ING201A

MAKALE OKUMA

3 MAKALE v2

Atmosfer Akademisi

Siteyle eş: başlıklar sitedekiyle aynı, QR o bölüme götürür.

ING201A

MAKALE OKUMA

Kaynaklar ve makaleler


Makaleler site

- **Sıra sitedekiyle aynı:** önce kaynak kartı, sonra (açık lisanslıysa) parçalar.
- **Her parça:** Türkçe cümle → altında İngilizcesi → basitçe → **kendi cümlenle yaz** → kontrol.
- **Telifli makaleler (AMS ©):** çeviri yok; yalnız okuma rehberi ve DOI.
- **Çeviri ve sadeleştirme bize aittir;** özgün metin ve lisans her kartta.

💎 **ÖZ:** Oku → kendi cümlenle yaz → kontrol et. Kendi cümlen = paraphrase alıştırması.

Yucel & Onen (2014) tam işlendi

Kart sitede

Künye (APA): Yucel, I., & Onen, A. (2014). Evaluating a mesoscale atmosphere model and a satellite-based algorithm in estimating extreme rainfall events in northwestern Turkey. Natural Hazards and Earth System Sciences, 14(3), 611–624. https://doi.org/10.5194/nhess-14-611-2014

Lisans: CC BY 3.0

- **Ne yapıyor:** Türkiye'de bölgesel bir hava modelinin (WRF) ve bir uydu ürününün şiddetli yağışta yağış ölçerlere göre ne kadar iyi olduğunu sınıyor.
- **Projede:** Türkiye bağlamı: model yağışının Türkiye'de doğrulanması gerektiği gerekçesi (giriş, par. 4).
- **Projede:** Doğrulama ölçüleri: POD, FAR, CSI; projedeki yağış yakalama oranı aynı mantıkla düşünülür (Şekil 8–9).
- **Projede:** Uydu ürününün düzenli yanlılığı: referans verinin sınırlılığı (sonuç).

💎 **ÖZ:** Türkiye'de bölgesel bir hava modelinin (WRF) ve bir uydu ürününün şiddetli yağışta yağış ölçerlere göre ne kadar iyi olduğunu sınıyor.

§1 Giriş, paragraf 1

Parça sitede

Küresel ısınma ve iklim değişikliğinin etkileri, dünyada gözlenen felaket olaylarının sayısı arttıkça daha belirgin hâle geliyor.

Influences of global warming and climate change are becoming more dominant with increasing numbers of catastrophic events observed around the world.

Küresel ısınmayla yağış ve su döngülerinde büyük değişiklikler gözleniyor; şiddetli yağış gibi meteorolojik afetlerin sıklığı sürekli artıyor ve bu da yüksek kuraklık ve taşkın riskine yol açıyor.

With global warming, major changes in rain and water cycles are being observed, frequency of meteorological disasters such as heavy rainfalls are increasing continuously, consequently resulting in high drought and flood risks.

Örneğin karada son 50 yılın yağış miktarları incelendiğinde, aşırı yağışın toplam yağış içindeki payının arttığı görülüyor (Trenberth vd., 2007).

For example, the study of precipitation amounts during the last 50 years on land shows that the percentage of extreme precipitation compared to total precipitation has increased (Trenberth et al., 2007).

Dünyanın birçok bölgesinde olduğu gibi bu tür aşırı olaylar, yarı kurak ortamlarda taşkına daha yatkın bölgelerde de gözleniyor.

As it occurs and is evident in several geographical regions on the earth, these types of extreme events are also being observed throughout regions more prone to flooding in semiarid environments.

Ayrıca karmaşık topoğrafyalı bölgelerde aşırı olaylar zamanda ve mekânda belirgin farklılıklar gösteriyor ve kısa sürede çok büyük yağış miktarları üretiyor.

Also, in regions having complex topography, extreme events show significant temporal and spatial variations and generate extensive amounts of precipitation in short durations.

Basitçe:

- Isınan dünyada aşırı yağışın payı artıyor.
- Dağlık, engebeli bölgelerde kısa sürede çok yağış düşebiliyor.
- Bu, taşkın riskini doğrudan büyütüyor.

Kendi cümlenle yaz: ana bulgu, tek cümle, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Isınan dünyada aşırı yağışın payı artıyor.

§2 Giriş, paragraf 2

Parça sitede

Can ve malın söz konusu olduğu acil durumlar için taşkın tahmin sistemleri yaygınlaşıyor.

Flood forecasting systems are becoming more widespread for emergency cases where life and property are concerned.

Bu sistemler tehlikeli olayları önceden kestirmeye ve harekete geçmek için yeterli zaman kazanmaya yardım eder.

Such systems help to predict hazardous events and allow sufficient time for action.

İdeal olarak yalnız doğru ve güvenilir tahmin üretmekle kalmamalı, uygun önlemin alınabilmesi için yeterince uzun öncü süre de sağlamalıdırlar.

