlerinin mevsimsel varyansları oldukça küçüktür.

İlkbahar ve yaz mevsimlerinde bölgesel ortalamalarda üç ensemble tahminini de negatif ortalama değerleri verdiği ve gözlem ortalamalarıyla benzeşmedikleri görülmektedir. YSA ve SE tahminlerinin düşük varyans değerleri sergilemesi genel performansları iyi olmasına rağmen incelenmesi ve iyileştirilmesi gereken bir nokta olarak göze çarpmaktadır.

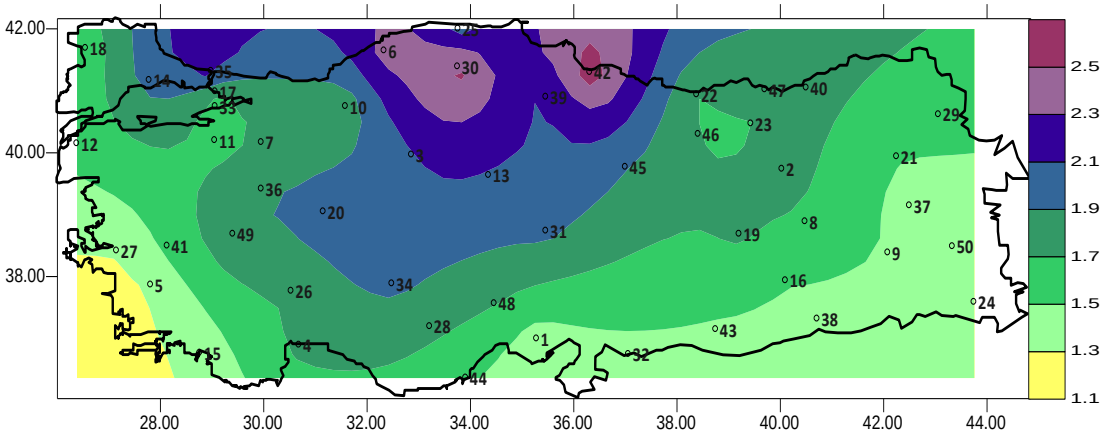
Çizelge 4.3: Gözlem ve ensemble tahminlerinin mevsimlik ve bölgesel olarak ortalama sıcaklık anomalisi ve varyans değerleri.

		İlkbahar		Yaz		Sonbahar		Kış	
Bölge	**Metod**	Ort.	Var.	Ort.	Var.	Ort.	Var.	Ort.	Var.
Akdeniz	**Gözlem**	**0.745**	**1.689**	**0.155**	**0.710**	**-0.422**	**3.862**	**0.417**	**6.343**
	KTRL	-0.043	0.699	-0.279	0.194	0.124	1.700	0.355	0.917
	YSA	-0.058	0.362	-0.114	0.143	-0.014	0.718	0.031	0.422
	SE	-0.011	0.271	-0.180	0.199	0.019	0.843	0.055	0.350
Marmara	**Gözlem**	**0.186**	**2.405**	**-0.040**	**1.007**	**-0.037**	**5.093**	**0.111**	**5.584**
	KTRL	-0.397	0.771	-0.579	0.306	0.469	2.350	1.005	1.173
	YSA	-0.192	0.448	-0.323	0.133	0.324	0.564	0.399	0.393
	SE	-0.133	0.431	-0.316	0.273	0.183	0.718	0.394	0.388
Karadeniz	**Gözlem**	**0.215**	**1.802**	**0.268**	**1.060**	**-0.382**	**4.716**	**0.385**	**6.071**
	KTRL	-0.752	0.978	-0.640	0.500	0.529	3.448	1.512	0.983
	YSA	-0.312	0.370	-0.170	0.208	0.201	0.369	0.434	0.281
	SE	-0.317	0.383	-0.128	0.423	0.179	0.540	0.484	0.296
Doğu A.	**Gözlem**	**0.039**	**4.538**	**0.078**	**0.794**	**0.096**	**3.185**	**0.026**	**9.285**
	KTRL	-0.016	1.939	-0.131	0.463	0.198	0.909	0.763	2.105
	YSA	-0.115	0.606	-0.004	0.145	0.036	0.235	0.237	0.547
	SE	-0.031	0.528	-0.077	0.101	0.085	0.207	0.278	0.431
GDA	**Gözlem**	**0.301**	**1.496**	**0.048**	**0.836**	**-0.111**	**3.663**	**0.673**	**8.018**
	KTRL	0.037	1.643	-0.210	0.490	0.119	0.718	0.561	1.749
	YSA	-0.018	0.674	-0.006	0.201	0.099	0.235	0.292	0.847
	SE	0.049	0.860	-0.058	0.118	0.110	0.260	0.259	0.622
Ege	**Gözlem**	**0.270**	**1.468**	**0.043**	**0.916**	**-0.226**	**5.646**	**0.005**	**6.827**
	KTRL	-0.046	0.714	-0.393	0.216	0.273	1.309	0.432	0.807
	YSA	-0.148	0.526	-0.332	0.314	0.138	0.663	0.242	0.405
	SE	-0.048	0.349	-0.405	0.353	0.149	0.998	0.188	0.365
İç A.	**Gözlem**	**0.562**	**1.606**	**0.458**	**0.757**	**-0.733**	**5.575**	**0.084**	**11.373**
	KTRL	0.132	1.536	-0.323	0.340	0.299	0.804	0.315	1.204
	YSA	-0.057	0.483	-0.091	0.190	0.006	0.424	0.002	0.447
	SE	-0.031	0.396	-0.072	0.192	0.030	0.429	-0.010	0.442

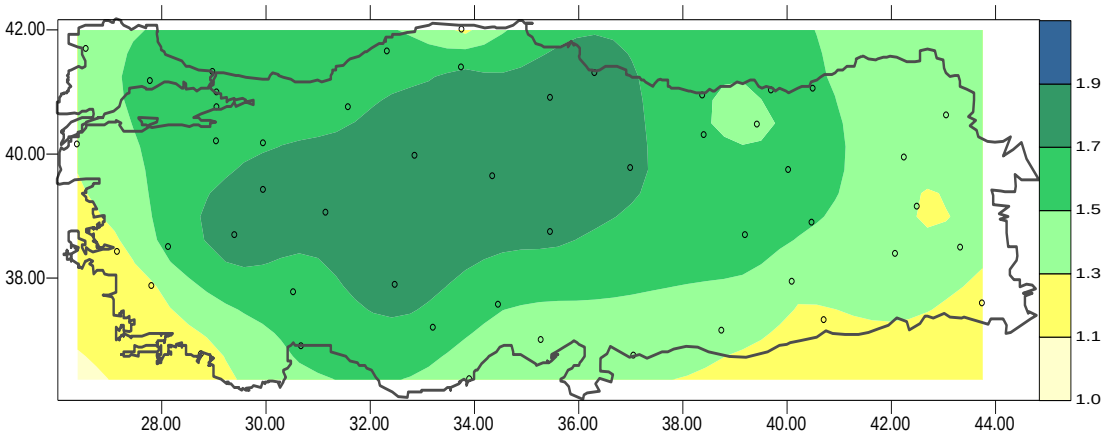
Ensemble tahmin sistemlerinin doğruluk analizi:

MAE: Şekil 4.7'de KTRL tahminlerine göre MAE değerlerinin özellikle iç kesimlerden kuzeye Karadeniz kıyılarına doğru arttığı gözlenmektedir. En düşük MAE değerlerinin Güneydoğu Anadolu (GDA), Akdeniz'in doğu kıyıları ve Ege kıyılarında yer aldığı, değerlerin İç Anadolu'dan Orta Karadeniz ve Karadeniz'in kuzey kıyılarına doğru arttığı görülmektedir. Şekil 4.8 ve 4.9'da sırasıyla YSA ve SE tahmin sistemlerinin MAE değerleri İç Anadolu Bölgesinde en yüksek değerlerde olmak üzere çevre bölgelere doğru azalmakta ve benzer bir dağılım göstermektedirler. Hata değerleri KTRL tahmin sisteminin hata değerlerine göre daha küçük aralıkta değişmektedir. Ensemble sistemlerinin doğruluğunun ayrıntılı şekilde ortaya konulabilmesi için hata değerleri çeşitli şekillerde grafiklerle incelenmiştir.

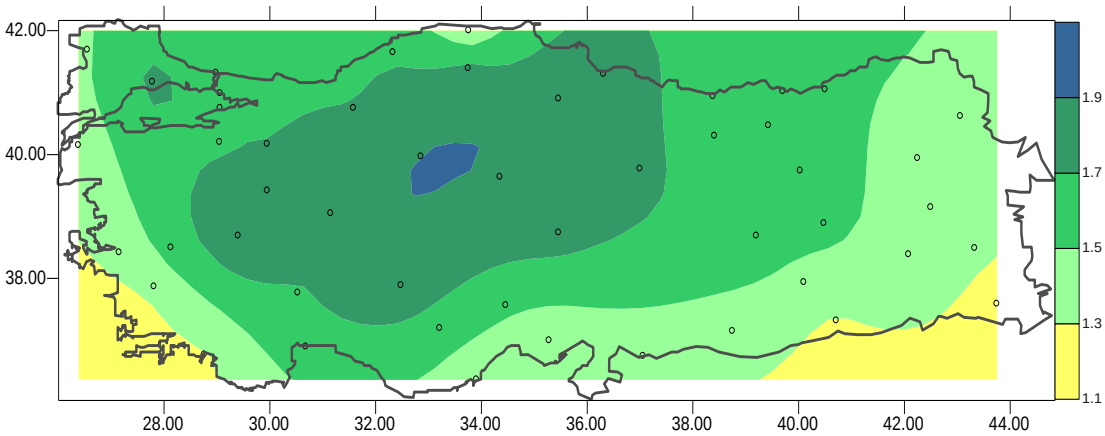
RMSE: MAE değerlerine göre büyük hatalara karşı daha hassas olan RMSE ölçüsünün ensemble sistemlerinin tahminlerinden elde edilen değerlerinin yersel dağılımı Şekil 4.10-4.12'de görülmektedir. Burada KTRL tahminleri için MAE dağılımlarına benzer şekilde İç Anadolu'dan Karadeniz Bölgesi'ne doğru hata değerlerinin arttığı görülmektedir. YSA ve SE tahminlerine ait RMSE değerlerinin ise KTRL'e göre özellikle Karadeniz Bölgesinde olmak üzere çoğu bölgede daha düşük olduğu görülmektedir.



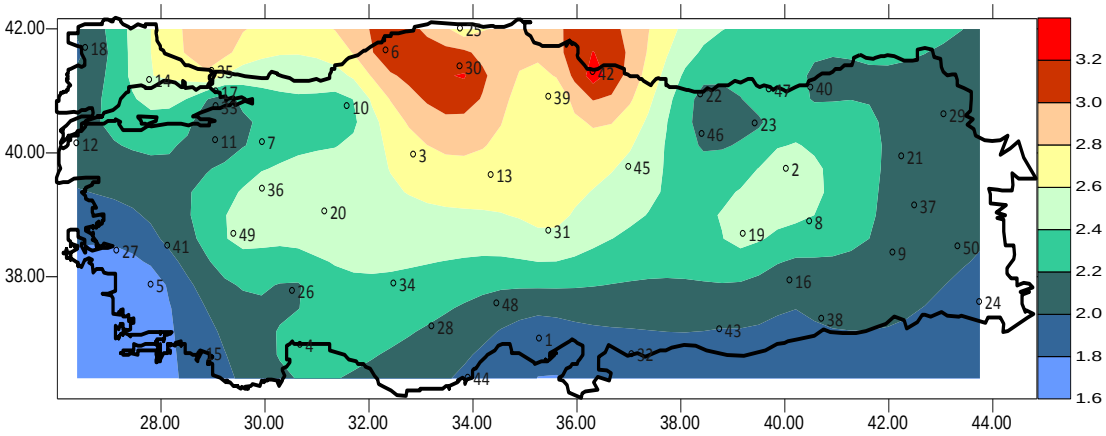
Şekil 4.7: Kontrol ensemble (KTRL) sistemine ait 50 test tahmini için MAE'lerin yersel dağılımları.



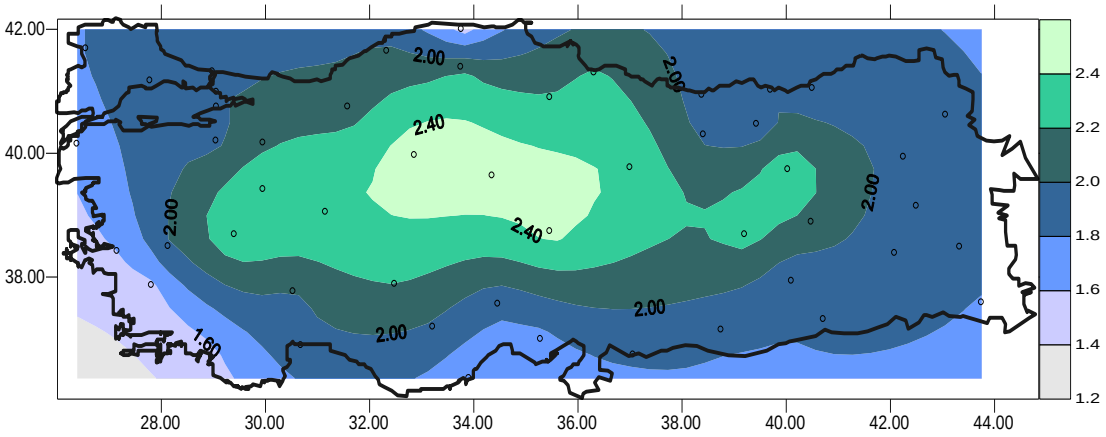
Şekil 4.8: YSA ensemble sistemine ait 50 test tahmini için MAE'lerin yersel dağılımları.



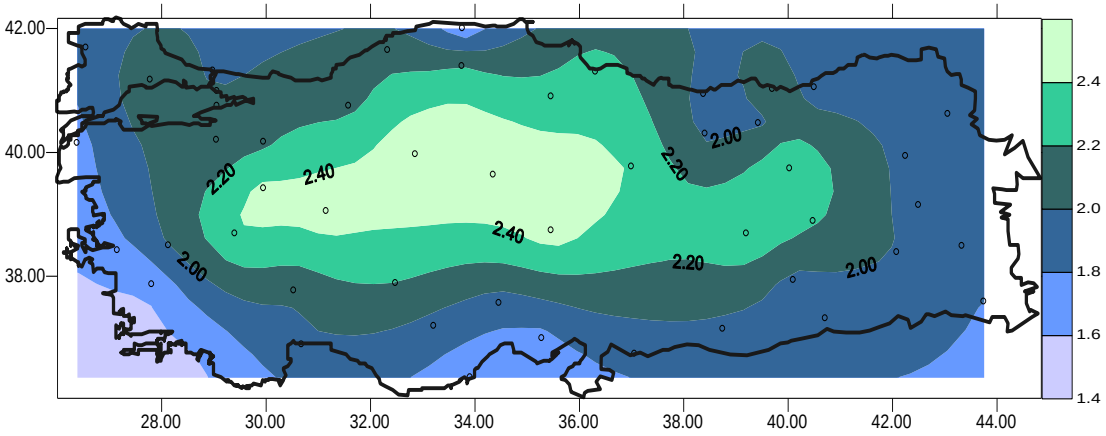
Şekil 4.9: Süperensemble sistemine ait 50 test tahmini için MAE'lerin yersel dağılımları.



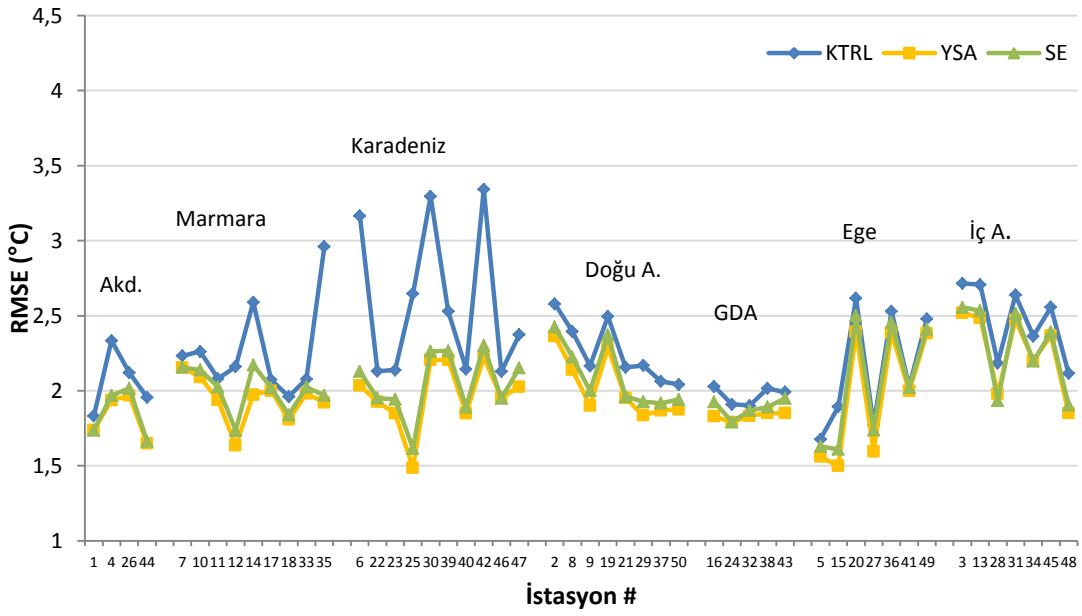
Şekil 4.10: KTRL sistemine ait RMSE dağılımları.



Şekil 4.11: YSA ensemble sistemine ait RMSE dağılımları.



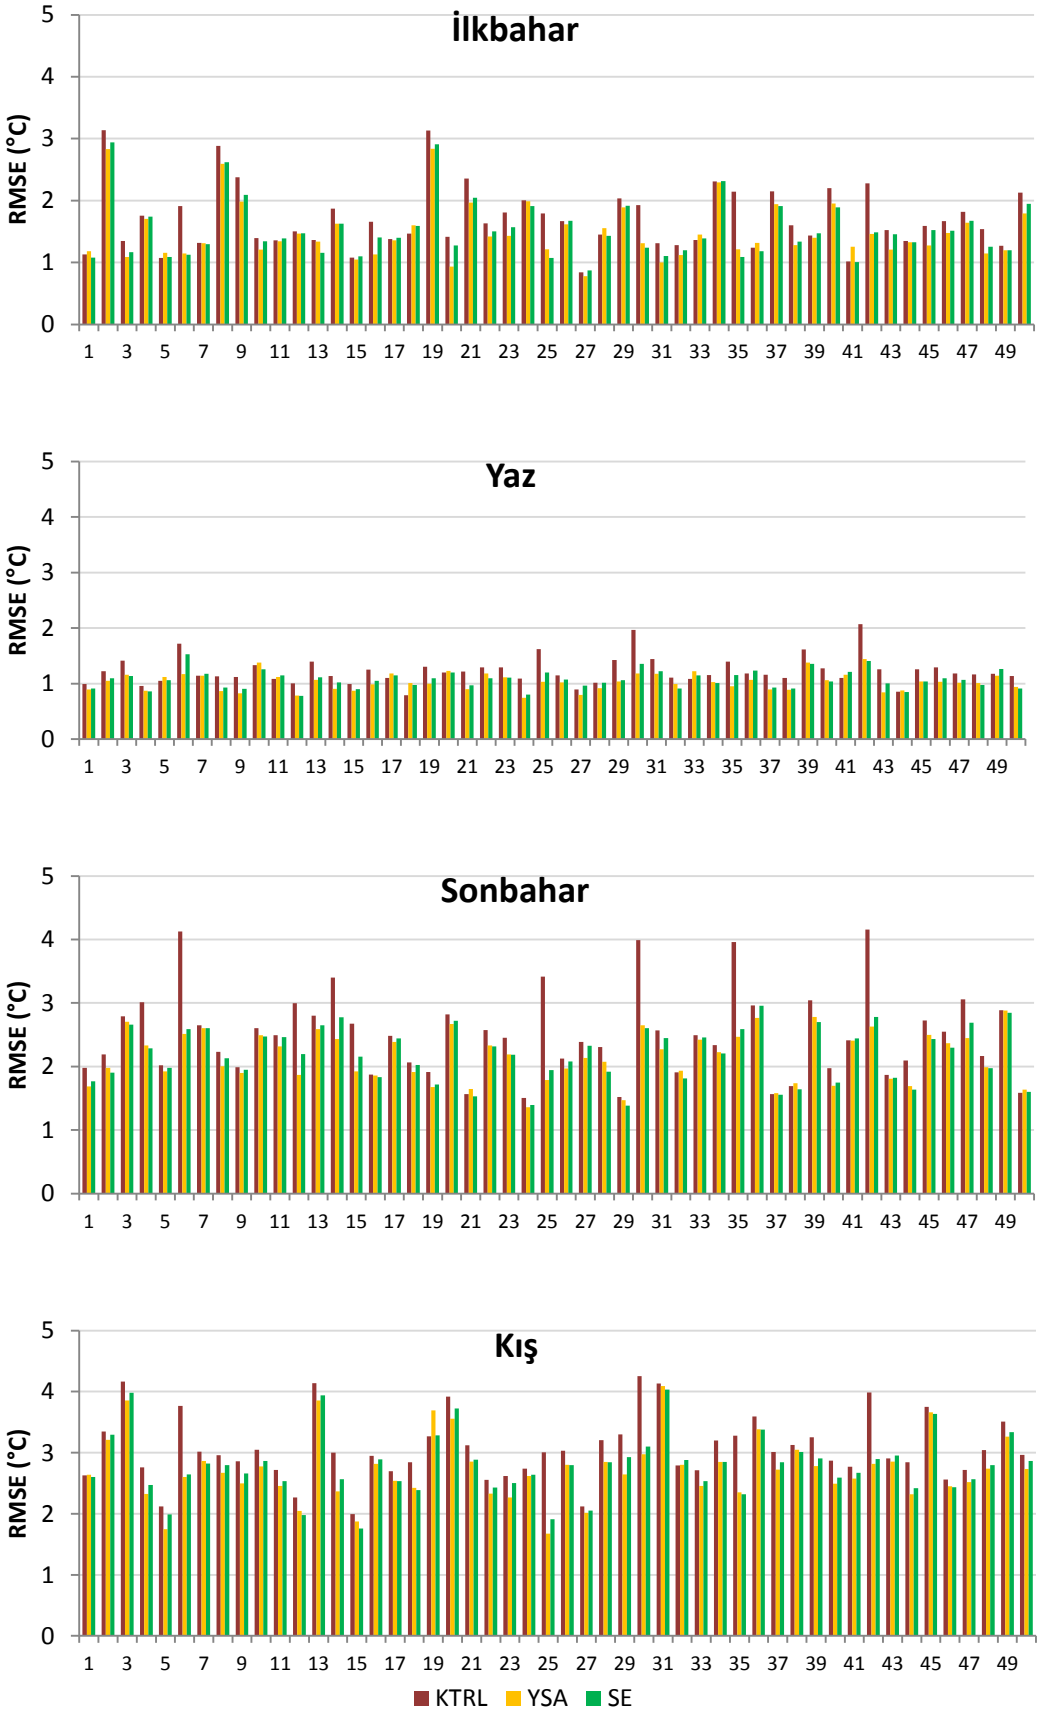
Şekil 4.12: Süperensemble (SE) sistemine ait RMSE dağılımları.



Şekil 4.13: Ensemble tahmin sistemlerinin bölgelere göre sıralanmış istasyonlar için RMSE değerleri.

Yersel dağılımları verilen 3 tahmin sisteminin RMSE değerleri bölgesel olarak sıralanmış istasyonlar için aynı grafik üzerinde (Şekil 4.13) gösterilmiştir. Buradan KTRL tahminlerin hata değerlerinin özellikle Karadeniz Bölgesi'nde olmak üzere tüm istasyonlarda YSA ve SE sistemlerine göre daha yüksek olduğu açıktır. Karadeniz ve Marmara'da daha önce bahsedilen (üye modellerle KTRL tahmin arasında MAE bakımından fark görülmeyen) 6 istasyonda (14, 35, 6, 25, 30, 42) YSA ve SE sistemleriyle KTRL arasındaki fark büyüktür. Ege bölgesindeki istasyonlarda ensemble sistemleri birbirlerine çok yakın hata değerlerine sahiptir. YSA ve SE tahmin sistemlerinin ise oldukça yakın değerlerde olduğu, yersel dağılımları gösteren haritalardan da görülmekteydi.

Şekil 4.14'de ensemble sistemlerinin test tahminlerine ait hata değerleri mevsimsel olarak ayrılarak incelenmiştir. Tüm ensemble sistemleri için en düşük RMSE değerleri yaz mevsiminde en yüksek değerler ise kış mevsiminde görülmektedir. Sonbahar ve ilkbahar geçiş mevsimlerinde ise 2 ve 19 numaralı istasyonlar (Ağrı, Elazığ) dışında sonbahardaki hata değerlerinin daha yüksek olduğu açıktır. KTRL tahminleri ile YSA ve SE tahminlerinin RMSE değerleri arasındaki farkın en yüksek olduğu mevsim de sonbahardır.



Şekil 4.14: Ensemble sistemlerinin mevsimlik RMSE (°C) değerleri.

Şekil 4.13'de de verildiği gibi genel hata değerlendirmesinde KTRL tahminin diğer istasyonlara göre yüksek hataya sahip olduğu Bartın, İnebolu, Kastamonu, Kumköy gibi istasyonlarda özellikle sonbahar ve kış mevsimi hata değerleri YSA ve SE sistemlerinin hata değerlerinden oldukça yüksektir. Burada KTRL tahminlerinin RMSE değerlerinin 4'e kadar yükseldiği istasyonlar olduğu görülmektedir.

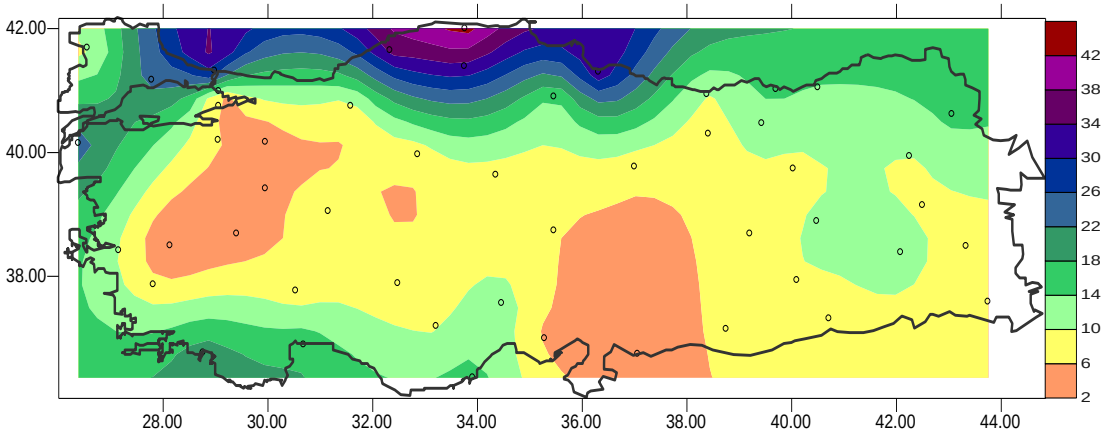
Ortalama Hata: Bu tahmin sistemlerinin sistematik hatalara sahip olup olmadıklarını irdelemek gerekirse mevsimsel olarak bölgesel ortalamaları alınmış ortalama hata (OH) değerleri Çizelge 4.4'de verilmiştir. İlkbahar mevsiminde tüm istasyonlar için YSA gözlenenden küçük tahminler vermiştir ve en yüksek OH değerleri bu mevsimde Karadeniz Bölgesindeki istasyonlarda KTRL tahminlerinde gözlenmiştir. KTRL tahminleri Karadeniz'de tüm mevsimlerde en yüksek bias'a sahiptir. Bu sonuçların ensemble üyesi modellerin bu bölgelerdeki yüksek hata değerleri ile bağlantılı olduğu açıktır. YSA ve SE metodlarının ise bu sistematik hataları KTRL ensemble sistemine göre daha iyi elimine ettiği ve tahminlerdeki OH'ların daha düşük olduğu açıktır.

Çizelge 4.4: Ensemble sistemlerinin mevsimlik ortalama hata değerlerinin bölgesel ortalamaları.

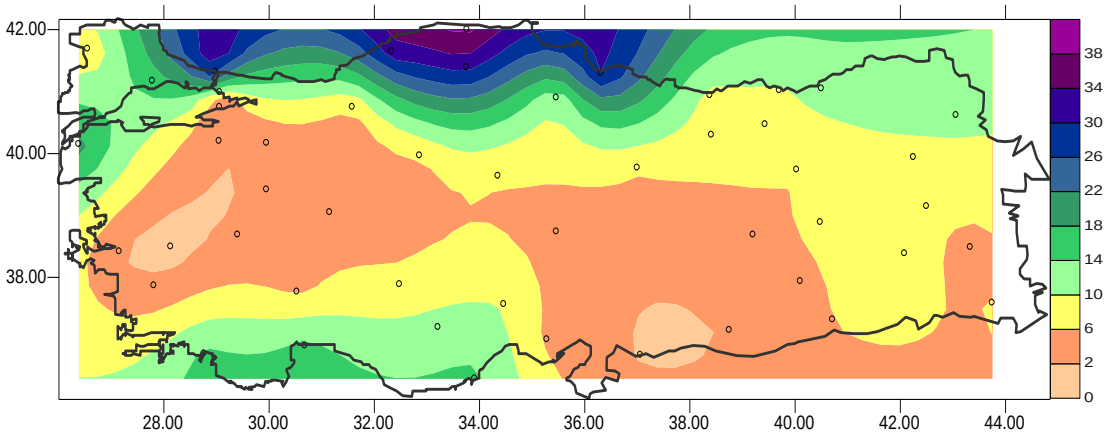
		İlkbahar	Yaz	Sonbahar	Kış
Akdeniz	KTRL	-0.789	-0.458	0.546	-0.062
	YSA	-0.803	-0.290	0.408	-0.386
	SE	-0.757	-0.357	0.441	-0.362
Marmara	KTRL	-0.583	-0.540	0.505	0.894
	YSA	-0.378	-0.283	0.360	0.288
	SE	-0.319	-0.276	0.219	0.282
Karadeniz	KTRL	-0.967	-0.909	0.910	1.127
	YSA	-0.528	-0.438	0.582	0.050
	SE	-0.533	-0.396	0.560	0.100
Doğu A.	KTRL	-0.055	-0.209	0.102	0.737
	YSA	-0.154	-0.082	-0.060	0.211
	SE	-0.070	-0.155	-0.011	0.252
GDA	KTRL	-0.264	-0.258	0.229	-0.112
	YSA	-0.319	-0.054	0.210	-0.381
	SE	-0.252	-0.106	0.220	-0.414
Ege	KTRL	-0.316	-0.437	0.498	0.427
	YSA	-0.418	-0.376	0.364	0.236
	SE	-0.318	-0.448	0.375	0.183
İç A.	KTRL	-0.429	-0.782	1.032	0.231
	YSA	-0.619	-0.550	0.739	-0.081
	SE	-0.593	-0.530	0.763	-0.093

Ensemble tahmin sistemlerinin başarı analizi:

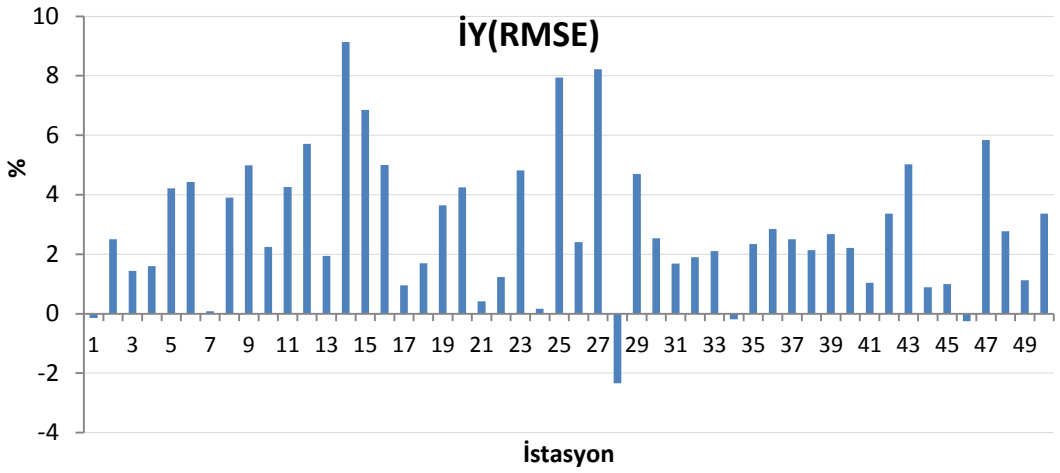
Adaptif YSA ensemble ve Süperensemble (SE) sistemlerinin KTRL tahminlerin RMSE hata değerlerinde yüzde olarak ne kadar iyileşme (İY) sağladıklarının yersel dağılımları sırasıyla Şekil 4.15 ve Şekil 4.16'da verilmiştir. Burada YSA ensemble sistemi ile en yüksek iyileşme değerleri maksimum %44 olmak üzere %20'dan büyük değerlerle orta Karadeniz'in kuzey sahillerinde ve Trakya bölgesinde gözlenmektedir. Aynı bölgelerde SE sistemi de Çanakkale istasyonu dışında %20'lerden yüksek İY değerlerine sahiptir ancak YSA sistemine göre değerler biraz daha düşüktür ve maksimum başarı Orta Karadeniz'in sahil kısımlarına doğru görülmektedir



Şekil 4.15: YSA tahminlerinin KTRL tahminlerine göre RMSE değerleri bakımından iyileşme yüzdelerinin (İY) yersel dağılımı.



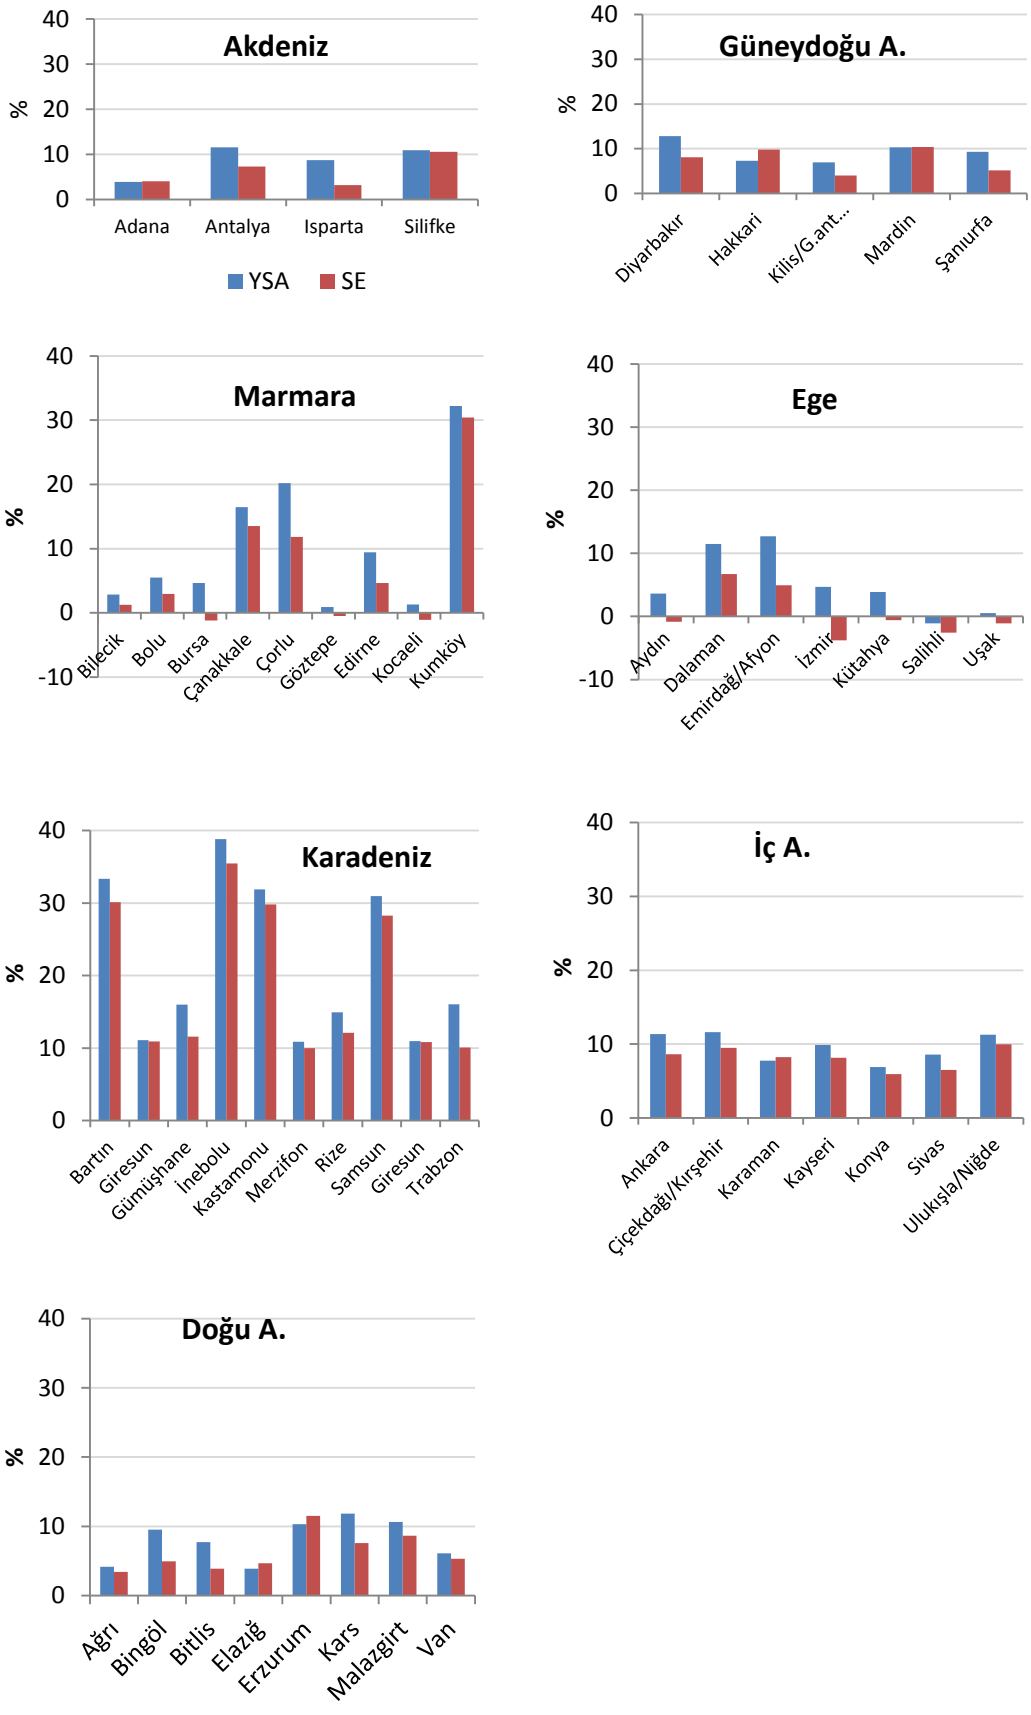
Şekil 4.16: Süperensemble tahminlerinin KTRL tahminlerine göre RMSE değerleri bakımından iyileşme yüzdelerinin (İY) yersel dağılımı.



Şekil 4.17: YSA ensemble sistemi tahminlerinin Süperensemble sistemi tahminlerine göre RMSE değerlerindeki iyileşme yüzdesi (İY).

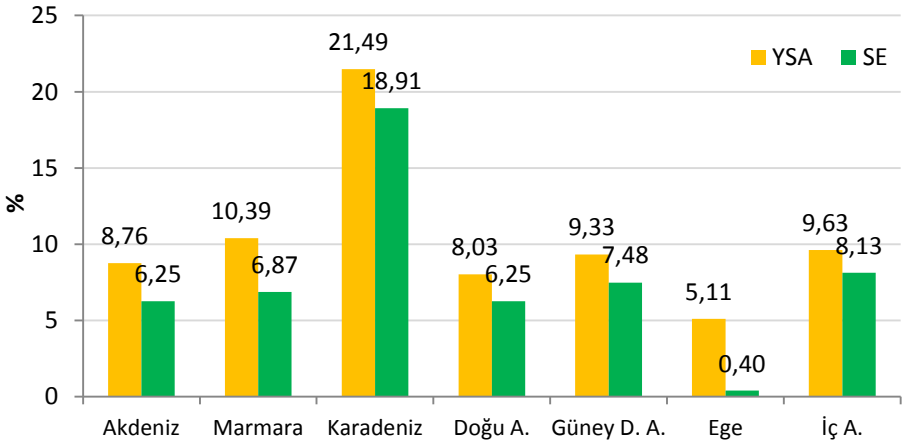
Şekil 4.17'de görülen grafikte tüm istasyonlar için YSA ensemble sisteminin SE sistemine göre RMSE değerlerindeki İY'leri verilmiştir. Sadece 4 istasyon dışında (Adana, Karaman, Konya, Şebinkarahisar/Giresun) SE hata değerlerine göre ortalama performansı daha iyi gözlenmiştir. Diğer tüm istasyonlarda maksimum %9'luk iyileşme sadece 1 istasyonda gözlenirken genelde %5'in altında değerler YSA'nın SE'ya göre tahmin başarısının çok az farklı olduğunu göstermektedir. En yüksek iyileşme değerleri görülen 3 istasyon, Çorlu/Tekirdağ, İnebolu/Kastamonu ve İzmir istasyonlarıdır.

Şekil 4.18'de istasyonlar bölgesel olarak ayrılarak YSA ve SE sistemlerinin MAE değerlerinin KTRL tahmin değerlerine göre ne kadar iyileştiği veya kötüleştiği İY değerleri ile daha ayrıntılı olarak verilmiştir. Görüldüğü gibi %30'ları aşan iyileşme değerleri Karadeniz Bölgesi'ndeki 4 istasyonda ve Akdeniz Bölgesi'ndeki 1 istasyonda tespit edilmiştir. Karadeniz'deki diğer istasyonlarda ise %10-15'lik iyileşme değerleri görülmektedir. YSA ensemble sisteminin Adana, Giresun, Mardin gibi istasyonlarda SE ile hemen hemen aynı başarıyı gösterdiği Karaman'da ise daha başarısız olduğu gözlenmiştir.

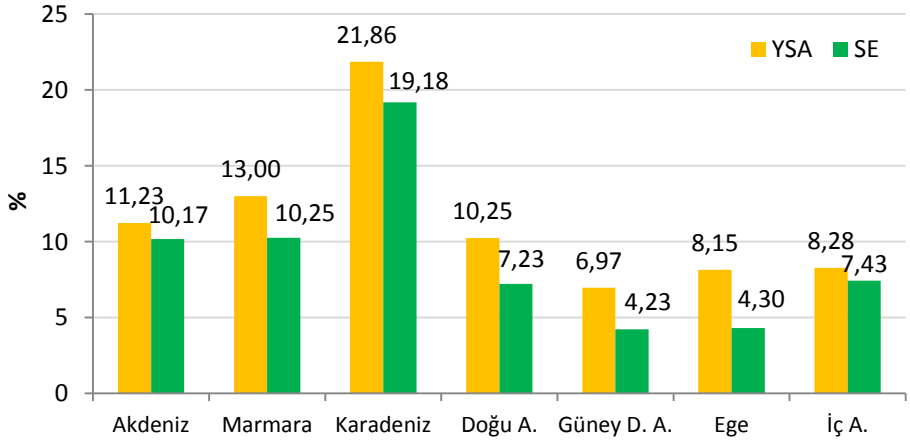


Şekil 4.18: Bölgelere ayrılmış her bir istasyon için YSA ve SE sistemlerinin KTRL tahminlerinin MAE değerlerine göre İY'leri.