Ideally, they should not only produce accurate and reliable forecasts, but also provide long enough lead times for appropriate action to be taken.

Taşkın uyarılarının zamanında yapılmasını sağlayacak makul uzunlukta bir öncü süre için, çoğu zaman akış tahmin modelininkiyle uyumlu mekânsal çözünürlükte nicel yağış tahminleri gerekir.

To achieve a reasonably long lead time, which enables timely issuance of flood warnings, quantitative precipitation forecasts with a spatial resolution compatible with that of the flow forecasting model are frequently required.

Şiddetli konvektif yağışların tahmini meteorolojinin zor problemlerinden biridir; aynı zamanda afete hazırlık ve zarar azaltma ile uğraşan birçok kurum için erken taşkın uyarısını zamanında yapabilmek çok önemlidir.

Prediction of severe convective rainfalls is one of the many challenging problems in meteorology; at the same time, it is very important for many agencies engaged in disaster preparedness and mitigation to issue early flood warning in a timely fashion.

Basitçe:

- Taşkın uyarısı hem doğru hem erken olmalı.
- Erken uyarı için yağış tahmini, akış modelinin ızgarasına uyan çözünürlükte olmalı.
- Konvektif yağışı tahmin etmek zor; ama uyarı için şart.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Taşkın uyarısı hem doğru hem erken olmalı.

§3 Giriş, paragraf 3

Parça sitede

Geleneksel olarak hava tahmini çoğunlukla sayısal hava tahmini (NWP) modellerine dayanır; bu modeller geniş alan kapsamı ve yüksek zamansal çözünürlükle atmosfer tahminlerinin en güvenilir kaynağıdır (Liu vd., 1997).

Traditionally, weather forecasting has been based mainly on numerical weather prediction (NWP) models and they are the most reliable source for atmospheric forecasts with a large spatial coverage and high temporal resolution (Liu et al., 1997).

Mezoölçekli NWP modelleri hem operasyonel hem de şiddetli hava tahmininde önemli rol oynamıştır.

Mesoscale NWP models have played an important role in operational as well as severe weather forecasting.

Yüksek çözünürlüklü mezoölçekli modeller, özellikle topoğrafyanın ve arazi kullanımı çeşitliliğinin sinoptik ölçekli havayı değiştirdiği bölgelerde yerel tahmine katkı sağlayabilir.

High-resolution mesoscale models can contribute to localized weather forecasting, particularly in areas where the topography and land-use heterogeneity modulate synoptic-scale weather.

Model öngörülebilirliği açısından gerekli olan bu modellerin doğrulama çalışmaları son yıllarda ilgi görmektedir.

The verification studies of these mesoscale models, which are essential in terms of model predictability, have been gaining interest in recent years.

Colle vd.

A number of studies, such as those by Colle et al.

(2003a, b), Kim ve Lee (2006), Lin ve Colle (2009), Shi vd.

(2003a, b), Kim and Lee (2006), Lin and Colle (2009), Shi et al.

(2010) gibi çalışmalar mezoölçekli modellerin öngörülebilirliğini doğrulamış ve genellikle nicel yağış tahmini/kestirimine (QPF/QPE) odaklanarak bunları iyileştirecek çeşitli istatistik teknikleri değerlendirmiştir.

(2010), have verified the predictability of mesoscale models and generally focused on quantitative precipitation forecasts/estimates (QPF/QPE) and evaluated various statistical techniques for improved QPF/QPE.

Basitçe:

- Hava tahmininin ana aracı NWP modelleridir.
- Yüksek çözünürlüklü model dağ ve kent etkisini daha iyi yakalar.
- Modelin yağışı gözlemle karşılaştırılarak doğrulanır.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Hava tahmininin ana aracı NWP modelleridir.

§4 Giriş, paragraf 4

Parça sitede

Ancak NWP modellerinden doğru yağış hesabı hâlâ zordur.

However, accurate precipitation calculations from NWP models are still a challenge.

Uygun başlangıç ve yanal sınır koşullarıyla yüksek çözünürlüklü mezoölçekli modeller nicel yağış tahminini iyileştirmek için büyük potansiyel sunar; çünkü bu çözünürlükteki modeller konvektif sistemlerin başlamasını ve örgütlenme biçimini tahmin etmede beceri gösterebilir (Done vd., 2004).

With appropriate initial and lateral-boundary conditions, high-resolution mesoscale models offer great potential for improved QPF/QPE because models with this resolution can have skill in predicting the initiation and organizational mode of convective systems (Done et al., 2004).

Weisman vd.

A study from Weisman et al.

(1997), örgütlü konvektif sistemlerdeki baskın dolaşımları çözmek için 4 km ızgara aralığının yeterli göründüğünü göstermiştir.

(1997) showed that 4 km grid spacing appears to be sufficient in resolving the dominant circulations in organized convective systems.

NWP modelleri, şiddetli yağış gibi karmaşık hava olaylarını daha iyi anlamak ve öngörülebilirliği artırmak için erişilebilir bir araçtır; aşırı yağışları belirlemede yetersiz kalan gözlem verisini de tamamlar.

NWP models provide an accessible tool for better understanding and improving the predictability of complex weather phenomena such as heavy rainfall events, while they are performed to add to the insufficient observational data for identifying extreme precipitation events.

Fırtınaları belirlemek için başlangıç ve sınır verisinin yetersiz olması nedeniyle, gerçek olaylarda mezoölçekli sistemlerin başlangıcını iyi simüle etmek zordu (Choi vd., 2011).

Because of the insufficient enforcement of initial- and boundary data to identify storms, the initiation of mesoscale systems in real cases was difficult to simulate well (Choi et al., 2011).

Bu yüzden birçok çalışma, simülasyonların başlangıç koşullarını iyileştirmek için veri özümsemenin yararlı bir araç olduğunu önermiştir ve üç boyutlu varyasyonel özümseme (3DVAR) başlangıç verisi sağlamada baskın yöntem hâline gelmiştir.

Therefore, many studies have suggested that data assimilation is a useful tool in order to improve the initial conditions for simulations (Liu et al., 2005; Yu, 2007; Choi et al., 2011) and the three-dimensional variational assimilation (3DVAR) has become a predominant method for providing initial model data in these studies and others (e.g., Lee et al., 2010).

Ancak 3DVAR tekniği şiddetli hava kestiriminde, özellikle Türkiye'deki şiddetli yağış miktarı için henüz başarıyla uygulanmamıştır.

However, the 3DVAR assimilation technique is yet to be successfully applied for severe weather estimations, especially for the amount of heavy rainfall in Turkey.

Bu nedenle mezoölçekli model testleri yapmak ve sonuçları doğrulamak, model tahminlerinin iyileştirilmesine yön vermek için zorunludur.

Therefore, it is imperative to conduct mesoscale model tests and verify the results to provide a direction for the improvement of model forecasts.

Basitçe:

- Modelden doğru yağış almak hâlâ zor.
- Başlangıç koşulu iyileşirse (veri özümseme) yağış da iyileşebilir.
- Türkiye için bu tür doğrulama eksik: makalenin boşluğu bu.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Modelden doğru yağış almak hâlâ zor.

§5 Sonuç, ilk paragraf

Parça sitede

Bu çalışmada MPE uydu yağış algoritmasından ve veri özümsemeli ile özümsemesiz WRF modelinden elde edilen yağış kestirimleri, Türkiye'nin kısmen dağlık batı Karadeniz bölgesine kurulu 34 yağış ölçerlik ağa karşı, 2000–2011 arasından seçilen 25 farklı ilkbahar/yaz/sonbahar şiddetli yağış dönemi için değerlendirildi.

In this study, QPE from the MPE rainfall algorithm and WRF model with and without data assimilation were evaluated against the network of 34 rain gauges installed in the partially mountainous region of the western Black Sea in Turkey during 25 different spring/summer/fall heavy rainfall event periods selected from 2000 to 2011.

Çalışma, WRF ve uydu ile kestirilen yağışın şiddetli yağış olaylarını doğru üretme becerisini kapsamlı biçimde doğruluyor.

The study provides a comprehensive validation of the characteristics of WRF- and satellite-estimated precipitation to examine their abilities to accurately reproduce heavy rainfall events.

WRF'in yağış tahminini daha da iyileştirmek için model 3DVAR veri özümseme şemasıyla da çalıştırıldı ve şiddetli yağış ile taşkın tahmini amaçlı yağış tahmini üretme potansiyeli gösterildi.

In an effort to further improve the developed QPF by WRF model, the WRF model was also applied with a 3DVAR data assimilation scheme, and its potential in producing QPF for heavy rainfall events and for flood forecasting purposes was shown.

Karşılaştırmalar, WRF modelinin şiddetli yağışları üretmede umut verici bir potansiyeli olduğunu ve veri özümsemeyle sonuçların daha da iyileştiğini gösteriyor.

Comparisons indicate a promising potential of the WRF model in producing heavy rainfall events and with the use of data assimilation in WRF, the results are further improved with a better model performance.

Ancak MPE algoritmasında ele alınması gereken bazı sistematik yanlılık yapıları bulunuyor.

However, with an MPE algorithm some systematic bias structures exist that need to be addressed.

Basitçe:

- 25 olay, 34 yağış ölçer: model ve uydu yağışı karşılaştırıldı.
- Veri özümsemeli model daha iyi sonuç verdi.

- Uydu ürününde düzenli bir yanlılık var: referans veri de sorgulanmalı.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** 25 olay, 34 yağış ölçer: model ve uydu yağışı karşılaştırıldı.

§6 Yöntem 2.1: çalışma alanı ve iklim

Parça sitede

Çalışma alanı kışın kıtasal kökenli soğuk Sibirya Yüksek Basıncının ve denizel kökenli İzlanda Alçak Basıncının kutupsal hava kütlelerinin, yazın ise subtropikal hava kütlelerinin (Azor Yüksek Basıncı ve Pakistan Alçak Basıncının bir kısmı) etkisindedir.