SE ve YSA sistemlerinin yukarıda verilen MAE bakımından İY'si değerlerinin bölgesel ortalamaları alındığında Şekil 4.19'da görüldüğü gibi en yüksek değerler Karadeniz en düşük değerler ise Ege Bölgesinde gözlenmektedir. Karadeniz Bölgesi ortalaması alınırken çok yüksek hata değerli istasyonların bölge ortalaması değerine etkisi olduğu açıktır. YSA'nın SE'a göre başarısının en farklı olduğu bölgeler Ege ve Marmara bölgeleridir. RMSE bakımından İY değerlerinin bölgesel ortalamalarında (Şekil 4.20) Karadeniz Bölgesi değerleri İY(MAE) değerlerine göre değişim göstermemiştir. Güneydoğu Anadolu ve İç Anadolu Bölgesi dışında diğer bölgelerde ise MAE'lerdeki başarıya göre burada daha yüksek iyileşme değerleri mevcuttur.



Şekil 4.19: Bölgesel olarak YSA ve SE sistemlerinin KTRL tahminlerinin MAE değerlerine göre İY(MAE) değerleri.

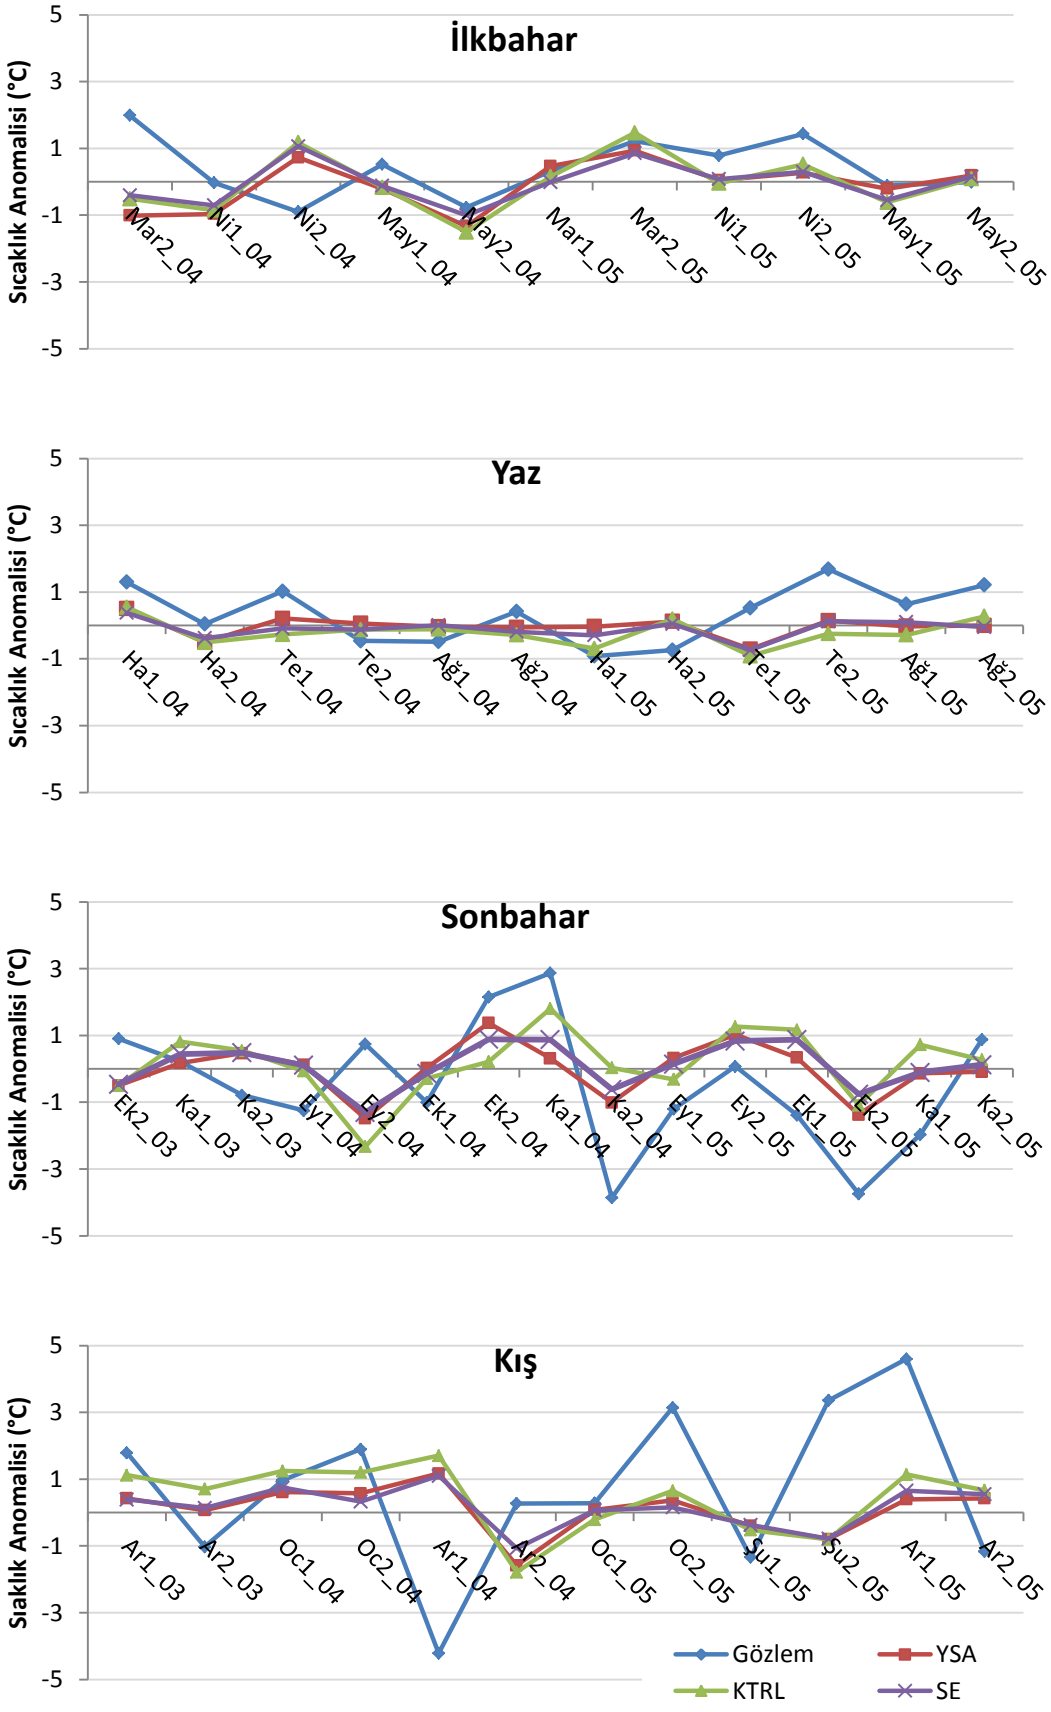


Şekil 4.20: Bölgesel olarak YSA ve SE sistemlerinin KTRL tahminlerinin RMSE değerlerine göre İY(RMSE) değerleri.

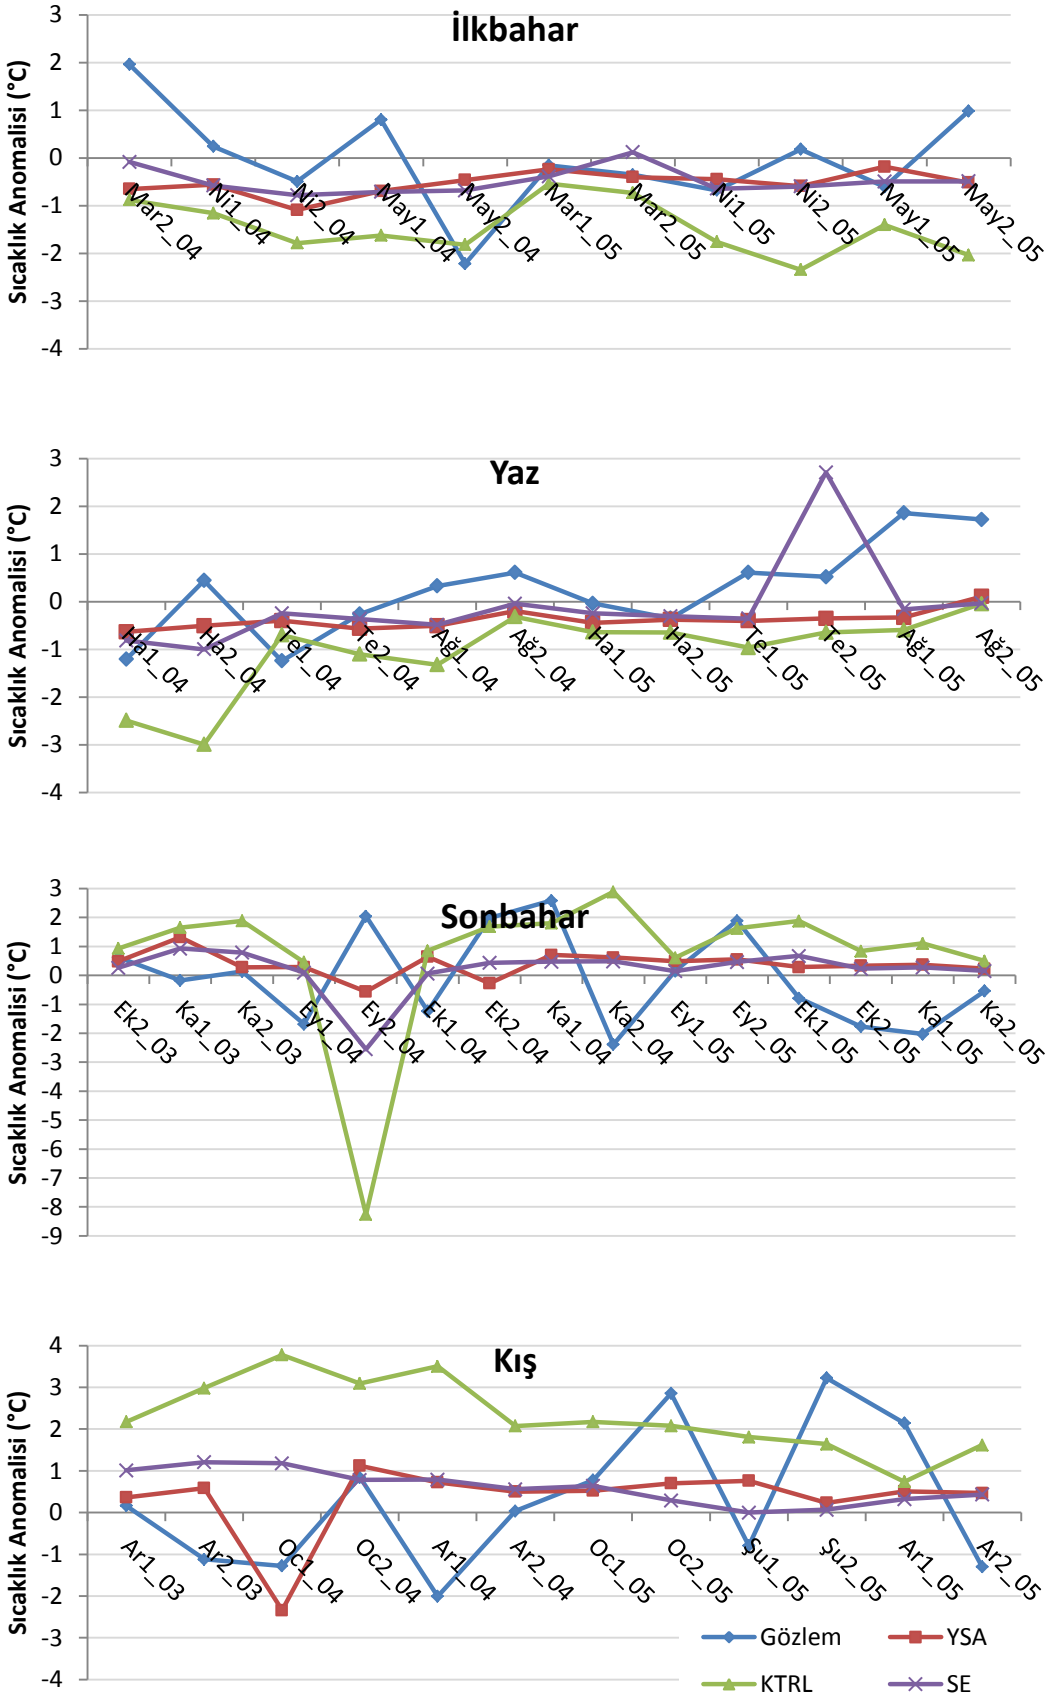
İki istasyon örneği için ensemble sistemlerinin anomali tahminleri ve mevsimlik hata değerlendirmesi

Şekil 4.21 ve 4.22'de sırasıyla Adana ve İnebolu istasyonları için mevsimsel olarak ayrılmış gözlem ve ensemble sistemi tahminlerinin (zamansal) dağılımları görülmektedir. Bu 2 istasyon seçilirken özellikle YSA ve SE tahminlerinin başarısı yüksek olan ve olmayan istasyonlar olmasına dikkat edilmiştir. Bu grafiklerin ortaya konmasındaki amaç yapılan tüm hata analizlerinin altında yatan bu tahminlerin gözlemlerle birlikte nasıl bir dağılım sergilediğini ortaya koymaktır. Buradan Şekil 4.21'deki Adana istasyonuna ait tahminlerin özellikle ilkbahar ve yaz mevsimlerinde gözlem değerlerine göre varyasyonlarının çok düşük olduğu ve birbirlerine yakın değerler tahmin ettikleri görülmektedir. Sonbahar ve kışın varyasyonları artmakla birlikte 3 ensemble sisteminin yine birbilerine yakın sonuçlar vermişlerdir.

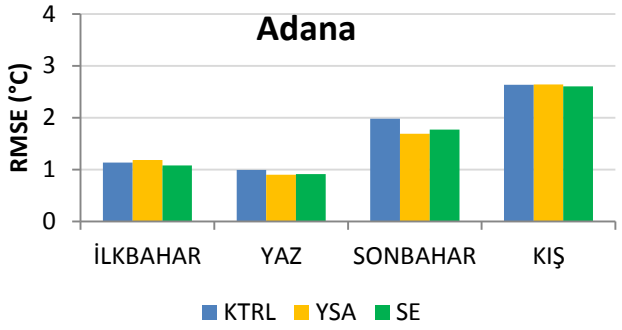
KTRL tahminlerine göre hata değerlerindeki iyileşme yüzdesinin yüksek olduğu istasyonlardan Karadeniz'in İnebolu istasyonunda KTRL tahmini, Adana'daki dağılımların aksine YSA ve SE tahminlerinden farklı dağılım sergilemektedir. Burada ilkbahar mevsiminde KTRL tahminleri negatif anomali değerleri verirken, kış mevsiminde de tam tersi tüm testler için pozitif değerler görünmektedir. Bu da İnebolu istasyonu için KTRL tahminlerinin bir bias'a sahip olduğunu göstermektedir. Ensemble tahmin sistemlerinin OH değerlerini gösteren Çizelge 4.4'de Karadeniz Bölgesi ortalamasında KTRL tahminlerinin bu yöndeki eğilimleri açık olarak görülmektedir. YSA ve SE tahminleri birbirlerine yakın tahminler vererek paralel bir dağılım sergilemektedirler.



Şekil 4.21: Adana istasyonu için gözlem ve ensemble tahminlerinin mevsimlere ayrılmış olan test örneği.

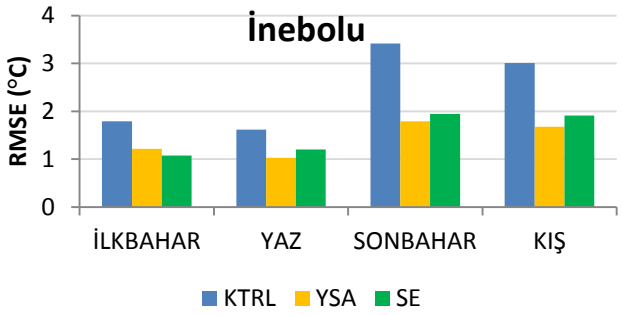


Şekil 4.22: İnebolu istasyonu için gözlem ve ensemble tahminlerinin mevsimlere ayrılmış olan test örneği.



Şekil 4.23: Adana istasyonu için ensemble tahminlerinin mevsimlere göre RMSE (°C) değerleri.

Şekil 4.23'de Adana istasyonu için ortalama mevsimsel RMSE değerleri görülmektedir. Burada her 3 ensemble metodunun tahminlerinde sonbahar ve kış hata değerleri daha yüksektir. Sonbahar mevsiminde KTRL ile diğer sistemlerin farkı kışa göre biraz daha fazladır ve YSA ile SE daha düşük mevsimlik ortalama değere sahiptir.



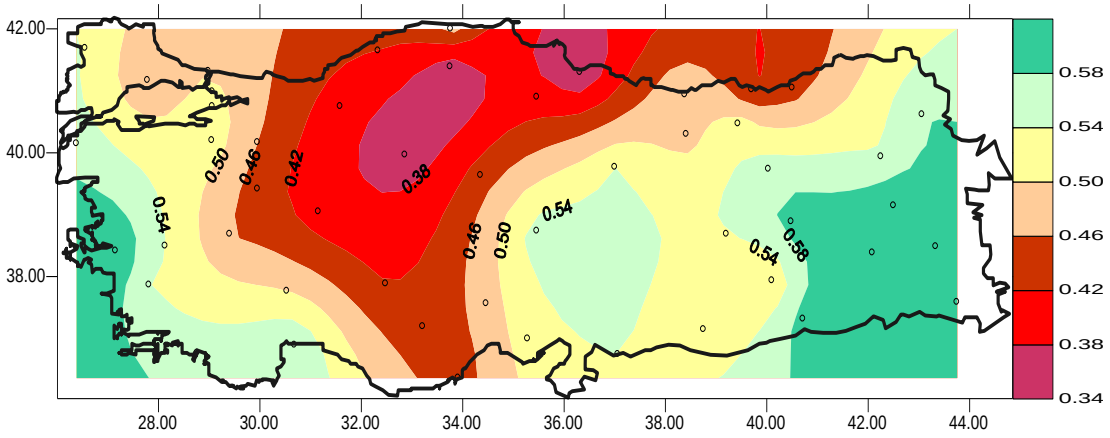
Şekil 4.24: İnebolu için ensemble tahminlerinin mevsimlere göre RMSE (°C) değerleri.

İnebolu/Kastamonu (25 numaralı) istasyonu için mevsimlik anomali tahminlerinden elde edilen hata değerlerinin, Adana istasyonundan farklı olarak tüm mevsim ortalamalarında YSA ve SE ile farkları daha büyüktür (Şekil 4.24). İlkbahar mevsimi dışında YSA'nın SE'den az farkla da olsa daha düşük mevsimsel RMSE değerleri gözlenmiştir.

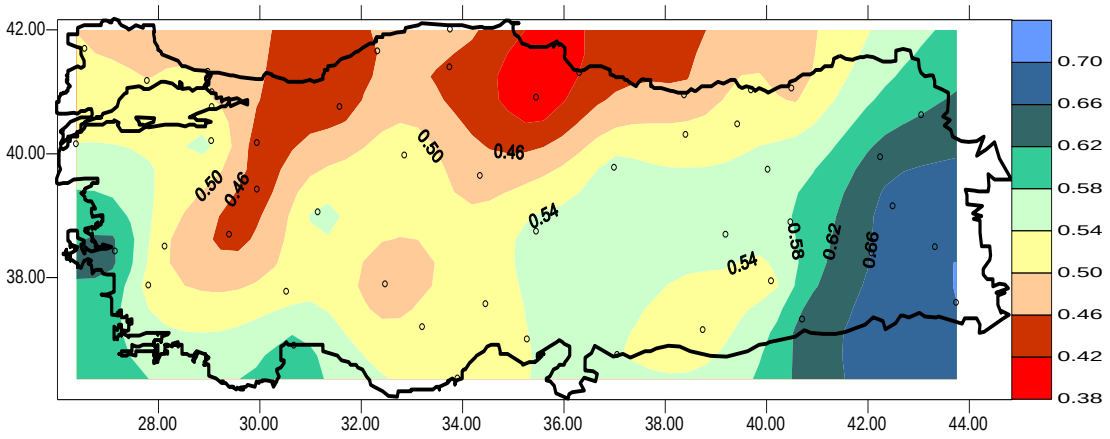
İşaret ve eşik değerleri uyum oranları:

Genel sıcaklık veya anomali değerlerine göre performans değerlendirmesinin yanında, anomalilerin pozitif veya negatif değerde mi olacağı yani ortalamadan yüksek mi düşük mü sıcaklıklar görüleceğinin başarılı tesbiti önemli bir değerlendirmedir. Bu nedenle KTRL, YSA ve SE tahmin sistemlerinin gözlenen anomali değerlerinin işaretlerine uygun tahminler verme yüzdeleri Çizelge 4.1'deki işaret eşleşme/uyum oranı tablosundan elde edilmiştir ve bu değerlerin yersel dağılımları sırasıyla Şekil 4.25- 4.27'de görülmektedir.