The study area is impacted by polar air masses with continental origin of cold Siberian High, and maritime origin of Iceland Low in the winter and by subtropical air-masses (Azores High and part of Pakistan Low) in the summer.

Sibirya Yüksek Basıncı Karadeniz'i geçip Türkiye'nin kuzey kıyılarına yaklaştığında, kazandığı nem nedeniyle soğuk ve kuru hava denizel-kıtasal bir hava kütlesine dönüşür.

When the Siberian High crosses the Black Sea and approaches the northern coasts of Turkey, cold and dry air turn into a maritime continental air mass due to the acquired moisture content.

Coğrafi yapının çeşitliliği, dağların uzanışı ve karaya yakın denizlerin etkisi bölgenin iklim tiplerini belirler.

The diversity of the geographic structure, extension of the mountains and effects of the seas in the vicinity of the land determine the climate types of the region.

Kıyıya paralel uzanan ve yüksekliği 2065 m'ye ulaşan dağlar yağışın iç kesimlere taşınmasını sınırlar; iç kesimlerde sıcaklık ve yağış azalır ve karasal iklimin etkileri görülür.

Mountains, which lie parallel to the shoreline and have an elevation of up to 2065 m, restrict transfer of precipitation to the inland zones, where temperature and precipitation decrease and the effects of continental climate are observed.

Bu nedenle kıyı kesimlerinde yıllık ortalama yağış 700 ile 1050 mm arasında değişir ve Türkiye ortalamasından (yaklaşık 650 mm) yüksektir; dağların güneyinde ise bu değer yaklaşık 400 mm'ye kadar düşer.

Therefore, mean annual precipitations in the coastal zones vary between 700 and 1050 mm, higher than the mean annual value of Turkey (approximately 650 mm), whereas this value becomes as low as about 400 mm south of mountains.

Yıllık yağışlı gün sayısı kıyı kesimlerinde yaklaşık 130 iken iç bölgelerde 70 güne iner; yağışın çoğu sonbahar ve kışın görülür (Sensoy et al., 2008).

The number of rainy days in a year is about 130 in coastal zones, but it decreases to 70 days in the inland regions, while most of the precipitation is observed in fall and winter (Sensoy et al., 2008).

Basitçe:

- Kıyıya paralel dağlar nemli havayı zorla yükseltir: kıyı yağışlı, iç kesim kurak.

- Kıyıda yıllık yağış 700–1050 mm, dağların güneyinde yaklaşık 400 mm.
- Bu topoğrafya, modelin yağışı doğru yere koymasını zorlaştırır: yüksek çözünürlük bu yüzden gerekli.

Kendi cümlenle yaz: ana bulgu, tek cümle, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Kıyıya paralel dağlar nemli havayı zorla yükseltir: kıyı yağışlı, iç kesim kurak.

§7 Bulgular: Şekil 8–9 (POD, FAR, CSI)

Parça sitede

Örneğin Şekil 8 bu skor değerlerini 25 olayın her biri için (a) panelinde 1 saatlik, (b) panelinde 3 saatlik, (c) panelinde 6 saatlik ve (d) panelinde 24 saatlik aralıklarla gösterirken, Şekil 9a, b, c ve d 34 istasyonun her biri için eşdeğer çizimleri gösterir. Bu şekillerde hem olay hem istasyon çizelgeleri 1 ile 24 saatlik aralıklarla birlikte incelendiğinde, MPE tüm zaman aralıklarında WRF modeline göre belirgin biçimde daha yüksek FAR, biraz daha yüksek POD ve daha düşük CSI gösterir. Ayrıca zaman aralığı 1 saatten 24 saate büyüdükçe POD'da beklenen belirgin artış ve FAR'da azalma görülür. Böylece hem POD'un hem FAR'ın fonksiyonu olan CSI değeri, eş değer eğrileriyle gösterildiği üzere 1'e yaklaşır. FAR, zaman aralıklarıyla birlikte MPE'nin en az iyileşen parametresidir ve bu bulgu, MPE'de algoritmanın yağışı sürekli olarak olduğundan az kestirmesine yol açan sistematik bir sorunun varlığını doğrular. Şekil 8'de, MPE ile birkaç istasyon, istasyonların geri kalanının aksine tüm aralıklarda sürekli düşük FAR değerleri gösterir; çünkü algoritma bu istasyonlarda farklı olaylardan gelen fırtınaların izini yakalamada bir miktar yetenek gösterir. Bu istatistik parametrelerde olaylar arası değişkenlik (bkz. Şekil 8), istasyonlar arasındaki değişkenlikten (bkz. Şekil 9) çok daha belirgindir.

For example, Fig. 8 shows these score values in panel (a) for 1 h intervals, panel (b) for 3 h intervals, panel (c) for 6 h intervals, and panel (d) for 24 h intervals for each of the 25 events, while Fig. 9a, b, c, and d show the equivalent diagrams for each of the 34 stations. As both event and station charts, along with 1- to 24-hourly intervals, are examined in these figures, the MPE

shows substantially higher FAR, slightly higher POD and lower CSI than those of the WRF model at all time intervals. Also, as the time interval aggregates from 1 h to 24 h, the desired pattern of significant increase in POD and decrease in FAR is witnessed. Thus, the CSI value, which is a function of both POD and FAR, converges towards 1, shown within contours. FAR is the least improved parameter of MPE, along with time intervals, and this finding confirms the existence of a systematic problem in MPE that makes the algorithm persistently underestimate precipitation. In Fig. 8, a few stations show consistently low FAR values at all intervals in contrast to the rest of the stations with MPE, as the algorithm shows some ability to capture the track of storms from different events at these stations. Inter-event variability (see Fig. 8) on these statistical parameters is much more evident than the variability appears among stations (see Fig. 9).

Basitçe:

- POD: yağışı yakalama oranı; FAR: yanlış alarm oranı; CSI: ikisini birleştiren başarı ölçüsü.
- Uydu ürünü (MPE) daha çok yanlış alarm verdi; model (WRF) daha başarılı.
- Süre uzadıkça (1 sa → 24 sa) tüm skorlar iyileşir: kısa süreli yağışı tutturmak en zor iş.

- Olaydan olaya fark, istasyondan istasyona farktan büyük.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** POD: yağışı yakalama oranı; FAR: yanlış alarm oranı; CSI: ikisini birleştiren başarı ölçüsü.

Patakchi Yousefi vd. (2024) tam işlendi

Kart sitede

Künye (APA): Patakchi Yousefi, K., Belleflamme, A., Goergen, K., & Kollet, S. (2024). Impact of deep learning-driven precipitation corrected data using near real-time satellite-based observations and model forecast in an integrated hydrological model. Frontiers in Water, 6, Article 1439906. https://doi.org/10.3389/frwa.2024.1439906

Lisans: CC BY 4.0

- **Ne yapıyor:** Tahmin yağışını derin öğrenmeyle düzeltip bir hidrolojik modele veriyor ve düzeltmenin sonraki etkisine bakıyor.
- **Projede:** Zincir fikri: düzeltilmiş yağışı hidrolojik modele vermek (giriş, par. 1 ve 3).
- **Projede:** Literatür boşluğu: DL düzeltmesi + hidrolojik model az çalışılmış (giriş, par. 3).
- **Projede:** Uyarı: yağış iyileşse de hidrolojik sonuç iyileşmeyebilir; referans veri kalitesi kritik (sonuç, par. 2).

💎 **ÖZ:** Tahmin yağışını derin öğrenmeyle düzeltip bir hidrolojik modele veriyor ve düzeltmenin sonraki etkisine bakıyor.

§1 Giriş, paragraf 1

Parça sitede

Su kaynakları tahmini birçok sektör için önemlidir.

Water resources forecasting is important for many sectors.

Suyun varlığı ve dağılımına ilişkin bilgi, örneğin tarımda, evsel ve endüstriyel su temininde ya da ekosistemlerin işleyişinde suyun sürdürülebilir yönetimini sağlar.

Information on the availability and distribution allows for a sustainable management of water, for example in agriculture, domestic and industrial water supply, or ecosystem functioning.

Bütünleşik hidrolojik modeller (IHM) su kaynakları tahmininde, iklim değişikliğinin su varlığına etkilerini öngörmede ve hidrolojik uç olaylarla ilişkili riskleri değerlendirmede hayati rol oynar.

IHMs play a vital role in water resources forecasting, predicting the impacts of climate change on water availability and assessing risks associated with hydrological extremes (Qi et al., 2016; Tuo et al., 2016).

Bu modellerle elde edilen simülasyonların doğruluğu büyük ölçüde sayısal hava tahmini ve iklim modellerinden gelen atmosferik zorlama verisinin kalitesine bağlıdır.

The accuracy of simulations obtained by these models heavily relies on the quality of atmospheric forcing data from numerical weather prediction and climate models (Bennett et al., 2022).

Zorlama verileri arasında yağış anahtardır: karasal yüzey ve yüzey altı su bütçesinin ana sürücüsüdür ve kara yüzeyi enerji dengesini de etkiler.

Amongst the forcing data, precipitation is key, the main driver for the terrestrial surface and subsurface water budgets and also impacting the land surface energy balances (Fekete et al., 2004; Fersch et al., 2020; Jabbari et al., 2019; Pan et al., 2010; Tanhapour et al., 2023).

Yağış doğruluğunu tek başına artırmak daha iyi hidrolojik tahmini garanti etmese de, model tabanlı yağış verisindeki hatalar, özellikle şiddetli yağış olaylarında, hidrolojik tahminlerin doğruluğunu güçlü biçimde etkiler.