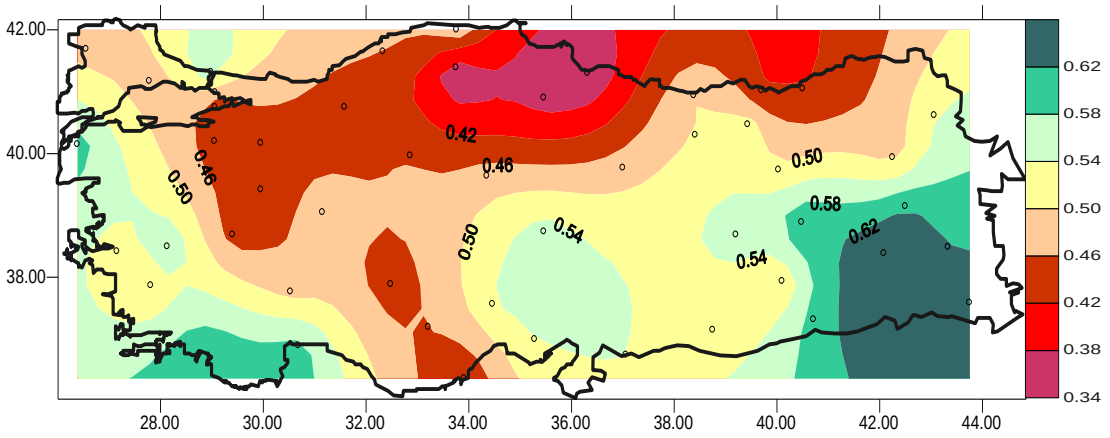
Şekil 4.25'de KTRL tahminlerininde %34 ile %58 arasında değişen İEO gözlenirken YSA ensemble tahminlerinde özellikle Doğu Anadaolu Bölgesinde %70'lere kadar çıkan değerler (Şekil 4.26) elde edilmiştir. Bu durum da YSA sisteminin anomali değerlerinin işaretlerini daha doğru tahmin edebildiğini göstermektedir. Batı sahillerinden içlere doğru Karadeniz ve Akdeniz'deki bazı istasyonları da içine alan bir bölgede KTRL tahminlerinin uyum değerleri düşmekte sonra tekrar doğuya doğru değerlerin artmaktadır. YSA ve SE sistemlerinin İEO dağılımları daha farklıdır fakat en yüksek değerleri yine Doğu Anadolu ve Güneydoğu Anadolu Bölgesinde görmek mümkündür. SE tahminlerinin maksimum İEO değerleri YSA değerlerine ulaşmamıştır, bu da YSA'nın bazı istasyonlarda daha başarılı olduğunun göstergesidir.



Şekil 4.25: KTRL ensemble test tahminlerinin gözlem verilerine göre işaret eşleşme oranı (%) dağılımları.



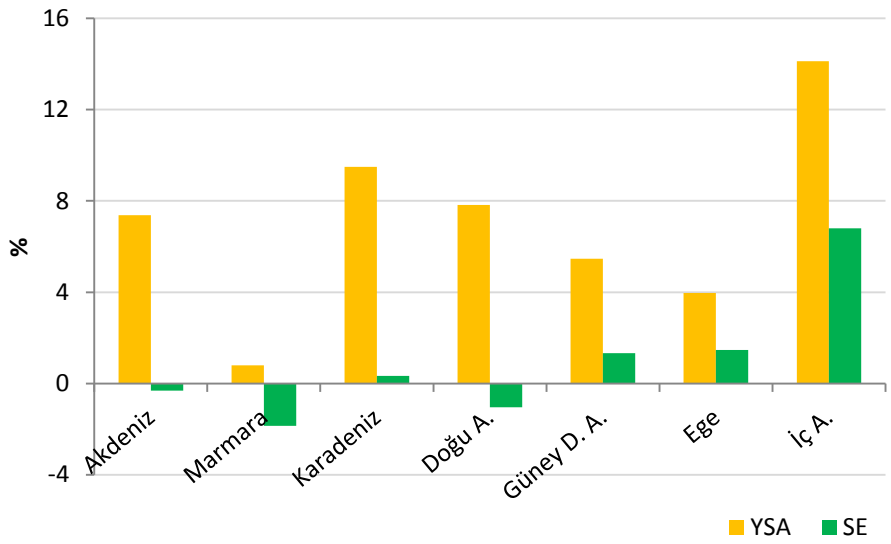
Şekil 4.26: YSA ensemble sisteminin test tahminlerinin gözlem verilerine göre işaret eşleşme oranı (%) dağılımları.



Şekil 4.27: Süperensemble metodunun test tahminlerinin gözlem verilerine göre işaret eşleşme oranı (%) dağılımları.

İşaret Eşleşme Oranı (İEO) bakımından KTRL ensemble tahminlerine göre başarı analizi:

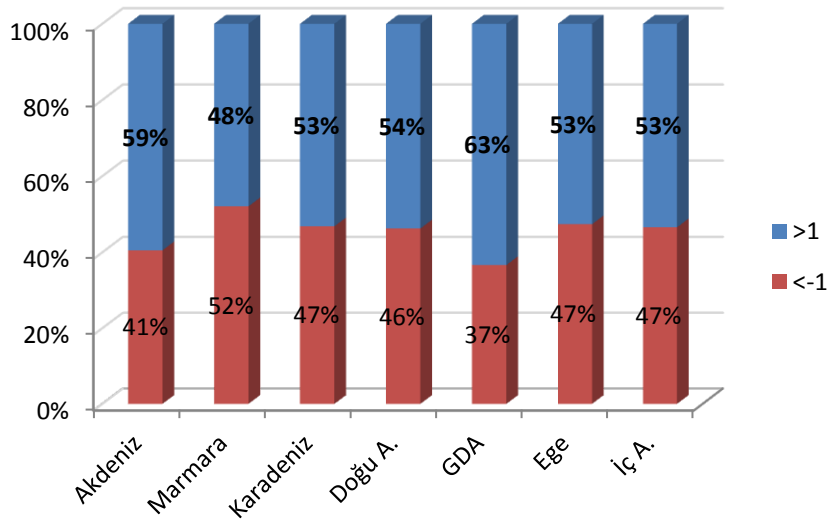
YSA ve SE sistemlerinin anomali işaretlerini doğru tahmin etmekteki perfomanslarının yersel dağılımdan sonra bölgesel olarak bu değerlerin ortalaması alınıp KTRL sisteme göre değerlerdeki iyileşme yüzdeleri hesaplanmıştır (Şekil 4.28). Burada YSA ensemble'ının KTRL sistemine göre tüm bölgeler ortalamasında değişen oranlarda özellikle İç Anadolu'da %14'lere varan değerlerde başarılı olduğu ve SE sistemine göre daha başarılı olduğu görülmektedir. SE sisteminin Marmara ve Doğu Anadolu Bölgelerinde KTRL tahmine göre başarısının az da olsa düştüğü negatif değerlerden anlaşılmaktadır. Bu da önemli bir kriter olan anomali değerinin ortalamadan yüksek mi alçak mı olacağının bilinmesinde YSA'nın SE'a göre çok daha üstün olduğunu göstermektedir.



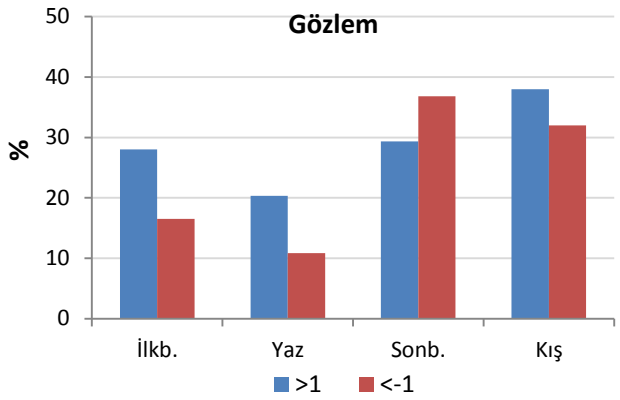
Şekil 4.28: Bölgeler ortalamasında ensemble tahminlerinin (YSA ve SE) gözlem değerlerine göre işaret eşleşme oranlarının (İEO) KTRL tahminlerinin İEO'larına göre iyileşme yüzdeleri.

Gözlem anomali değerleri (>1°C) ve (<-1°C) olan testler dikkate alındığında performans değerlendirmeleri:

Yukarıdaki bütün değerlendirmeler ortalama performans/doğruluk değerlendirmeleri için yapılmıştır. +1°C ve -1°C değerlerini eşik değerler olarak kabul ederek, gözlem verilerinde bu değerlerden büyük ve küçük anomali değerlerine sahip testler için ensemble sistemlerinin performansları değerlendirilmeye çalışılmıştır. Gözlem test verilerinin belirlenen eşik değerlerine sahip test sayılarına bakıldığında, istasyon başına 50 test verisi içinde, ortalama 24 ile 31 arasında değişen sayılar düşmektedir. Bölgesel olarak incelendiğinde bu eşik değerli testlerin en çok gözlendiği bölge İç Anadolu Bölgesidir. Bu bölgede Kayseri ve Konya istasyonlarında toplam 33 test verisinde belirlenen eşik değerli anomali değerleri gözlenmiştir. Ege ve GDA ise ortalama 24 test verisi ile bu eşik değerlerinin diğer bölgelere oranla daha az görüldüğü bölgelerdir. Bu eşik değerlerinden hangisinin sayıca daha fazla görüldüğü ise Şekil 4.29'da verilmiştir. Marmara Bölgesi dışında tüm bölgelerde az farkla da olsa anomali değerlerini 1°C'den büyük olduğu testlerin sayısı anomali değerlerinin -1°C'den küçük olduğu test sayılarına göre daha fazladır. Özellikle GDA Bölgesinde bu fark daha fazladır. Bölge genelindeki toplam 120 test verisinin %63'ünde anomali değerleri 1°C ve daha yüksek iken %37'sinde -1°C ve daha düşüktür.

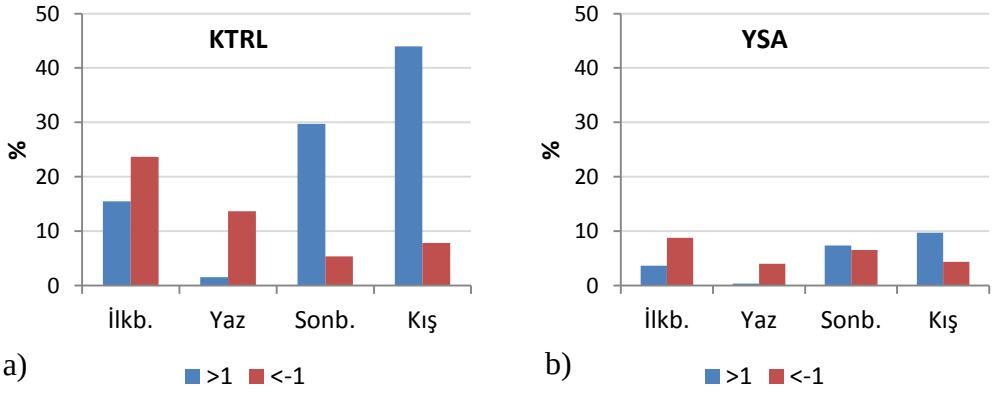


Şekil 4.29: Bölgelere göre gözlemlerde görülen (>1°C) ve (<-1°C) anomali değerlerinin görülme oranı.



Şekil 4.30: Tüm istasyonlar genelinde anomali değerleri (>1°C) ve (<-1°C) olan testlerin toplam mevsim değerleri içerisinde sayıca yüzdeleri.

Şekil 4.30'da tüm istasyonlar genelinde gözlem verilerinin mevsimlere göre 1°C'den büyük ve -1°C'den küçük anomali değerlerine sahip olduğu test sayıları yüzdeleri görülmektedir. Buradan sonbahar mevsimi dışında tüm mevsimlerde anomali değerlerinin 1°C'den büyük olduğu dönemlerin -1°C 'den küçük anomali değerli dönemlere göre daha fazla olduğu görülmektedir.

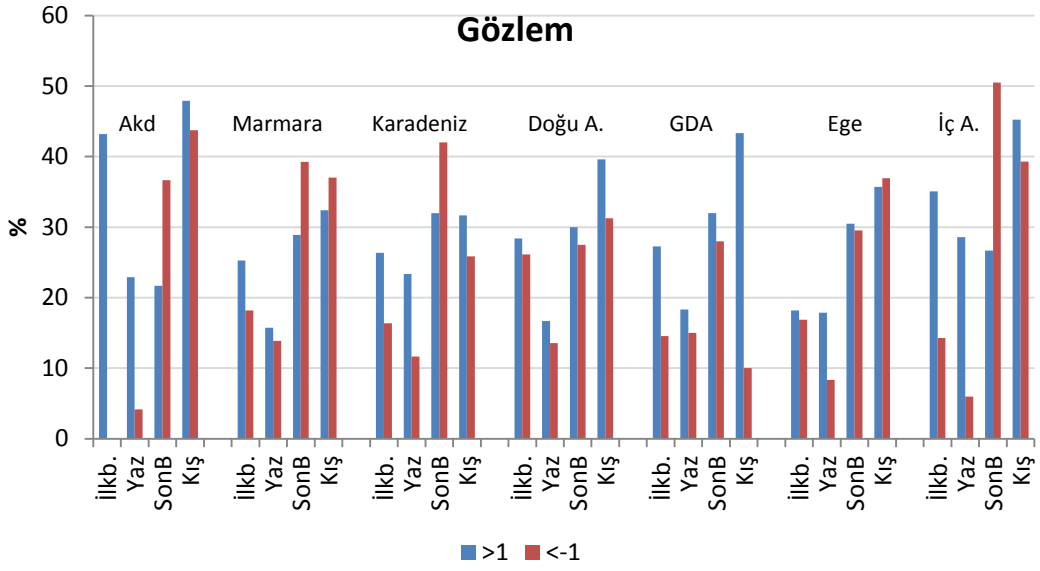


Şekil 4.31: Tüm istasyonlar genelinde anomali değerleri (>1°C) ve (<-1°C) olan; a) KTRL, b) YSA tahminlerinin mevsimler içindeki sayıca yüzdeleri.

Şekil 4.31'de ise KTRL ve YSA sistemlerinin tahminlerine göre bu eşik değerli test sayılarının yüzdesi gözlem verilerine göre oldukça düşük görünmektedir. KTRL tahminlerine göre kışın, testlerin %40'ını aşan sayıda 1°C'den büyük anomali değerleri gözlenirken bu sayı YSA için %10'lardan düşüktür. Gözlem verilerinde sonbahar mevsimi dışında 1°C'den büyük anomali değerleri test sayıları, -1°C'den küçük anomali değerli test sayılarına oranla daha yüksekken, yüzdeleri çok düşük de

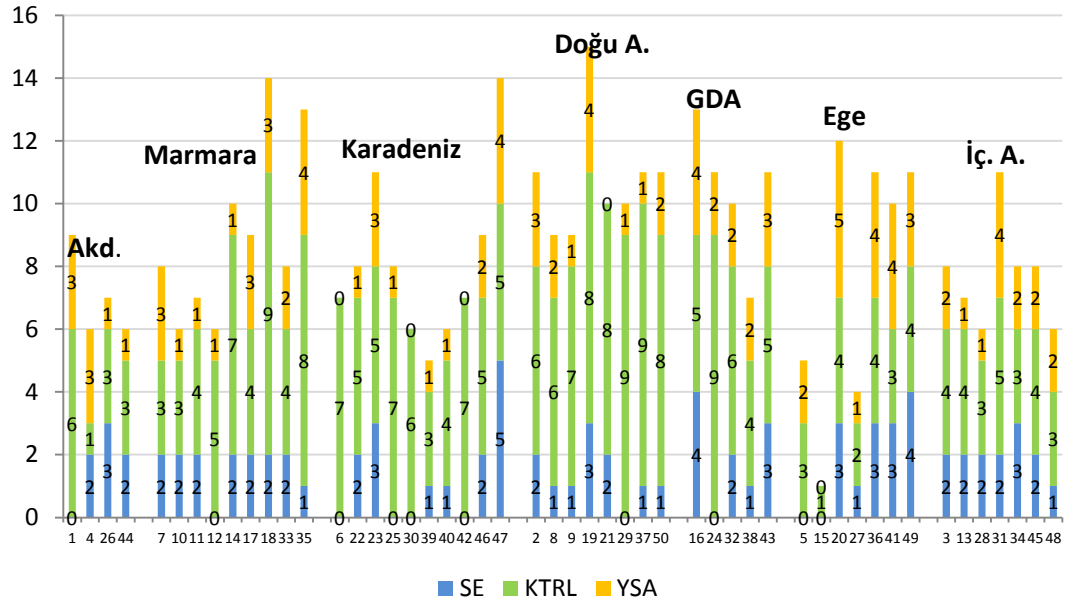
olsa KTRL ve YSA tahminlerinde ilkbahar ve yaz mevsimlerinde tam tersi olarak 1°C'den düşük anomali değerleri nispeten daha yüksek oranda gözlenmiştir.

Şekil 4.32'de ise bölgelere göre bu eşik değerlerine sahip test sayılarının mevsimler bazında oranları görülmektedir. Buradan Akdeniz bölgesinde ilkbahar mevsiminde sıcaklık anomalilerinin %40'lar oranında 1°C'den büyük olduğu, yaz mevsimi sıcaklıklarında da çok az sayıda sıcaklık düşüşü (anomali <-1°C) olduğu, sonbahar ve kış mevsimlerinde de sıcaklık artışlarının, azalışların görüldüğü dönemlere göre daha fazla sayıda olduğu gözlenmektedir. Marmara, Karadeniz ve İç Anadolu'da ise sonbahar mevsim sıcaklıklarında ise ortalamadan 1°C'lik ve daha fazla azalmalar görülen dönemlerin sayılarının daha fazla olduğu gözlenmektedir. GDA ise özellikle kış sıcaklıklarında olmak üzere tüm mevsimlerde pozitif anomali değerlerinin daha yüksek olduğu görülmektedir.



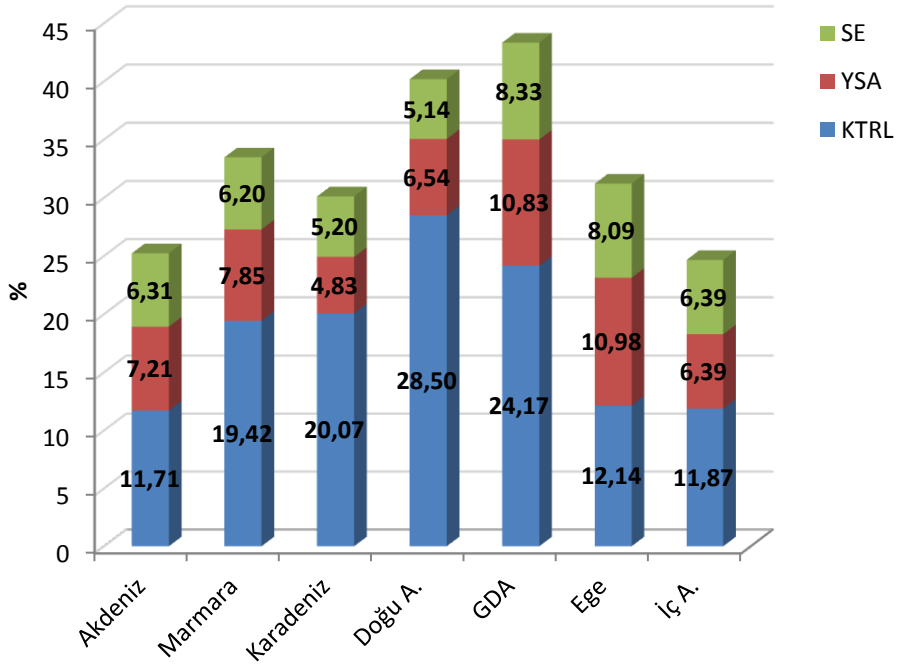
Şekil 4.32: Gözlem test verilerindeki (>1°C) ve (<-1°C) anomali değerlerinin mevsimlik değerler içindeki sayıca yüzdelerinin bölgesel değerleri.

Şekil 4.33'de bölgelere göre sıralanmış istasyonlar için gözlem anomalileri (>1°C) ve (<-1°C) olan dönemlerde ensemble tahminlerinin de aynı kriterlere uygun olduğu toplam gün sayıları görülmektedir. Buradan SE tahminlerinin hemen hemen tüm istasyonlar için bu eşik değerli tahminlerde en başarısız metod olduğu görülmektedir. KTRL tahminlerinin de YSA tahminlerine göre daha fazla sayıda testte bu eşik değerlerini başarıyla yakaladığı görülmektedir.

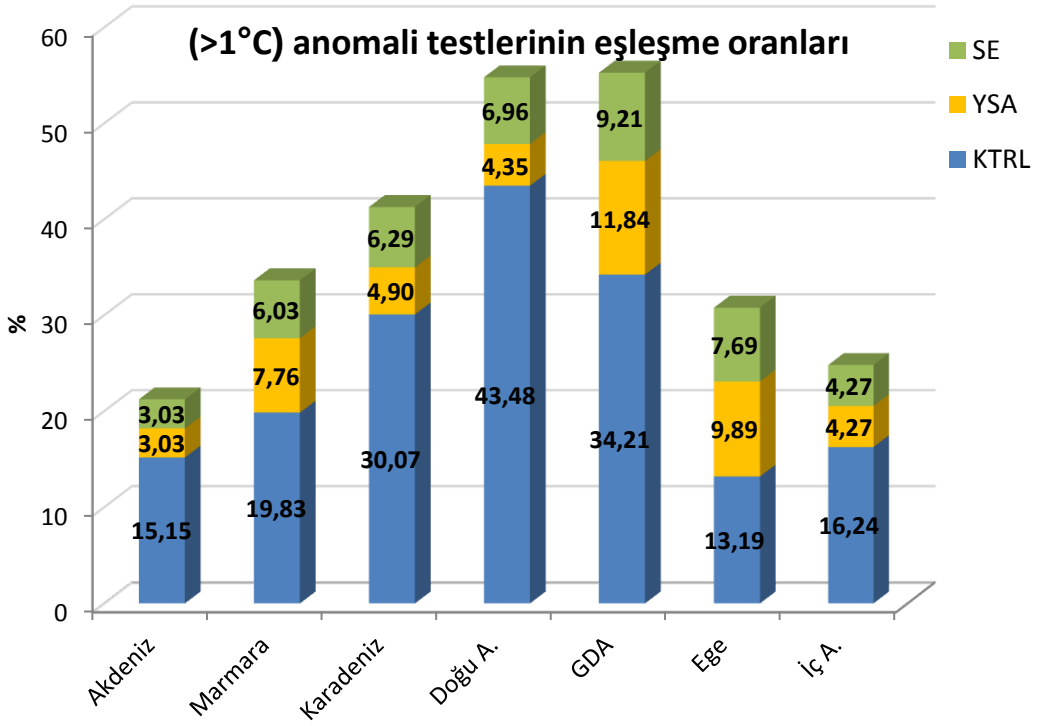


Şekil 4.33: Gözlem anomalileri (>1°C) ve (<-1°C) olan tarihlerde ensemble tahminlerinin bu kriterlere uyduğu toplam tahmin sayıları.