While enhancing precipitation accuracy alone does not ensure improved hydrological predictions, errors in model-based precipitation data, especially for heavy rainfall events, strongly affects the accuracy of hydrological predictions (Li et al., 2023; Qi et al., 2016; Saadi et al., 2023a, 2023b).

Basitçe:

- Hidrolojik modelin kalitesi, ona verilen yağışın kalitesine bağlı.
- Şiddetli yağıştaki hata, akış tahminini en çok bozan şey.
- Yağışı düzeltmek tek başına yetmez ama gerekli bir adım.

Kendi cümlenle yaz: ana bulgu, tek cümle, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Hidrolojik modelin kalitesi, ona verilen yağışın kalitesine bağlı.

§2 Giriş, paragraf 3

Parça sitede

Taşkın tahmini ve yağış-akış çalışmalarında yağış doğruluğunun rolü ve yağışın klasik ya da makine öğrenmesi yöntemleriyle düzeltilmesi incelenmiştir.

In flood forecasting and rainfall-runoff studies, the role of precipitation accuracy and its correction using conventional, or machine learning methods have been explored (Huang et al., 2023; Saadi et al., 2023a; Tri et al., 2022; Wijayarathne et al., 2020; Xu et al., 2023).

Yine de özellikle su kaynakları tahmin sistemlerinde derin öğrenmeye (DL) dayalı yağış düzeltmesi üzerine araştırma belirgin biçimde azdır.

Yet, there is a notable scarcity of research especially on DL-based precipitation correction in water resources forecasting systems.

Örneğin yukarıda anılan sistemlerde zorlama verisi olarak kullanılan kısa, orta ya da uzun vadeli yağış tahminlerinin düzeltilmesi genellikle istatistiksel yanlılık düzeltmesi ya da veri özümseme (DA) ile yapılır.

For example, the correction of short-term, medium or long-term precipitation forecasts used as forcing data within the previously mentioned systems is commonly implemented through a statistical bias correction or adjustment, or data assimilation (DA).

Örnek olarak, ABD'nin ulusal su modeli NWM 2.1, Climate Forecast System (CFS) tahminlerinden gelen uzun vadeli yağış ve diğer atmosferik zorlamalar için kantil eşleme yanlılık düzeltmesi kullanır.

For reference, within the context of the forecasting systems mentioned above, NWM 2.1 utilizes quantile mapping bias correction (adjustment) for long-range precipitation and other atmospheric forcing data from Climate Forecast System (CFS) forecasts (Cosgrove et al., 2024; Panofsky and Brier, 1968).

ParFlow/CLM DE06 deneysel 10 günlük deterministik tahminleri ise atmosferik zorlama olarak çoğunlukla Avrupa Orta Vadeli Hava Tahminleri Merkezi'nin (ECMWF) 4 boyutlu varyasyonel veri özümsemeye dayalı yüksek çözünürlüklü deterministik orta vadeli tahminlerini (HRES) kullanır.

The ParFlow/CLM DE06 experimental 10-day deterministic forecasts use as atmospheric forcing mainly the high-resolution deterministic medium-range forecasts (HRES) from the European Centre for Medium-Range Weather Forecasts (ECMWF) (refer to Belleflamme et al., 2023) that are based on a 4D variational Data Assimilation (Bannister, 2001).

Basitçe:

- Yağışı düzeltmenin klasik yolu: kantil eşleme gibi istatistiksel yanlılık düzeltmesi.
- Derin öğrenmeyle düzeltip hidrolojik modele vermek az çalışılmış: boşluk burada.

- Projedeki ‘basit istatistiksel düzeltme’ bu klasik yolun karşılığı.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Yağışı düzeltmenin klasik yolu: kantil eşleme gibi istatistiksel yanlılık düzeltmesi.

§3 Giriş, paragraf 4

Parça sitede

Yağış düzeltme yöntemlerinin etkinliği istatistiksel değerlendirmeyle ölçülür; örneğin olasılık dağılımları, hata ölçüleri ve düzeltilmiş yağış ile gözlem arasındaki mekânsal-zamansal korelasyonlar karşılaştırılır.

The effectiveness of precipitation correction methods is measured through statistical evaluation, e.g., comparing probability distributions, error metrics, and spatiotemporal correlations between corrected precipitation and observed data (Li et al., 2021; Liu et al., 2020; Patakchi Yousefi and Kollet, 2023).

Ancak bu düzeltme yöntemlerini, ayrıca yağışın anlık tahmini, tahmini ve ölçek küçültme uygulamalarını hayata geçirmek ve değerlendirmek bazı zorluklar getirir: referans (gerçek) verinin bulunabilirliği ve kalitesi, veri dengesizliği (örneğin veriye dayalı yöntemlerde) ve anlamlı değerlendirme ölçülerinin seçimi; bu zorluklar taşkın tahmini uygulamalarından iyi bilinir.

However, implementing and evaluating these correction methods as well as nowcasting, forecasting, and downscaling applications of precipitation imposes challenges such as the availability and quality of ground truth data, data imbalance (e.g., in data-driven methods), and the selection of meaningful evaluation metrics, which is well known from flood forecasting applications (Hess and Boers, 2022; Lam et al., 2023; Ravuri et al., 2021; Wang et al., 2021).

Aşağıdaki paragraflarda bu zorluklar ayrıntılı açıklanmaktadır.

In the following paragraphs, these challenges are explained in greater detail.

Basitçe:

- Düzeltmenin iyi olup olmadığı istatistik ölçülerle anlaşılır.
- Üç zorluk: referans verinin kalitesi, nadir şiddetli yağış (veri dengesizliği), doğru ölçü seçimi.
- Projede yüksek şiddetli yağışlar bu yüzden ayrıca değerlendiriliyor.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Düzeltmenin iyi olup olmadığı istatistik ölçülerle anlaşılır.

§4 Giriş, paragraf 5 (ilk kısım)

Parça sitede

Yağışın mekânda ve zamanda çok değişken olması, yerinde gözlemlerden güvenilir referans veri gerektirir; oysa klasik yağış ölçüm kaynaklarının sınırları vardır: yağış ölçerlerde mekânsal temsil sorunu, hava radarında ışın engellemesi kaynaklı boşluklar gibi.

High spatiotemporal variability of precipitation necessitates reliable ground truth data from in-situ observations, yet conventional sources of measuring precipitation have limitations, such as spatial representativity issues in rain gauge observations and beam-blockage gaps in weather radar data (Kidd et al., 2017; Yaswanth et al., 2023; Yousefi et al., 2023).

Uydu verisi daha geniş alanı kapsasa da bulutluluk ve kestirim algoritmalarından kaynaklanan belirsizlikler doğruluğunu etkiler ya da veri boşluklarına yol açar.

Although satellite data cover larger areas, uncertainties stemming from cloud cover and retrieval algorithms affect their accuracy or lead to data gaps (Tian et al., 2009).

Basitçe:

- Yağış ölçer bir noktayı, radar engelsiz alanı, uydu geniş alanı ölçer.
- Her birinin kendi hatası var; ‘gerçek’ yağış da belirsiz.

- Projede referans yağış istasyon gözlemi; her referansın sınırlılığı yazılmalı.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Yağış ölçer bir noktayı, radar engelsiz alanı, uydu geniş alanı ölçer.

§5 Sonuç, paragraf 1

Parça sitede

Bu çalışmada, Orta Avrupa'da operasyonel hidrolojik simülasyonlara yönelik olarak, uydu tabanlı H-SAF h61 yağış gözlemlerini kullanan U-Net evrişimli sinir ağı (CNN) ile HRES yağışına uygulanan derin öğrenme düzeltmesinin doğrudan ve sonraki etkilerini değerlendirdik.

In this study, we evaluated the immediate and downstream impacts of implementing U-Net CNN DL-based correction on HRES precipitation using the satellite-based H-SAF h61 precipitation observations toward operational hydrological simulations over central Europe.

Bulgular, derin öğrenmeye dayalı yağış düzeltmesinin yağış tahmininin doğruluğunu artırmada etkili olduğunu öne çıkarıyor.

The findings of this study highlight the effectiveness of using the DL-based precipitation correction in improving the accuracy of precipitation forecast.

Düzeltilmiş yağış verisi (HRES-C), tahmin verisine (HRES) kıyasla referans kabul edilen veriyle (H-SAF) ortalama hata, kök ortalama kare hata ve korelasyon bakımından daha iyi uyum gösterdi.

The corrected precipitation data (HRES-C) exhibited greater agreement in mean error, root mean squared error, and correlation with the assumed reference data (H-SAF), compared to the forecast data (H-RES).

Bu, saatlik yağıştaki veri dengesizliğine ve uydu verisindeki mekânsal-zamansal boşluklara rağmen derin öğrenme yöntemlerinin yağış verisini düzeltme potansiyelini gösteriyor.

This shows the potential of DL-driven methods in correcting precipitation data despite the data imbalance of hourly precipitation and spatiotemporal gaps in satellite-based data.

Basitçe:

- Derin öğrenmeyle düzeltilmiş yağış, referansa daha yakın çıktı.
- İyileşme hata ölçüleriyle (ortalama hata, RMSE, korelasyon) gösterildi.
- Projedeki ‘sinir ağı daha iyi mi?’ sorusunun bir benzeri burada denendi.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

My sentence + (Author, year)

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Derin öğrenmeyle düzeltilmiş yağış, referansa daha yakın çıktı.

§6 Sonuç, paragraf 2

Parça sitede

Toprak nemi (SM) simülasyonlarında, zorlama verisi olarak kullanılan HRES 24 saatlik tahmini, referans alınan ESA CCI toprak nemi verisiyle hem H-SAF'tan hem de HRES-C'den daha iyi mekânsal-zamansal uyum gösteriyor.

For soil moisture (SM) simulations, the HRES 24-h forecast used as forcing data shows greater spatiotemporal agreement with the referenced ESA CCI SM data compared to both H-SAF and HRES-C.