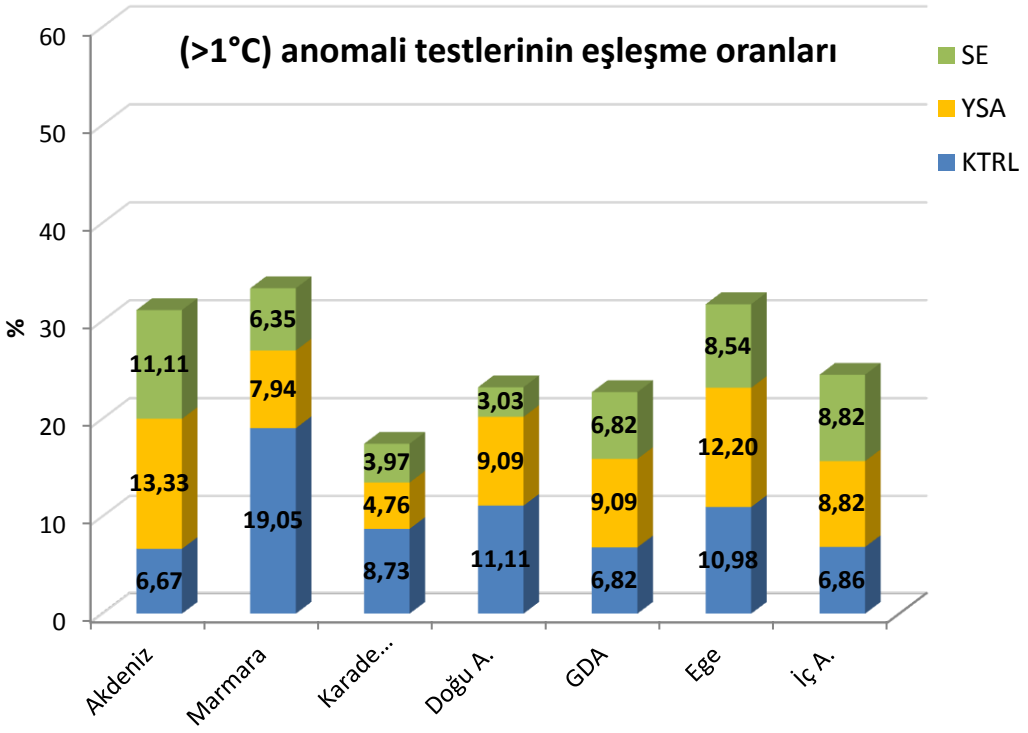
Şekil 4.34, 4.35 ve 4.36'da sırasıyla bu eşik değerlerinin herhangi birini, sadece (>1°C) ve sadece (<-1°C) eşik değerli gözlem verilerine karşılık, ensemble metodlarının da aynı tarihler için bu eşik değerlerle uyumlu tahmin verme sayılarının (başarılı tarihlerin) bölgelere göre yüzdeleri görülmektedir. Şekil 4.34'e göre her iki eşik değere de uyumlu tahminler en çok Doğu Anadolu Bölgesinde (%28) ve KTRL ensemble'larından elde edilmiştir. YSA ve SE metodlarının bu eşik değerlerinde başarılı ensemble tahminleri veremediği, YSA'nın SE'a göre Karadeniz bölgesi dışında biraz daha başarılı olduğu söylenebilir. Bu sonuçlar, yine bu ensemble sisteminin varyans değerlerinin küçük olmasıyla ilişkilidir. Şekil 4.35 ve 4.36'dan ise KTRL tahminin 1°C'den büyük olan anomalileri doğru tahmin etmekte daha başarılı olduğu açıktır. -1°C'den düşük anomalilerin tahmininde YSA ensemble metodu Akdeniz, GDA, Ege ve İç Anadolu'da KTRL'den az farkla da olsa daha başarılıdır.



Şekil 4.34: Ensemble sistemlerinin tüm testler genelinde (>1°C) ve (<-1°C) eşik değerli gözlem verilerini bölgesel olarak toplamda yakalama yüzdeleri.



Şekil 4.35: YSA, KTRL ve Süperensemble tahminlerinin, gözlemlerde görülen (>1°C) anomali değerli testler için bu değerlerle eşleşme yüzdeleri.



Şekil 4.36: YSA, KTRL ve Süperensemble tahminlerinin, gözlemlerde görülen (<-1°C) anomali değerli testler için bu değerlerle eşleşme yüzdeleri.

Çizelge 4.5-4.8 mevsimsel olarak ensemble tahmin sistemlerinin tüm istasyonlar genelinde gözlem verilerinde gözlenmiş eşik değerleri (>1°C ve <-1°C) için benzer anomali tahminleri yapma sayıları uyum tabloları şeklinde verilmiştir. KTRL tahminlerinin ilkbahar mevsiminde uyumlu tahminleri en fazla sayıda göstermesi yanında tam zıt işaretli değerler (örneğin gözlem <-1°C iken tahminin >1°C olduğu test durumları) tahmin etme sayıları da YSA ve SE tahminlerine göre fazladır. Bu da ortalama KTRL tahminlerinin başarısının düşmesine sebep olmaktadır. Özellikle sonbahar mevsiminde örneği verilen şekilde yapılan yanlış tahminlerin sayısı oldukça yüksektir. YSA ve SE tahminlerinde de bu şekilde hatalı tahmin sayısı özellikle sonbahar mevsiminde fazladır. YSA tahminlerinin uyumluluk sayısı SE tahminlerine göre az farkla da olsa daha yüksektir. Yaz mevsimine ait tahminlerde üç ensemble metodunun da uyumluluk sayısı yok denecek kadar azdır.

Çizelge 4.5: Tüm istasyonlar genelinde İlkbahar mevsiminde (>1°C) ve (<-1°C) anomali test değerleri için ensemble sistemlerinin uyum sayıları.

		GÖZLEM	
		>1°C	<-1°C
KTRL	>1°C	**26**	28
	<-1°C	15	**38**
YSA	>1°C	**12**	6
	<-1°C	2	**24**
SE	>1°C	**10**	12
	<-1°C	0	**21**

Çizelge 4.6: Yaz mevsiminde (>1°C) ve (<-1°C) anomali gözlemleri için ensemble sistemlerinin uyum sayıları.

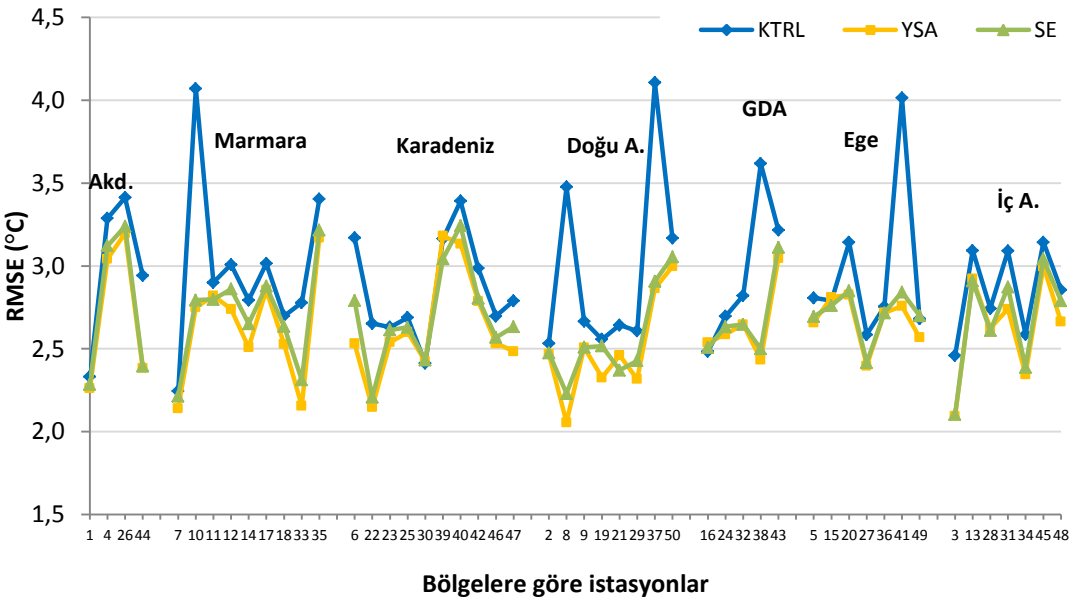
		GÖZLEM	
		>1°C	<-1°C
KTRL	>1°C	**0**	1
	<-1°C	16	**5**
YSA	>1°C	**0**	0
	<-1°C	5	**1**
SE	>1°C	**0**	0
	<-1°C	7	**1**

Çizelge 4.7: Sonbahar mevsiminde (>1°C) ve (<-1°C) anomali gözlemleri için ensemble sistemlerinin uyum sayıları.

		GÖZLEM	
		>1°C	<-1°C
KTRL	>1°C	**70**	67
	<-1°C	33	**4**
YSA	>1°C	**17**	11
	<-1°C	30	**16**
SE	>1°C	**21**	4
	<-1°C	40	**8**

Çizelge 4.8: Kış mevsiminde (>1°C) ve (<-1°C) anomali gözlemleri için ensemble sistemlerinin uyum sayıları.

		GÖZLEM	
		>1°C	<-1°C
KTRL	>1°C	**87**	10
	<-1°C	9	**21**
YSA	>1°C	**17**	32
	<-1°C	7	**13**
SE	>1°C	**14**	45
	<-1°C	8	**10**



Şekil 4.37: Gözlem anomalileri (>1°C) ve (<-1°C) olan testler dikkate alındığında ensemble tahminlerinin RMSE (°C) değerleri.

Her istasyon için bu eşik değerlerine sahip günler dikkate alındığında ensemble sistemlerinin sahip olduğu RMSE değerler Şekil 4.37'de görüldüğü gibidir. Burada yine KTRL tahminlerinin en yüksek RMSE değerlerine sahip olduğu, SE ve YSA ensemble sistemlerinin ise çoğu istasyonda birbirine çok yakın hata değerlerine sahip olduğu görülmektedir.

5. SONUÇ VE ÖNERİLER

Doğru ve güvenilir hava tahmini bilgisine ulaşmak birçok sektör için hayati önem taşıdığından yapılacak tahminlerin başarısını arttırmak, bu yönde metotlar geliştirmek günümüzdeki önemli araştırma konularındandır. Sayısal öngörü modelleri bünyesinde çeşitli denklemler, kabuller ve parametrizasyonlar kullanarak atmosferdeki süreçleri simüle etmeye çalışan, kısa, orta ve uzun vadeli tahminler için günümüzde birçok hava tahmin merkezi bünyesinde kullanılan atmosfer modelleri hava tahminindeki başarının her geçen gün artmasını sağlamaktadır. Modellerdeki yaklaşımlar ve süreçlerin tasvirindeki iyileşmelere rağmen bu modellerden elde edilen tahminler hala hatalar içermektedir.

Bu nedenle, atmosferin kaotik bir yapıya sahip olduğu ve çeşitli lineer olmayan ilişkiler içerdiğinin, başlangıç koşullarındaki küçük bir farklılığın model sonuçlarında yaratacağı farklılığın ortaya konması hava tahminine yeni bir yaklaşım getiren ensemble metodunun geliştirilmesine sebep olmuştur.

Bu çalışmada, Türkiye genelinde 50 istasyona ait 2 haftalık sıcaklık ortalaması tahminleri FSUGSM'in 4 farklı versiyonunun çalıştırılması sonucu elde edilmiştir. Bu model versiyonları konveksiyon ve radyasyon şemaları bakımından farklılık göstermektedir. Sıcaklık tahminleri anomalilere dönüştürülmüş ve modellerin girdi verisi olarak kullanılmıştır.

Böylece bu tez çalışmasının amacı Türkiye genelinde kullanılabilecek ve sıcaklık anomalilerini başarılı şekilde tahmin edebilecek bir ensemble tahmin sistemi ortaya koymaktır. Bu sebeple bias düzeltmesi yapılmış model ortalamaları kontrol tahmin (KTRL) olarak seçilmiştir ve geliştirilecek ensemble metodu performanslarının bu kontrol tahmini ile çeşitli açılardan kıyaslanması yapılmıştır. Ayrıca günümüzde yaygın şekilde uygulanan Süperensemble (SE) yaklaşımı da adaptif olarak uygulanmış, Yapay Sinir Ağları (YSA) metoduna dayanan ensemble sistemi ile değerlendirilmiş ve kıyaslanmıştır.

Adaptif olarak eğitilen YSA modelinde ağırlıkların yeni veri ile güncellenmesinin mantıksal olarak başarıyı arttırması beklenmektedir. Küresel iklim değişikliğine bağlı olarak ortalama sıcaklıkların veya diğer değişkenlerdeki ortalama değerlerin artış göstermesi bu yaklaşımın kullanılmasını avantajlı hale getirmektedir. Ancak bu çalışmada kullanılan kısıtlı veri ve eğitim verisi olarak ayrılmış verilerin güncellenirken ortalamada bir değişikliğe yol açmaması, anomali değerlerinin de çok değişmemesine yol açmıştır. Bu nedenle adaptif olmayan KTRL ve SE tahminlerinde performansların adaptif sistemlerle çok fazla farklılık göstermediği tespit edilmiştir.

Genel başarının ortaya konması amacıyla 50 test verisi dikkate alındığında YSA ve SE metotlarına dayanan ensemble tahminlerinin KTRL tahminlerine göre tüm istasyonlarda değişen oranlarda MAE, RMSE (örneğin en yüksek %44) veya İEO değerleri bakımından iyileşme gözlenmiştir. Bu da YSA sisteminin başarısını ortaya koymaktadır. İstasyonların %36'sında RMSE bakımından KTRL tahminlerine oranla %10 ve üzeri iyileşme söz konusudur. Bölgeler ortalamasına bakılıdığında da YSA tüm bölgelerde SE'dan daha başarılı bulunmuş, özellikle Karadeniz ve Marmara Bölgelerinde en yüksek iyileşme oranları elde edilmiştir.

Mevsimsel olarak performanslar dikkate alındığında, her bir üye modelin performansları değişiklik gösterdiği gibi ensemble metodlarında da farklı sonuçlar elde edilmiştir. KTRL tahminlerinin doğruluk değerlendirmeleri sonucu özellikle Karadeniz'de sonbahar ve kış mevsimlerinde yüksek hatalara sahip olduğu YSA ve SE tahminlerinin de bu yüksek hata değerleriyle paralellik göstererek yaz ve ilkbahar mevsimlerinde daha düşük hatalara sahip olduğu saptanmıştır. KTRL tahminlerinin özellikle sonbahar mevsiminde Karadeniz ve Marmara'daki bazı istasyonlarda olmak üzere hata değerlerinin YSA ve SE tahminlerine göre oldukça yüksek olduğu gözlenmiştir.

YSA ve SE tahminlerinin birçok istasyondaki varyasyon değerlerinin düşük olması, belirlenmiş eşik değerinin gözlemlerde tespit edildiği dönemlerde bu sistemlerin yeterli performansı göstermemelerine sebep olmaktadır. Yine de KTRL tahminin bu belirli dönemler için elde edilen genel hata değerlendirmelerinde YSA ve SE tahminlerinin daha başarılı olması dikkati çekmektedir. Yapılacak ilave çalışmalarla varyasyonlardaki bu düşük değerlerin giderilmesiyle YSA sisteminin anomali işaretlerini ve eşik değerleri daha doğru tahmin edeceği düşünülmektedir.

Bu çalışmada geliştirilen YSA, parametrik olmayan adaptif bir metod olduğundan sadece Türkiye'de değil Dünyanın her yerinde ve yağış verisi gibi normal dağılıma uymayan meteorolojik parametrelerin tahminlerinde de kullanılabilir. Aynı yapısal özellikle yeterli süre çalıştırılmış model versiyonlarından elde edilecek yağış vb verileri kullanılarak bu çalışma uygulanıp performansı değerlendirilebilir.

Bu konuda ileride yapılacak olan çalışmalarda aşağıdaki konulara da önem verilmesi gerekmektedir:

- YSA metodunda probleme de bağlı olarak hem öğrenme sürecinde, hem işlemciler arasındaki ağırlıklar ayarlanırken farklı algoritmalar kullanılabilmektedir. Bu da modeller arasında sayısal öngörü modellerinde olduğu gibi bazı zayıf veya güçlü yanların olmasına sebep olabilir. Bazı çalışmalarda ortaya konan bu problemin giderilmesi amacıyla YSA modellerinin ensemble'ının kullanılması denenmiştir. Bu çalışmada aynı çalışma prensibindeki ileri yönlü ağın sadece farklı işlemci sayıları dikkate alınarak bir nevi YSA'ların ensemble'ı da uygulanmaya çalışılmış fakat başarıda yeterli ilerleme gözlenememiştir ancak yapısal farklılıklara sahip YSA'ların ensemble'ı ile çalışmanın daha başarılı sonuçlar vermesi sağlanabilir.
- Bu çalışmada sadece tek bir modelin farklı parametrizasyonlarından elde edilen tahminlerinin ensemble'ı ortaya konmuştur. İleriki çalışmalarda başlangıç koşulları hataları da dikkate alınarak, farklı merkezlerde geliştirilmiş model tahminleri kullanmak, adaptif YSA sisteminde daha başarılı tahminler elde edilmesini sağlayacaktır. Böylece modellere bağlı hatalar daha fazla giderilebilecektir.

KAYNAKLAR

Aguado, E. and Burt, J. E. 2007. Understanding Weather and Climate, Pearson Prentice Hall, New Jarsey, USA.

Arpal, 2005. Procedures for the Poor Man and Multi-Model Ensemble Techniques. Amphore Project, Action 7-8. Liguria, Italy.

Bhowmik, S. K. R. and Durai, V. R. 2010. Application of multimodel ensemble techniques for real time district level rainfall forecasts in short range time scale over Indian Region. *Meteorol. Atmos. Phys.,* **106**, 19-35.

Bosart, L. F. 1975. SUNYA experimental result in forecasting daily temperature and precipitation. *Mon. Wea. Rev.,* **103**, 1013-1020.

Bramer, D. J. 1998. A Study of Short-Range Ensemble Forecasts with Small-Scale Initial Errors. *Master Thesis,* Iowa State University.

Brooks, H. E., Stensrud, D. J., Tracton, M. S., Rogers, E. and Toth, Z. 1996. Short-range ensemble forecasting pilot project. Preprints, *11th AMS Conference on Numerical Weather Prediction*, Norfolk, VA, Amer. Meteor. Soc., J39-J40.

Buckley, B., Edward, J. H. and Whitaker, R. 2008. Weather: A Visual Guide. Friefly Books, Sydney, Australia.

Buizza, R. and Palmer, T. N. 1998. Impact of Ensemble Size on Ensemble Prediction. *Mon. Wea. Rev*., **126**, 2503-2518.

Buizza, R., Miller M. and Palmer T. N. 1999. Stochastic representation of model uncertainties in the ECMWF ensemble prediction system. *Quart. J. Roy. Meteor. Soc.,* **125**, 2887-2908.

Buizza, R., Richardson, D. S., Palmer, T. N. 2001. The new 80-km High Resolution ECMWF EPS. ECMWF Newsletter, **90**, 2-9.

Buizza, R. 2002. Chaos and Weather Prediction January 2000. Meteorological Training Course Lecture Series, ECMWF.

Buizza, R. 2003. Weather Prediction: Ensemble Prediction. *Encyclopedia of Atmospheric Sciences*, London: Academic Press.

Buizza, R, Houtekamer, P. L., Toth, Z., Pellerin, G., Wei, M., Zhu, Y. 2005. A Comparison of the ECMWF, MSC and NCEP Global Ensemble Prediction Systems. *Mon. Wea. Rev.,* **133**(5), 1076-1097.

Buizza, R., Pappenberger, F., Salamon, P., Thielen, J. and de Roo, A. 2009. EPS/EFAS probabilistic flood prediction for Northern Italy: the case of 30 April 2009. ECMWF Newsletter, **120**, 10-16.

Chattopadhyay, S. and Chattopadhyay, G. 2008. Identification of the best hidden layer size for three-layered neural net in predicting monsoon rainfall in India. *Journal of Hydroinformatics*, **10**(2), 181-188.

Chaves, R. R., Mitra A. K., Krishnamurti, T. N. 2005. Seasonal climate prediction for South America with FSU multi- model synthetic superensemble algorithm. *Meteorol. Atmos. Phys.*, **89**, 37-56.

Chien, F.-C. and Jou, B. J.–D. 2004. MM5 Ensemble Mean Precipitation Forecasts in the Taiwan Area for Three Early Summer Convective (Mei-Yu) Seasons. *Weather and Forecasting*, **19**, 735-750.

Clemen, R. T. 1989. Combining forecasts: a review and annotated bibliography. *Int. J. Forecasting*, **5**, 559-583.

Comrie, A. C. 1997. Comparing Neural Networks and Regression Models for Ozone Forecasting. *Journal of the Air & Waste Management Association*, **47**, 653-663.

Dayhoff, J. E. and DeLeo J. M. 2001. Artificial neural networks: Opening the black box. *Cancer*, **91**(8),1615–1635.

Demuth, H. and Beale, M. 1998. Neural Network Toolbox for use with Matlab. The MathWork Inc., http://www.mathworks.com.

Dias, P. L. S., Moreira, D. S. and Neto, G. D. 2006. The master super model ensemble system (MSMES). Proceedings of 8 ICSHMO, Foz do Iguaçu, Brazil, April 24-28, 1751-1757.

Diyankov, O. V., Lykov V. A., Terekhoff, S. A. 1992. Artificial neural networks in weather forecasting. Neuroinformatics and Neurocomputers. *Neuroinformatics and Neurocomputers*, **2,** 829-835.

Doblas-Reyes, F. J., Déqué, M., Piedelièvre, J. P. 2000. Multi-model spread and probabilistic seasonal forecasts in PROVOST. *Quart. J. Roy. Meteor. Soc.*, **126**, 2069-2088.

Doblas-Reyes, F. J., Hagedorn, R., Balmaseda, M. A., Palmer, T. N. 2004. Multi-model seasonal forecasting for the North Atlantic and Europe. *Física de la Tierra*, **16**, 115-125.

Durmayaz, A. and Kadıoğlu, M. 2001. Assessment of the impact of global warming on the residential cooling energy requirement in Adana. *ITEC2001 4th International Thermal Energy Congress*, İzmir-Turkey, July 8-12, 2001, 51-56.

Eckel, F. A. and Mass, C. F. 2004. Effective Mesoscale, Short-range Ensemble Forecasting. University of Washington.

http://www.atmos.washington.edu/~cliff/eckel.pdf

Epstein, E. S. 1969. Stochastic-dynamic Prediction. *Tellus*, **21**, 739-759.

Freiwan, M. and Cigizoglu, K. 2005. Prediction of total monthly rainfall in Jordan using feed forward backpropagation method. *Freseinus Environmental Bulletin*, **14**(2), 142-151.

Gardner, M. W. and Dorling, S. R. 1998. Artificial Neural Networks (The Multilayer Perceptron)-A Review of Applications in the Atmospheric Sciences. *Atmospheric Environment*, **32**(14/15), 2627-2636.

Gneiting, T. and Raftery, A. E. 2005. Weather Forecasting with Ensemble Methods. *Science*, **310**, 248-249.

Graham, R. J., Evans, A. D. L., Mylne, K. R., Harrison, M. S. J. and Robertson, K. B. 2000. An assessment of seasonal redictability using atmospheric general circulation models. *Quart. J. Roy. Meteor. Soc*., **126**, 2211–2240.

Gupta, M. M., Jin, L. and Homma, N. 2003. Static and Dynamic Neural Network from Fundementals to Advanced Theory. John Wiley & Sons, Inc., New Jarsey.

Gyakum, J. R. 1986. Experiments in temperature and precipitation forecasting. *Weather and Forecasting*, **1**, 77-88.

Hagedorn, R., Doblas-Reyes, F. J. and Palmer, T. N. 2005. The rationale behind the success of multi-model ensembles in seasonal forecasting – I. Basic concept. *Tellus*, **57A**, 219-233.

Hamill, T. M. and Colucci S. J. 1996. Random and systematic error in NMC's short-range Eta ensembles. Preprints, *13th Conf. on Probability and Statistics in the Atmospheric Sciences*, San Francisco, CA, Amer. Meteor. Soc., 51-56.

Hamill, T. M. and Colucci, S. J. 1998. Perturbations to the land-surface condition in shortrange ensemble forecasts. Preprints, *Twelfth Conf. on Numerical Weather Prediction*, Phoenix, AZ, Amer. Meteor. Soc., 273-276.

Hansen, J. 2000. Ensemble-based Data Assimilation and Forecasting. Massachusetts Institute of Technology. http://www-paoc.mit.edu/paoc/research/ensemblea.asp.

Hart, K. A., Steenburgh, W. J., Onton, D. J. and Siffert, A. J. 2004. An evaluation of mesoscale-model-based model output statistics (MOS) during the 2002 Olympic and Paralympic winter games. *Weather and Forecasting*, **19**, 200-218.

Hebb, D. 1949. The Organization of Behaviour. John Wiley, New York.

Hoffman, R. N., Kalnay, E. 1983. Lagged average forecasting, an alternative to Monte Carlo forecasting. *Tellus*, **35A**, 100-118.

Hollingsworth, **A.** 1980. An experiment in Monte Carlo forecasting. Workshop on Stochastic Dynamic Forecasting. ECMWF, Shinfield Park, UK.

Hornik, K. M., Stinchcombe, M., White, H. 1989. Multilayer feedforward networks are universal approximators. *Neural Networks*, **2**, 359-366.

Houtekamer, P. L., Lefaivre, L., Derome, J., Ritchie, H., Mitchell, H. L. 1996. A system simulation approach to ensemble prediction. *Mon. Wea. Rev.*, **124**, 1225-1242.

Houtekamer, P. L, Mitchell, H. L. 1998. Data assimilation using an ensemble Kalman Filter technique. *Mon. Wea. Rev*., **126**, 796-811.

Hsieh, W. W, and Tang, B. 1998. Applying Neural Network Models to Prediction and Data Analysis in Meteorology and Oceanography. *Bull. Amer. Meteor. Soc.*, **79**(9), 1855-1870.

Hu, M. J. C. 1964. Application of the ADALINE System to Weather Forecasting, Master Thesis, Technical Report, 6755-1, Standart Electronic Lab, Stanford, C. A.

Jimenez, D. and Walsh, N. 1998. Dynamically Weighted Ensemble Neural Networks for Classification. Proceeding of the International Joint Conference on Neural Networks (IJCNN'98), Anchorage, Alaska, 753-756.

Kadıoğlu, M. 2001. Bildiğiniz Havaların Sonu. Güncel Yayıncılık, İstanbul.

Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., Iredell, M., Saha, S., White, G., Woollen, J., Zhu, Y., Chelliah, M., Ebisuzaki, W., Higgins, W., Janowiak, J., Mo, K. C., Ropelewski, C., Wang, J., Leet-maa, A., Reynolds, R., Jenne, R. and Joseph, D. 1996. The NCEP/NCAR 40-year reanalysis project. *Bull. Amer. Meteor*. *Soc*., **77**, 437-471.

Kalnay, E. 2003. Atmospheric Modeling, Data Assimilation and Predictability. Cambridge University Press, UK.

Kalnay, E. 2004**.** Ensemble forecasting and data assimilation: two problems with the same solution? *Symposium on the 50th Anniversary of Operational Numerical Weather Prediction*, 14-17 June 2004, University of Maryland.

Kang, I–S. and Shukla, J. 2004. Dynamical Seasonal Prediction and predictability of Monsoon, Report of the International Committee of the Third International Workshop on Monsoons (IWMIII). 2-6 November 2004, Hangzhou, China.

Kar, S. C., Hovsepyan, A., Park, C. K. 2006. Economic values of the APCN multi-model ensemble categorical seasonal predictions. *Meteorological Applications*, **13**, 267–277.

Krishnamurti, T. N., Kishtamal, C. M., LaRow, T. E., Bachiochi, D. R., Zhang, Z., Williford, C. E., Gadgil, S., Surendran, S. 1999. Improved Weather and Seasonal Climate Forecasts from Multimodel Superensemble. *Science*, **285,** 15-48.

Krishnamurti, T. N., Kishtamal, C. M., Zhang, Z., LaRow, T. E., Bachiochi, D. R., Williford, C. E. 2000. Multimodel Ensemble forecasts for Weather and Seasonal Climate. *Journal of Climate,* **13,** 4196-4216.

Krishnamurti T. N., Surendran, S., Shin, D. W., Correa-Torres, R., Vijaya Kumar, T.S.V., Williford, C. E., Kummerow, C., Adler, R. F., Simpson, J., Kakar, R., Olson, W. and Turk, F. J. 2001. Real-time multianalysis-multimodel superensemble forecasts of precipitation using TRMM and SSM/I products. *Mon. Wea. Rev.,* **129**, 2861–83.

Leith, C. E. 1974. Theoretical Skill of Monte Carlo Forecasts. *Mon. Wea. Rev.*, **102**, 409-418.

Liu, X., Coulibaly, P. and Evora, N. 2007. Comparison of data-driven methods for downscaling ensemble weather forecasts. *Hydrol. Earth Syst. Sci. Discuss*., **4**, 189–210.

Lorenz, E. N. 1963. Deterministic Nonperiodic Flow. *J. Atmos. Sci*., **20**, 130-141.

Lorenz, E. N. 1965. A study of the predictability of a 28-variable atmospheric model. *Tellus*, **17**, 321-333.

Makhfi, P. 2004**.** Introduction to ANN. http://www.makhfi.com/tutorial/introduction.htm.

Maqsood, I., Khan, M. R., Abraham, A. 2004. An ensemble of neural networks for weather forecasting. *Neural Comput & Applic*., **13**, 112-122.

Maqsood, I. and Abraham, A. 2006. Weather analysis using ensemble of connectionist learning paradigms. *Applied Soft Computing*, **7**, 995–1004.

Mcnelis, P. D. 2005**.** Neural networks in finance: Gaining predictive edge in the market. Elsevier Academic Press, Burlington.

Mehrotra K., Mohan C. K., Ranka S. 1997. Elements of Artificial Neural Networks, MIT press, Cambridge, Massacuhusetts, USA.

Minsky, M. L. and Papert, A. 1969. Perceptrons. MIT Press, Cambridge.

Mitra, A. K., Iyengar, G. R., Duari, V. R., Sanjay, J., Krishnamurti, T. N., Mishra, A., Sikka, D. R. 2011. Experimental real-time multi-model ensemble (MME) prediction of rainfall during monsoon 2008: Large-scale medium-range aspects. *J. Earth Syst. Sci*., **120**(1), 27–52.

Molteni, F., Buizza, R., Palmer, T.N. and Petroliagis, T. 1996. The ECMWF ensemble prediction system: methodology and validation. *Quart. J. Roy. Meteor. Soc*., **122**, 73-119.

Mutemi, J. N., Ogallo, L. A., Krishnamurti, T. N., Mishra, A. K., Vijaya Kumar, T. S. V. 2007. Multimodel based superensemble forecast for short and medium range NWP over various regions of Africa. Meteorol. Atmos. Phys., **87**(113), 87-113.

Müller, M. D. and Scherer, D. 2005. A Grid- and Subgrid-Scale Radiation Parameterization of Topographic Effects for Mesoscale Weather Forecast Models. *Mon. Wea. Rev.*, **133**, 1431-1442.

Oğuz, E. 1999. Genel Klimatoloji. Çetinkaya Kitabevi, İstanbul.

Öztopal, A. 2007. Uydu kaynaklı bulut tepe sıcaklığı ve diğer etkili meteorolojik değişkenlerle kısa vadeli yağış modellemesi için yapay sinir ağı yaklaşımı. *Doktora tezi*, İTÜ.

Palmer, T. N. 1993. Exteneded-Range Atmospheric Prediction and the Lorenz Model. *Bull. Amer. Meteo. Soc.*, **74**(1), 49-65.

Palmer, T. N. 2001. A nonlinear dynamical perspective on model error: Aproposal for nonlocal stochastic-dynamic parametrization in weather and climate prediction models. *Quart. J. Roy. Meteor. Soc.*, **127**, 279-304.

Palmer,T. N., Alessandri, A., Andersen, U., Cantelaube, P., Davey, M., Déqué, M., Díaz, E., Doblas-Reyes, F.-J., Feddersen, H., Graham, R, Gualdi, S., Guérémy J.-F., Hagedorn, R., Hoshen, M., Keenlyside, N., Latif, M., Lazar, A., Maisonnave, E., Marletto, V., Morse, A. P**., Orfila, B., Rogel, P, Terres J.-M, and Thomson, M. C.** 2004. Development of a European Multi-Model Ensemble System for Seasonal to Inter-Annual Prediction (DEMETER). *Bull. Amer. Meteo. Soc.*, **85**(6), 853-872.

Pei, J-S. and Mai, E. C. 2008. Constructing Multilayer Feedforward Neural Network**s** to Approximate Nonlinear Functions in Engineering Mechanics Applications. *Journal of Applied Mechanics*, 75, 061002.

Pham, D. T. and Liu, X. 1995. Neural Networks for Identification, Prediction and Control. Springer-Verlag, London, UK.

Principe, J. C., Euliano, N. R., Lefebvre, W. C. 2000. Neural and Adaptive Systems: Fundamentals Through Simulations. John Wiley & Sons, New York.

Raftery, A. E., Balabdaoui, F., Gneiting T. and Polakowski, M. 2003. Using Bayesian Model Averaging to Calibrate Forecast Ensembles. Department of Statistics, University of Washington, Technical Report 440.

Ramamurthy, M. K. and Jewett, B. F. 1998. Short-range ensemble forecast experiments of Hurricane Opal. Preprints, Twelfth Conf. on Numerical Weather Prediction, Phoenix, AZ, Amer. Meteor. Soc., 351-352.

Regonda, S., Rajagopalan, B., Clark, M. and Zagona, **E.** 2006. A Multi-model Ensemble Forecast Framework: Application to Spring Seasonal Flows in the Gunnison River Basin. *Water Resources Research*, **42**, W09404.

Reynolds, C. A., Webster, P. J. and Kalnay, E. 1994. Random error growth in NMC's global forecasts. *Mon. Wea. Rev.*, **122**, 1281-1305.

Reynolds, C. A., Ridout, J. A., McLay, J. G. 2011. Examination of parameter variations in the U. S. Navy Global ensemble. *Tellus A*, **63**(5),841-857.

Rixen, M. and Ferreira-Coelho, E. 2007. Operational surface drift prediction using linear and non-linear hyper-ensemble statistics on atmospheric and oceanic models. *Journal of Marine Systems*, **65**, 105-121.

Robertson, A. W., Lall, U., Zebiak, S. E. and Goddard, L. 2004. Improved combination of multiple atmospheric GCM ensembles for seasonal prediction. *Mon. Wea. Rev*., **132**, 2732-2744.

Rosenblatt, F. 1958. The perceptron, a probabilistic model for information storage and organization in the brain. *Psych. Review*, **62**, 386-408.

Ross, R. S., Chakraborty, A., Chen, A., Stefanova, L., Sirdas, S. and Krishnamurti, T. N. 2007. Improved seasonal climate forecasts for the Caribbean region using the Florida State University Synthetic Superensemble. *Meteorol. Atmos. Phys.*, **98**, 137–174.

Sanders, F. 1973. Skill in forecasting daily temperature and precipitation: some experimental results. *Bull. Amer. Meteor. Soc.,* **54**,1171-1179.

Schär, C., Vidale, P. L., Lüthi, D., Frei, C., Häberli, C., Liniger, M. A., Appenzeller, C. 2004. The role of increasing temperature variability in European summer heatwaves. *Nature,* **427**, 332-336.

Sirdas, S., Ross, R. S., Krishnamurti, T. N., Chakraborty, A. 2007. Evaluation of FSU synthetic superensemble performance for seasonal forecasts over the Euro-Mediterranean region. *Tellus,* **59A**, 50-70.

Statsoft, 2003. Elementary concepts in statistics. StatSoft Electronic Statistics textbook.
http://www.statsoft.com/textbook/stathome.html

Stensrud, D. J., Bao, J.-W. and Warner, **T. T.** 1998. Ensemble forecasting of mesoscale convective systems. Preprints, Twelfth Conf. on Numerical Weather Prediction, Phoenix, AZ, *Amer. Meteor. Soc*., 265-268.

Stensrud, D. J., Brooks, H. E., Du, J., Tracton, S., Rogers., E. 1999. Using Ensembles for Short-Range Forecasting. *Mon. Wea. Rev.,* **127**, 433-446.

Stensrud, D. J., Bao, J.-W., Warner, T. T. 2000. Using initial condition and model physics perturbations in short-range ensemble simulations of mesoscale convective systems. *Mon. Wea. Rev.,* **128**, 2077-2107.

Stensrud, D. J. 2001. Using short-range ensemble forecast for predicting severe weather events. *Atmospheric Research,* **56**, 3-17.

Stensrud, D. J., and Yussouf, N. 2006. Postprocessing multimodel ensemble data for improved short-range forecasting. *18th Conference on Probability and Statistics in the Atmospheric Science.* Atlanta, GA, Amer. Meteor. Soc.

Stephenson, D. B., Coelho, C. A. S., Doblas-Reyes, F. J. and Balmaseda, M. 2005. Forecast assimilation: a unified framework for the combination of multi-model weather and climate predictions. *Tellus,* **57A**, 253-264.

Strangeways, I. 2010. Measuring Global Temperatures-Their Analysis and Interpretation. Cambridge University Press, Cambridge, UK.

Şen, O., Şaylan, L., Toros, H. 2000. Türkiye İklim Verileri. Proje raporu, Türk Tesisat Mühendisleri Derneği Teknik Yayınları, Ankara, Türkiye.

Şensoy, S. 2004. The Mountains Influence on Turkey Climate. Bolwois 2004, Ohrid, FY Republic of Macedonia, 25-19 May 2004.

Taylor, J. W. and Buizza, R. 2002. Neural Network Load Forecasting with Weather Ensemble Predictions, *IEEE Transactions on Power Systems*, **17**(3), 626-632.

Taylor, J. W. and Buizza, R. 2006. Density forecasting for weather derivative pricing. *International Journal of Forecasting,* **22**, 29-42.

Teweles, S. and Wobus, H. 1954. Verification of prognostic charts. *Bull. Amer. Meteor. Soc.*, **35**, 455-463.

Thielen, J., Schaake, J., Hartman, R. and Buizza, R. 2008. Aims, Challenges and Progress of the Hydrological Ensemble Prediction Experiment (HEPEX): a summary of the 3rd HEPEX workshop, Stresa, 27-29 June 2007, *Atmos. Sci. Lett*., **9**, 29-35.

Toth, Z. and Kalnay, E. 1993. Ensemble Forecasting at NMC: the generation of perturbations. *Bull. Amer. Meteo. Soc.,* **74**, 2317-2330.

Toth, Z. and Vannitsem, S. 2002. Model Errors And Ensemble Forecasting. adres:http://www.emc.ncep.noaa.gov/gmb/ens/papers/ecmwf-finalwordweb.htm

Tracton, M. S., and Kalnay, E. 1993. Operational ensemble forecasting prediction at the National Meteorological Center: Practical aspects. *Weather and. Forecasting*, **8**, 379-398.

Ul-Saufie, A. Z., Yahya, A. S., Ramli, N. A., Hamid, H. A. 2011. Comparison Between Multiple Linear Regression And Feed forward Back propagation Neural Network Models For Predicting PM10 Concentration Level Based On Gaseous And Meteorological Parameters. *International Journal of Applied Science and Technology,* **1**(4), 42-49.

UNDP, 2007**.** Türkiye İklim Değişikliği Birinci Ulusal Bildirimi. Çevre ve Orman Bakanlığı, Ankara.

Warner, T. T. 2011. Numerical Weather and Climate Prediction. Cambridge University Press, Cambridge, UK.

Weigel, A. P., Liniger, M. A., Appenzeller, C. 2008. Can multi-model combination really enhance the prediction skill of probabilistic forecasts? *Quart. J. Roy. Meteor. Soc*., **134**, 241-260.

Widmann, M., Müller, B., Jones, J. and Storch H. 2003. Regional Modelling over Complex Terrain. http://www.zamg.ac.at/ALP-IMP/downloads /session_ widmann. pdf.

Widrow, B. and Hoff, M. E. 1960. Adaptive switching circuits. *Western Electronic Show and Convention*, Convention Record, **4**, 96-104.

Yun, W. T., Stefanova, L., Krishnamurti, T. N. 2003. Improvement of the multimodel superensemble technique for seasonal forecasts. *J. Climate*, **22**, 3834-3840.

Yun W. T., Stefanova L., Mitra A. K., Vijayakumar T. S. V., Dewar W., Krishnamurti T. N. 2005. A Multi-model superensemble algorithm for seasonal climate prediction using DEMETER forecasts. *Tellus A*, **57**, 280-289.

Yuval, 2000. Neural Network for Prediction of Climatological Time Series, Regularized by Minimization of the Generalized Cross-Validation Function. *Mon. Wea. Rev.*, **128**, 1456-1473.

Zhang, E. Y. and Trimble P. 1996. Predicting effects of climate fluctuations for water management by applying neural network. *World Resources Review*, **8**(3), 1-17.

EKLER

EK A: İstasyon bilgilerini içeren çizelge

EK B: Bölgelere göre ayrılmış istasyonlarda ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için ortalama mutlak hata (MAE) değerleri.

EK C: Bölgelere göre ayrılmış istasyonlarda, gözlem anomalileri ve ensemble sistemlerinin (KTRL, YSA, SE) anomali tahminlerinin mevsimsel ortalamaları.

EK A: İstasyon bilgilerini içeren çizelge.

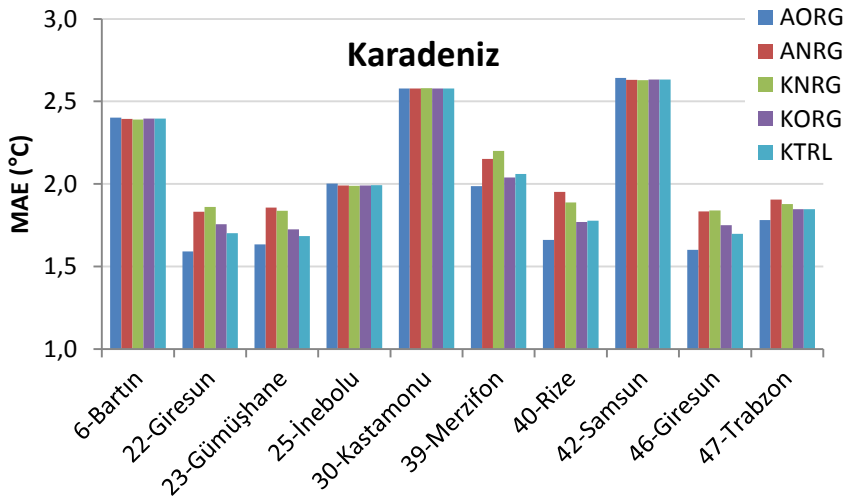
Çizelge A.1: Sıcaklık gözlemleri kullanılan istasyonlara ait enlem, boylam, rakım bilgileri.

	İst Adı	Enlem (°)	Boylam (°)	Rakım (m)
1	Adana	35.30	36.98	20
2	Ağrı	40.05	39.72	1632
3	Ankara	32.88	39.95	894
4	Antalya	30.70	36.88	50
5	Aydın	27.83	37.85	57
6	Bartın	32.35	41.63	30
7	Bilecik	29.97	40.15	526
8	Bingol	40.50	38.87	1177
9	Bitlis	42.10	38.37	1559
10	Bolu	31.60	40.73	742
11	Bursa	29.07	40.18	100
12	Çanakkale	26.40	40.13	3
13	Çiçekdağı/Kırşehir	34.37	39.62	900
14	Çorlu/Tekirdağ	27.80	41.15	183
15	Dalaman/Muğla	28.78	36.75	9
16	Diyarbakır	40.12	37.92	677
17	Göztepe/İstanbul	29.08	40.97	40
18	Edirne	26.57	41.67	48
19	Elazığ	39.22	38.67	882
20	Emirdağ/Afyon	31.17	39.03	945
21	Erzurum	42.27	39.92	1869
22	Giresun	38.40	40.92	38
23	Gumushane	39.45	40.45	1219
24	Hakkari	43.77	37.57	1720
25	İnebolu/Kastamonu	33.78	41.98	64
26	Isparta	30.55	37.75	997
27	İzmir	27.17	38.40	25
28	Karaman	33.23	37.18	1025
29	Kars	43.08	40.60	1775
30	Kastamonu	33.77	41.37	791
31	Kayseri	35.48	38.72	1068
32	Kilis/Gaziantep	37.08	36.73	638
33	Kocaeli	29.08	40.73	70
34	Konya	32.50	37.87	1022
35	Kumköy/İstanbul	29.00	41.30	30
36	Kütahya	29.97	39.40	969
37	Malazgirt/Muş	42.52	39.13	1565
38	Mardin	40.73	37.30	1080
39	Merzifon/Amasya	35.48	40.88	755

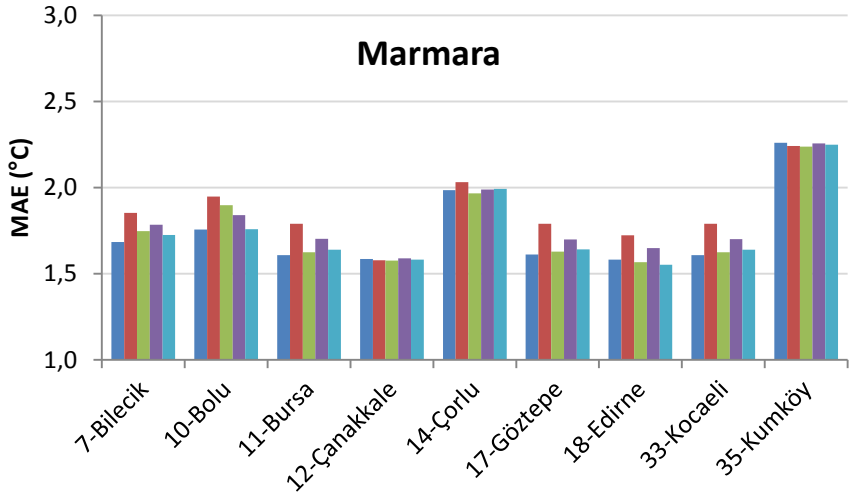
Çizelge A.1 (devam)

	İst Adı	Enlem (°)	Boylam (°)	Rakım (m)
40	Rize	40.52	41.03	4
41	Salihli/Manisa	28.15	38.48	111
42	Samsun	36.33	41.28	44
43	Şanlıurfa	38.77	37.13	547
44	Silifke/Mersin	33.93	36.35	15
45	Sivas	37.02	39.75	1285
46	S.karahisar/Giresun	38.43	40.28	1300
47	Trabzon	39.72	41.00	37
48	Ulukisla/Nigde	34.48	37.55	1451
49	Usak	29.42	38.67	919
50	Van	43.35	38.47	1661

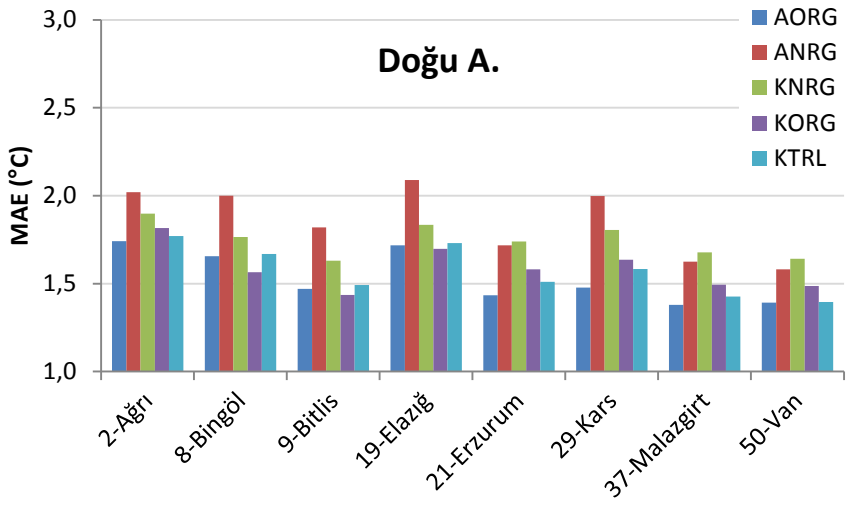
EK B



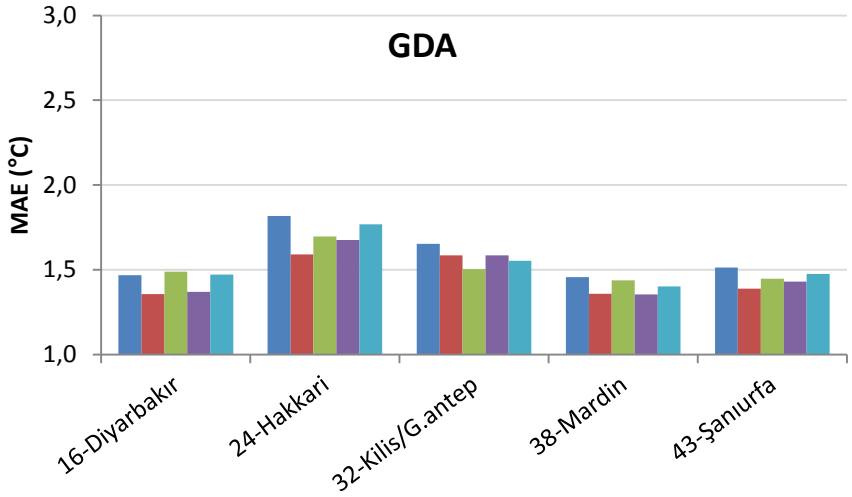
Şekil B.1: Karadeniz Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri.



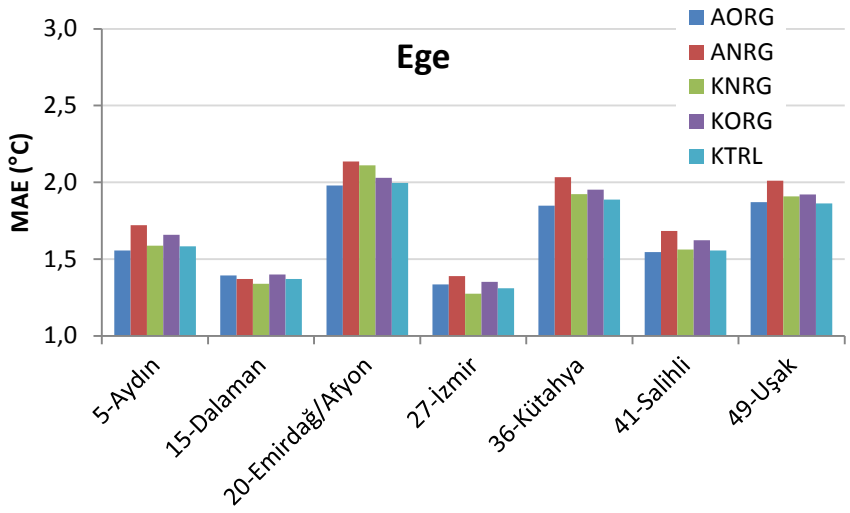
Şekil B.2: Marmara Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri.



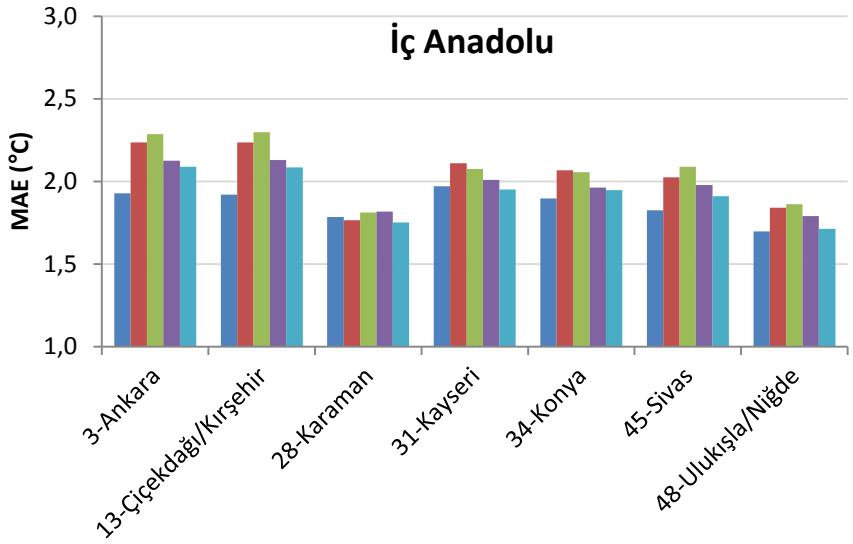
Şekil B.3: Doğu Anadolu Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri.



Şekil B.4: GDA Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri.

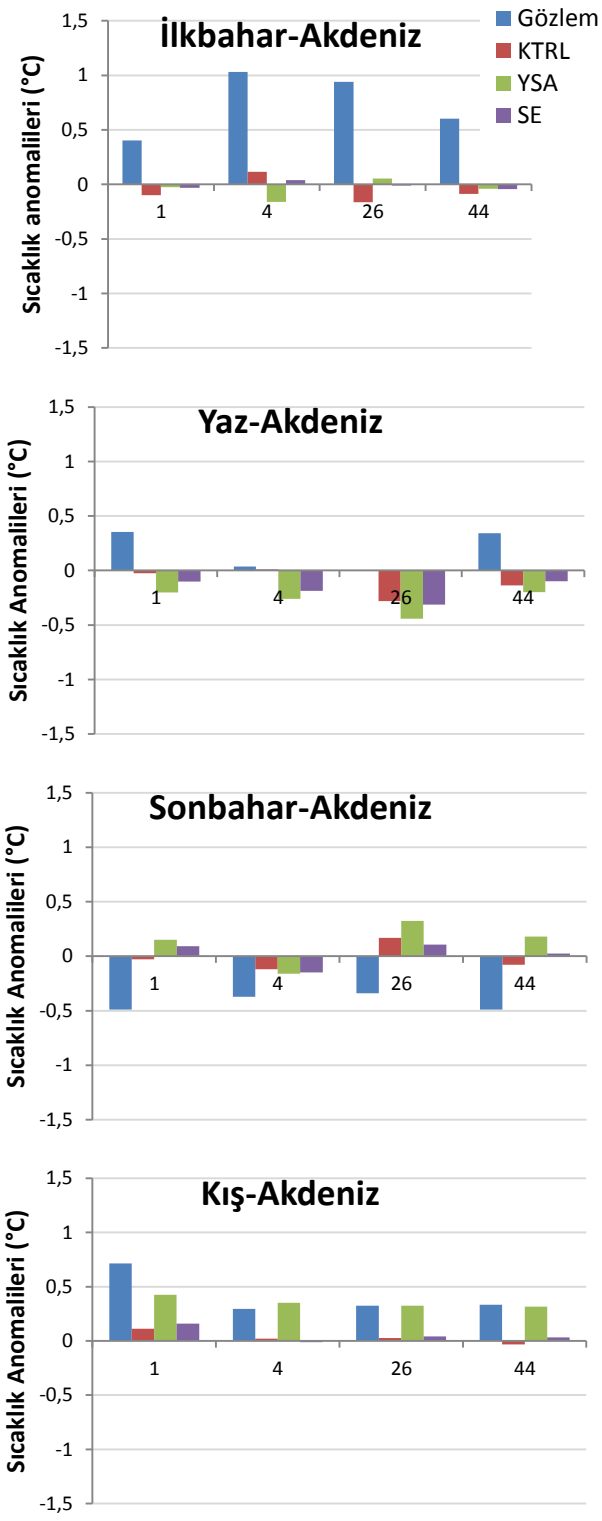


Şekil B.5: Ege Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri.

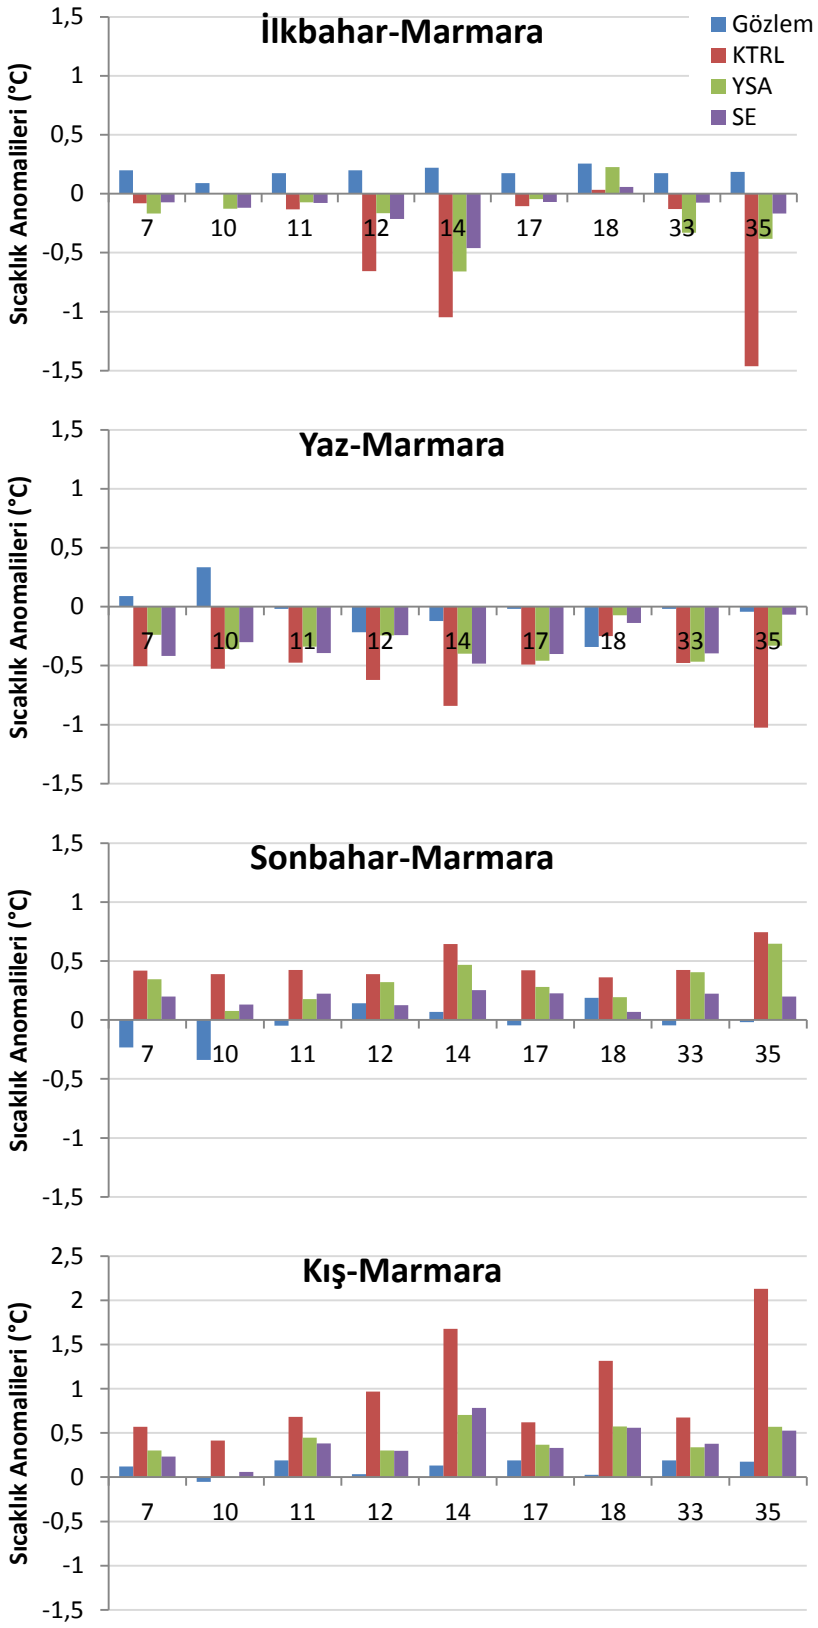


Şekil B.6: İç Anadolu Bölgesi istasyonlarında ensemble üyesi modeller ve kontrol (KTRL) tahminlerinin test periyodu için MAE değerleri.

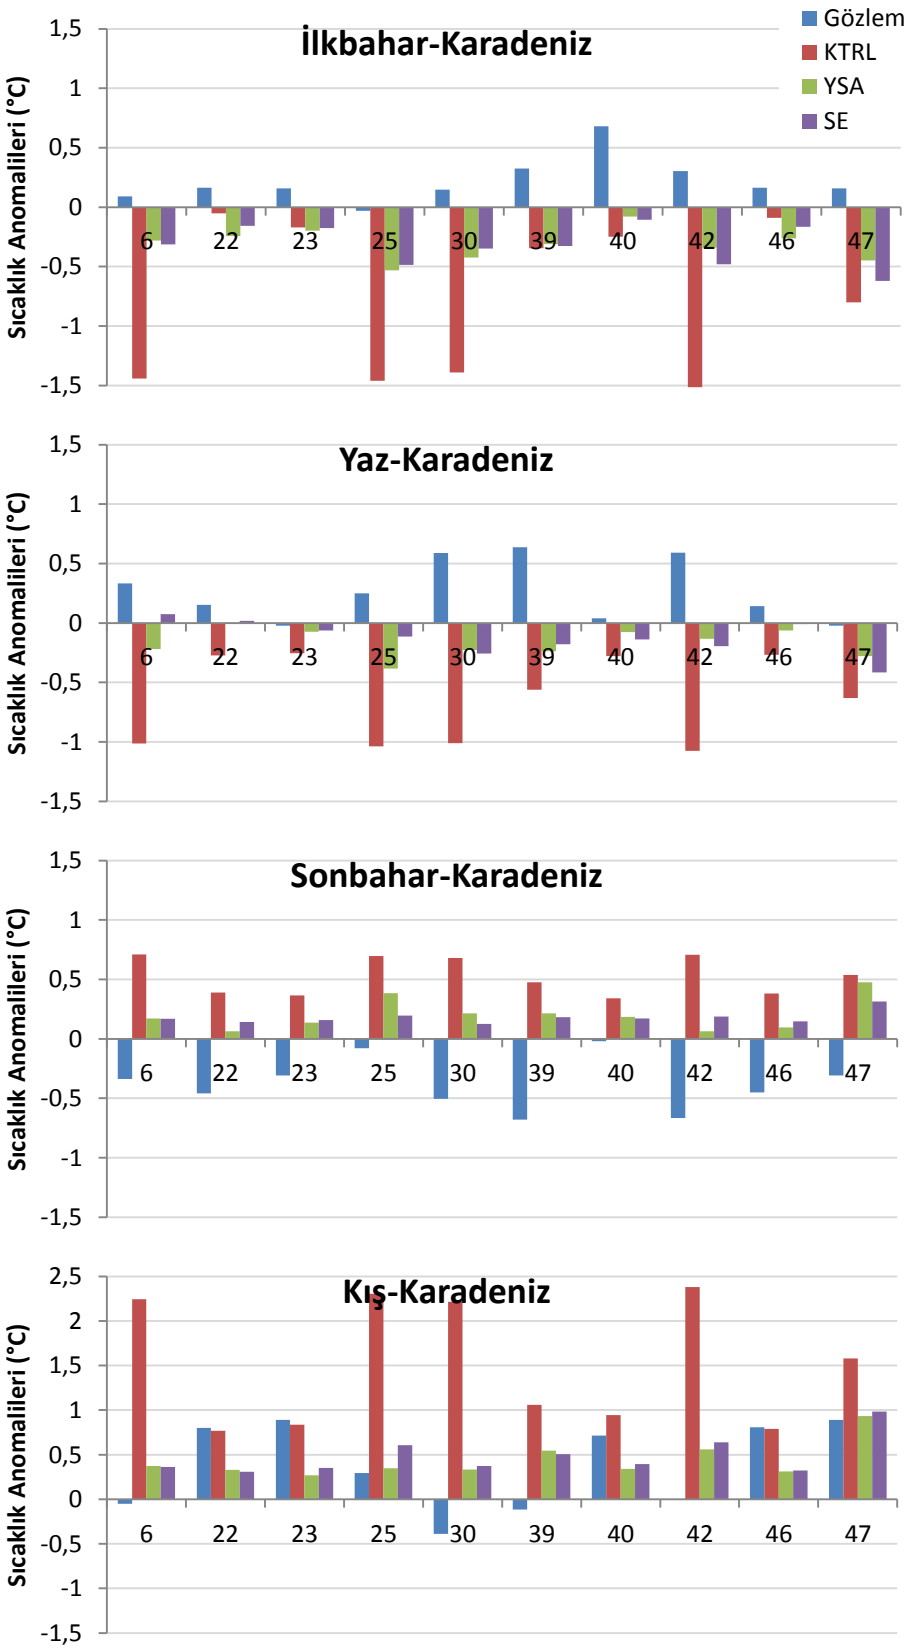
EK C



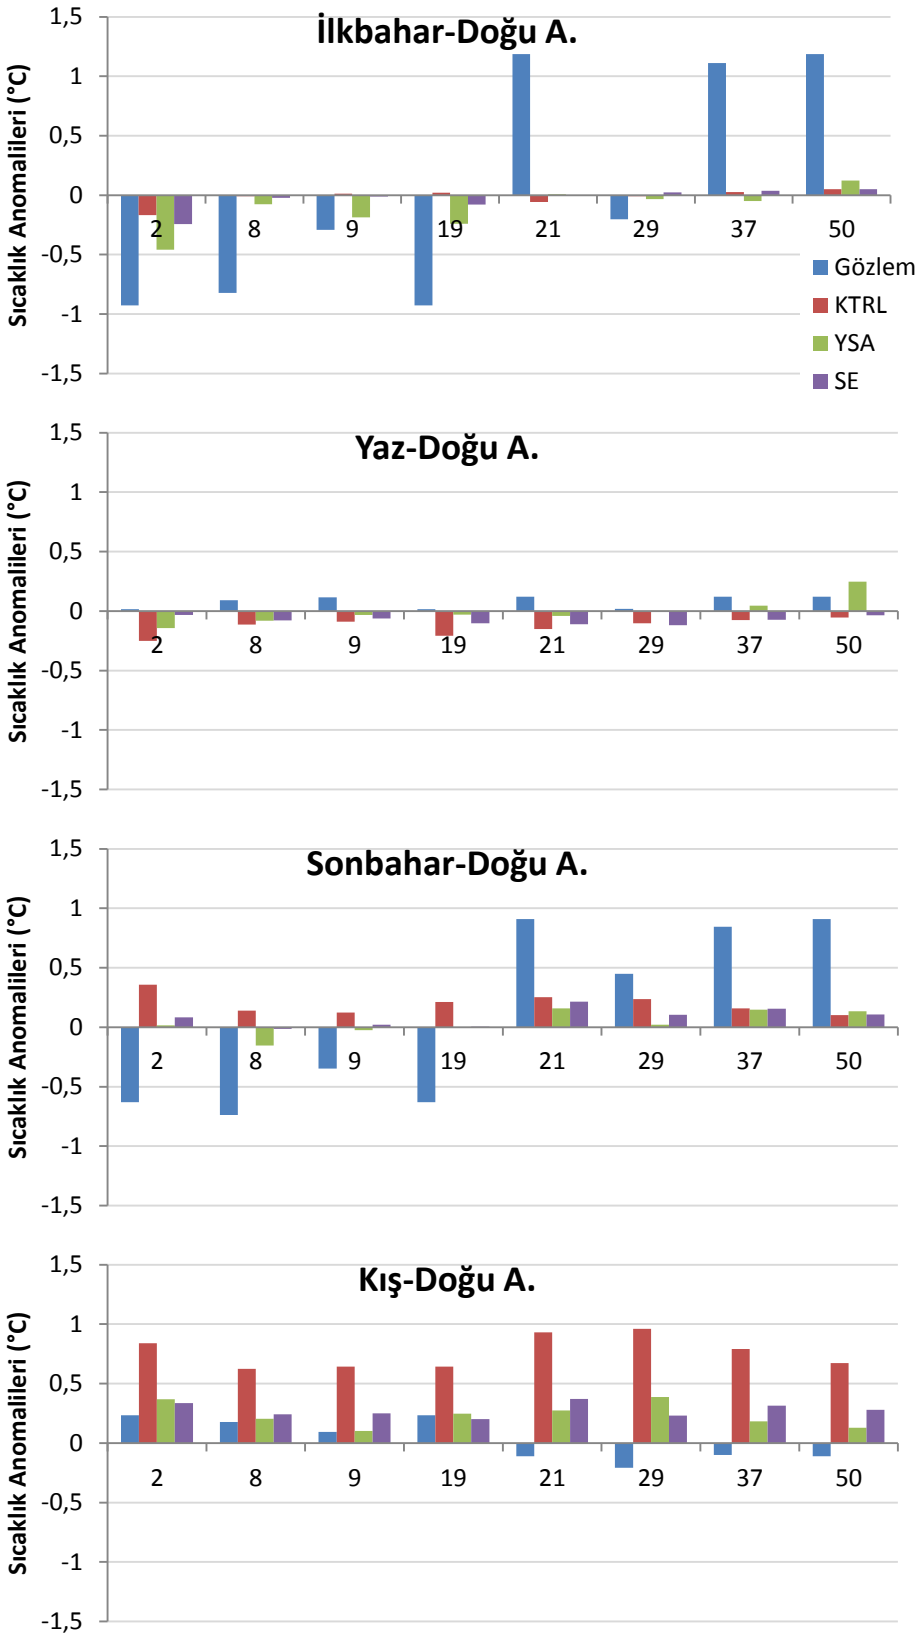
Şekil C.1: Akdeniz Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri.



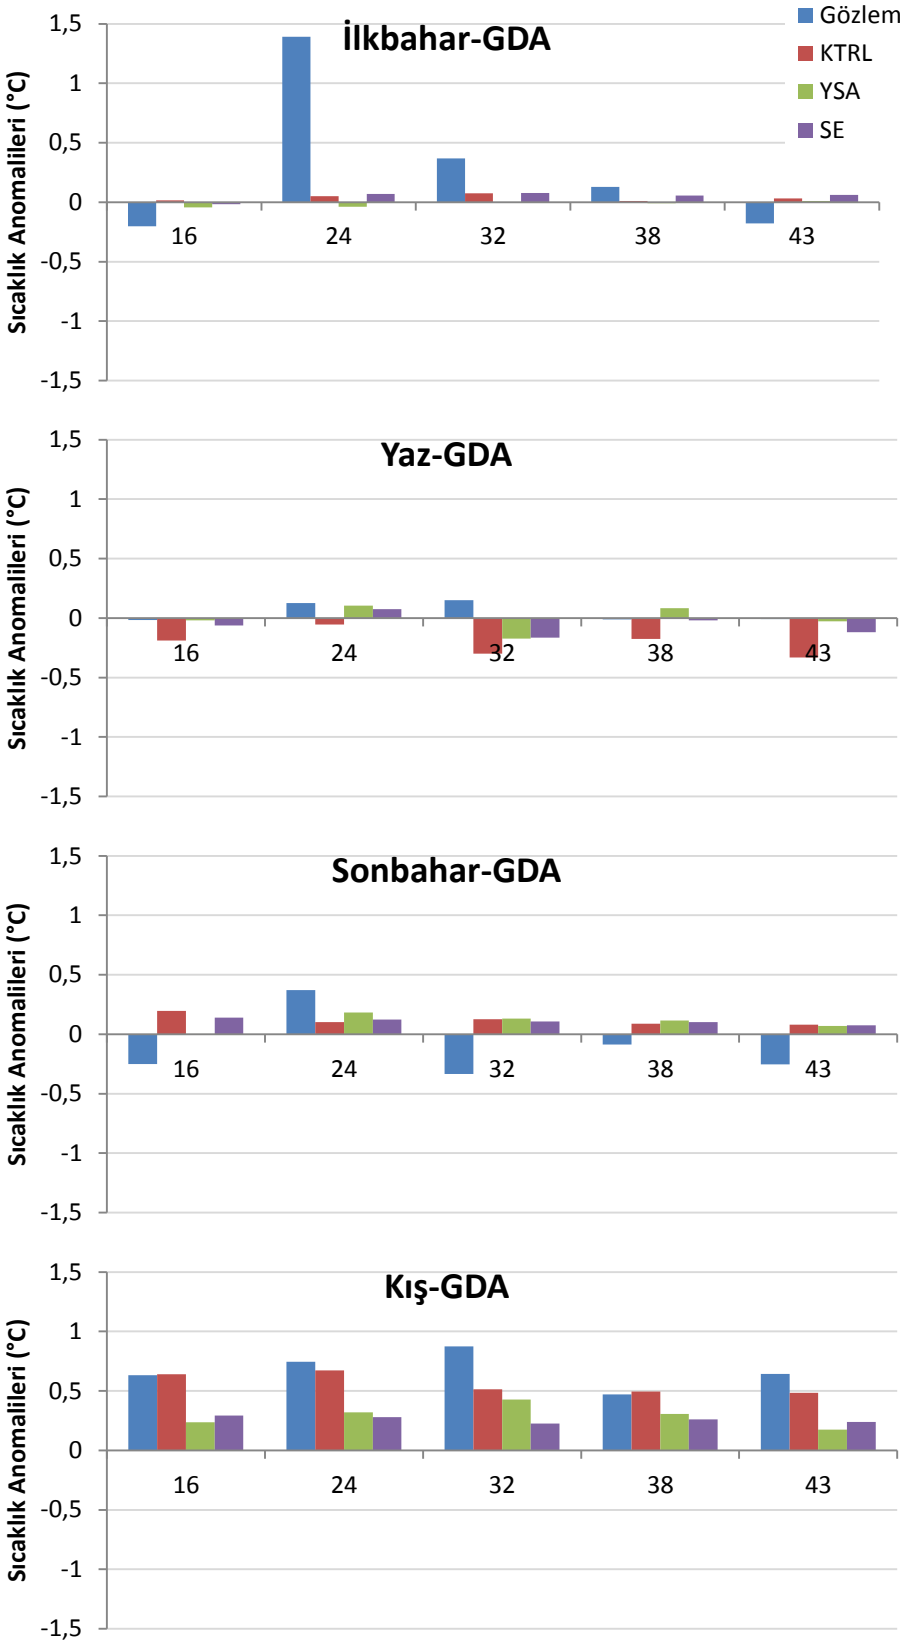
Şekil C.2: Marmara Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri.



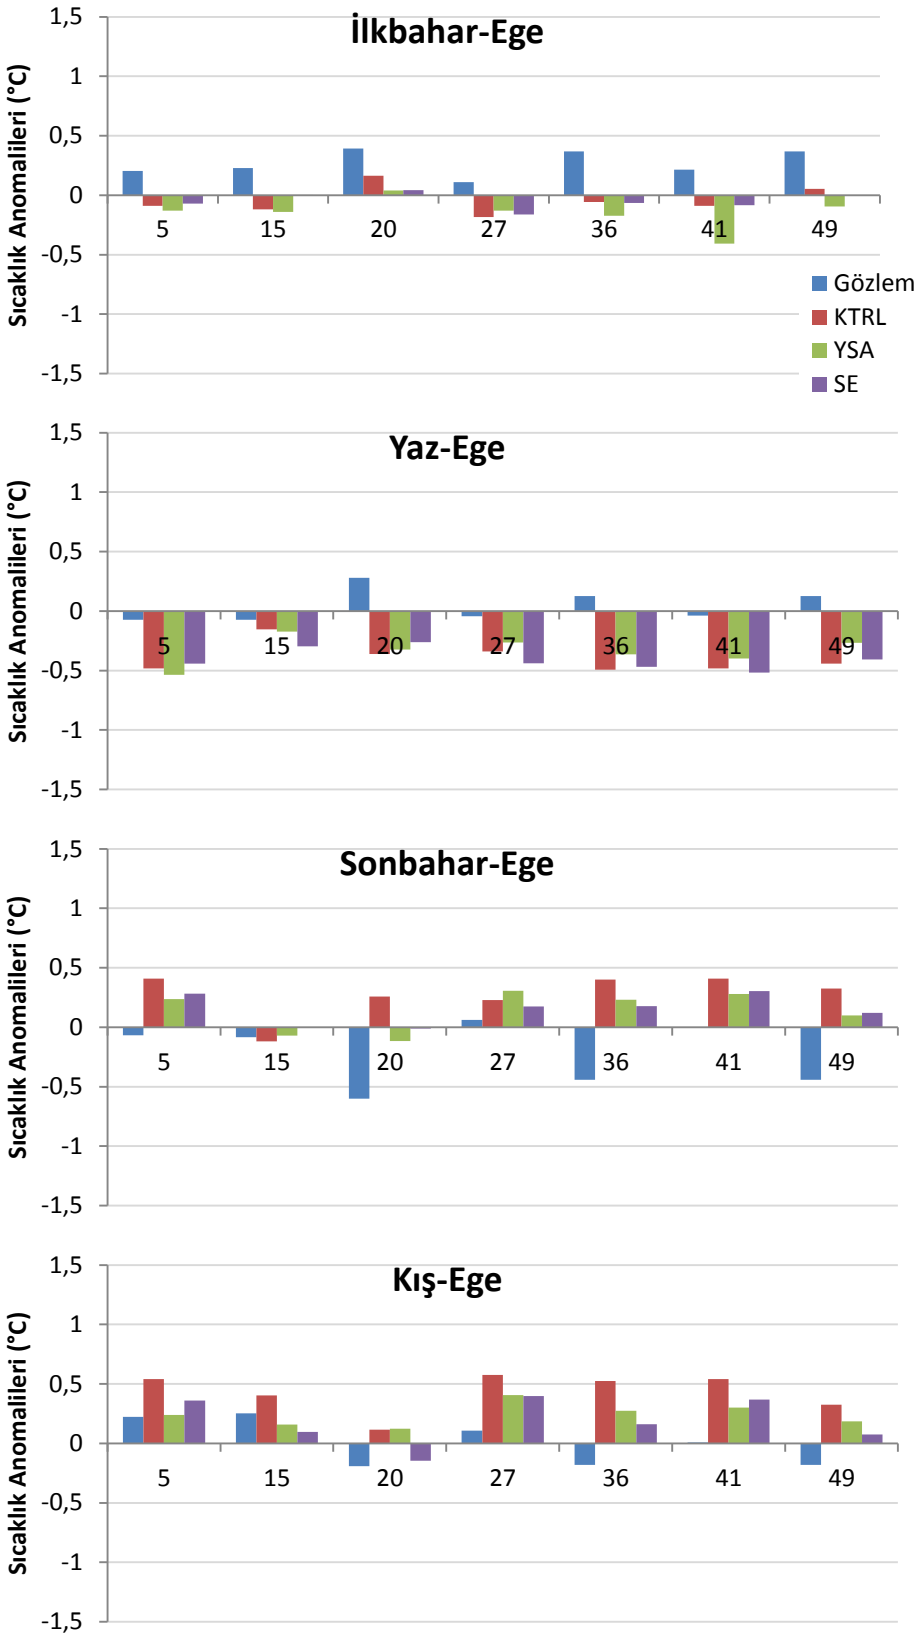
Şekil C.3: Karadeniz Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri.



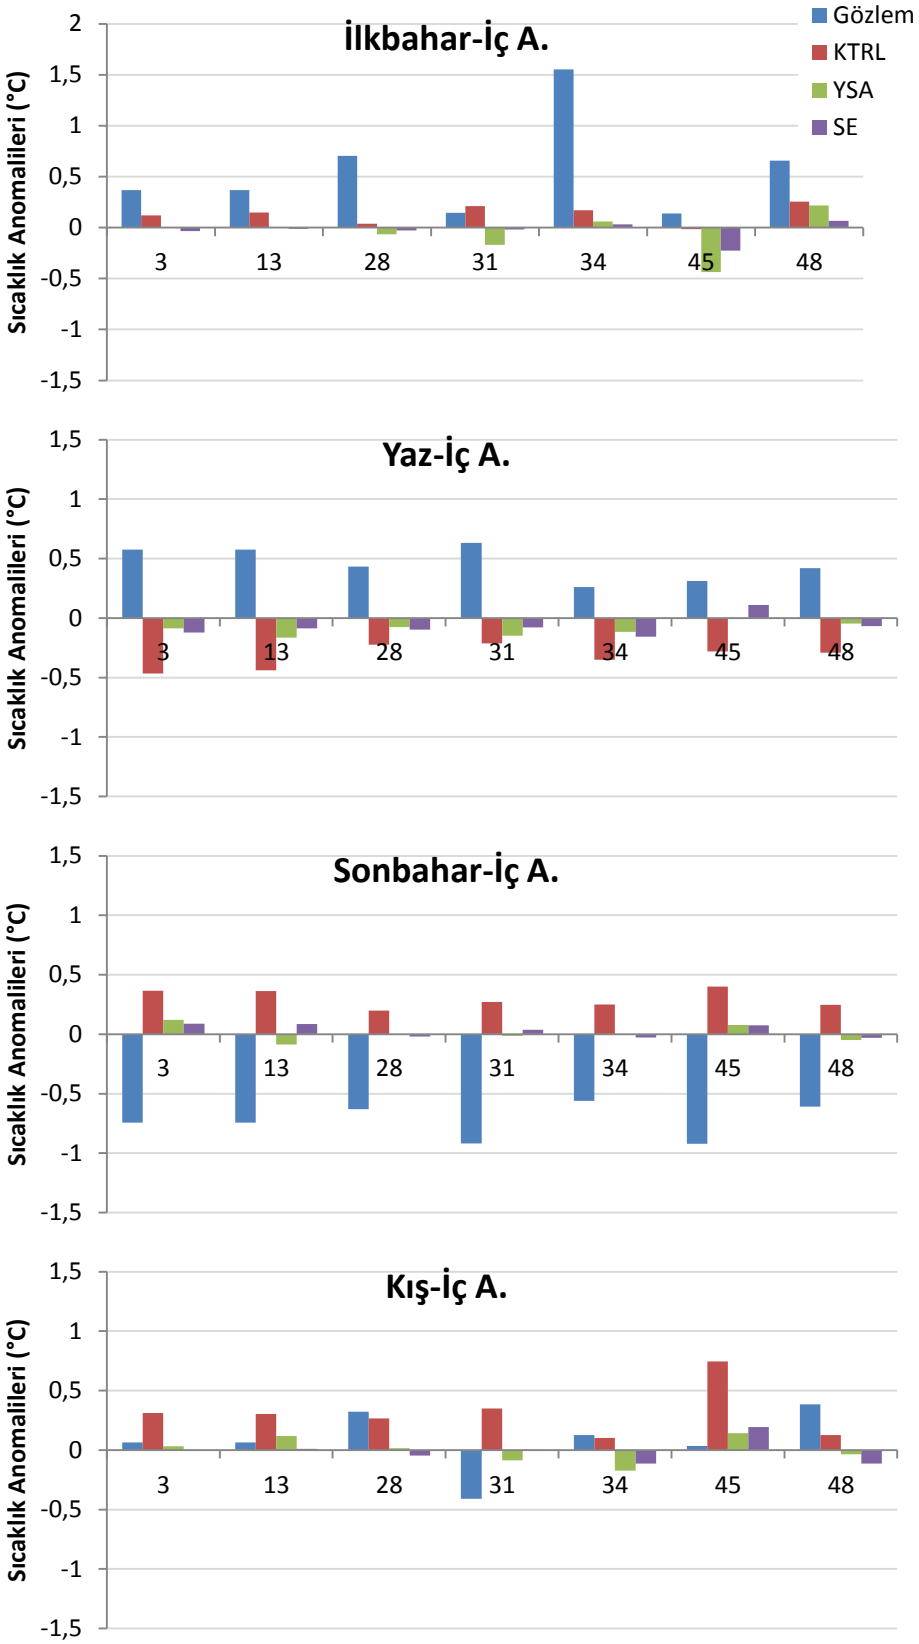
Şekil C.4: Doğu Anadolu Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri.



Şekil C.5: GDA Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri.



Şekil C.6: Ege Bölgesi istasyonlarına ait gözlenen ve ensemble sistemlerinin test tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri.



Şekil C.7: İç Anadolu Bölgesi istasyonlarına ait gözlenen ve ensemble tahminlerinden elde edilen mevsimlik ortalama sıcaklık anomalileri.

ÖZGEÇMİŞ

Ad Soyad: Sedef ÇAKIR

Doğum Yeri ve Tarihi: Gazimağusa/KKTC, 1980

Adres: İTÜ Ayazağa Kampüsü, Meteoroloji Mühendisliği Bölümü, Uçak ve Uzay Bilimleri Fakültesi, 34469, Maslak/İstanbul

Lisans Üniversite: Meteoroloji Mühendisliği, İstanbul Teknik Üniversitesi

Yayın Listesi:

Çakır, S. ve Kadıoğlu, M. 2010. Multi Model Ensemble Forecasting using Neural Network. *AGU-Fall Meeting 2010,* 13-17 December 2010, San Francisco, USA.

Çakır, S. ve Kadıoğlu, M. ve Çubukcu, N. 2011. YSA ile Çoklu-Model Demet Tahmini Uygulaması. V. Atmosfer Bilimleri Sempozyumu, 27-29 Nisan 2011, İstanbul, Türkiye.

Çakır, S. ve Kadıoğlu, M. 2011. Neural Network and Superensemble Applications for Ensemble Forecasting. *11th EMS / 10th ECAM,* 12-16 September 2011, Berlin, Germany.

Çakır, S., Kadıoğlu, M. and Çubukcu, N. 2011. Multi-Scheme Ensemble Forecasting of Surface Temperature Using Neural Network over Turkey, *Theoretical and Applied Climatology*, Düzeltmede.