Bu üç veri setinin 16 yağış ölçer verisiyle ek olarak değerlendirilmesi de bu bulguları destekliyor: HRES, diğer veri setlerine göre yağış ölçer gözlemleriyle daha tutarlı.

The additional evaluation of these three datasets against 16 rain gauge data supports these findings with higher consistency of HRES with the rain gauge observations compared to the other datasets.

Bu durum, derin öğrenme düzeltmesinde referans veri kalitesinin önemini vurguluyor ve operasyonel hidrolojik tahminde kısa vadeli düzeltme ya da gerçek zamana yakın uygulama için uydu gözlemlerinin 'gerçek' olarak daha iyi temsil sağladığı varsayımını sorgulatıyor.

This highlights the importance of reference data quality in DL-based correction approach and challenges the assumptions on the better representativity of H-SAF satellite-based observations as ground truth for short-term correction or near real-time application in operational hydrological forecasting.

Basitçe:

- Yağış iyileşti ama toprak nemi simülasyonu düzelmedi.
- Sebep büyük olasılıkla referans uydu verisinin kendi hataları.
- Ders: yağış skoru iyileşti diye hidrolojik sonuç da iyileşir varsayılamaz; projede akış ucu ayrıca ölçülüyor.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Yağış iyileşti ama toprak nemi simülasyonu düzelmedi.

§7 Sonuç, paragraf 3

Parça sitede

Gelecekteki araştırmalar derin öğrenme düzeltme yöntemlerinin deterministik yönlerine bağlı sınırlılıklara, örneğin referans verideki belirsizliklerin hesaba katılmasına odaklanmalıdır.

Future research should focus on the limitations related to deterministic aspects in DL-based correction methods, e.g., to account for uncertainties in the reference data.

Ayrıca tahmin verisinin doğruluğunun zamanla, özellikle tahmin öncü süresi uzadıkça azalması beklenir.

Furthermore, the accuracy of forecast data is expected to diminish over time, particularly as the forecast lead time extends.

Biz düzeltmeyi HRES'in ilk 24 saatlik tahmini üzerinde uyguladık.

We focused on implementing the correction over the initial 24-h forecast from H-RES.

Yine de daha uzun vadeli tahminlerde iyileştirme potansiyeli olduğunu kabul ediyoruz.

Yet, we recognize the potential for improvements in longer-term forecasts.

Basitçe:

- Referans verinin belirsizliği hesaba katılmalı.

- Öncü süre uzadıkça tahmin bozulur; düzeltme daha uzun süreler için de denenmeli.
- Projede akım tahmini 1 ve 3 saat ileri için ayrı ayrı değerlendiriliyor.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Referans verinin belirsizliği hesaba katılmalı.

Hess & Boers (2022) tam işlendi

Kart sitede

Künye (APA): Hess, P., & Boers, N. (2022). Deep learning for improving numerical weather prediction of heavy rainfall. Journal of Advances in Modeling Earth Systems, 14(3), Article e2021MS002765. https://doi.org/10.1029/2021MS002765

Lisans: CC BY-NC 4.0

- **Ne yapıyor:** Küresel topluluk tahminlerinin yağışını bir derin ağla düzeltiyor; nadir şiddetli yağışa ağırlık veren kayıp fonksiyonu kullanıyor.
- **Projede:** Veri dengesizliği: şiddetli yağış az görülür, ağ onu öğrenmekte zorlanır — projede yüksek şiddetli yağışların ayrıca değerlendirilmesinin gerekçesi.

💎 **ÖZ:** Küresel topluluk tahminlerinin yağışını bir derin ağla düzeltiyor; nadir şiddetli yağışa ağırlık veren kayıp fonksiyonu kullanıyor.

§1 Giriş, paragraf 1

Parça sitede

Yağışı ve özellikle şiddetli yağış olaylarını modellemek ve tahmin etmek hâlâ zordur.

Modeling and predicting rainfall, and in particular heavy rainfall events, remains is challenging.

İlgili çok ölçekli dinamikler küçük ölçekli damlacık etkileşimlerinden büyük ölçekli hava sistemlerine kadar uzanır.

The relevant multi-scale dynamics range from small-scale droplet interactions to large-scale weather systems.

Ayrıca mekânda ve zamanda yüksek kesiklilik ile güçlü biçimde Gauss dışı, sağa çarpık dağılım (Koutsoyiannis, 2004a, 2004b) doğru tahmini güçleştirir.

Further, the high intermittency in space and time, as well the strongly non-Gaussian, right-skewed distribution (Koutsoyiannis, 2004a, 2004b) make accurate predictions difficult.

Termodinamik Clausius-Clapeyron ilişkisi (Allan & Soden, 2008; Donat et al., 2013; Guerreiro et al., 2018) ve kapsamlı model benzetimleri (Masson-Delmotte, V. et al., 2021), ısınan bir atmosferde şiddetli yağışın sıklığının ve şiddetinin artmasının beklendiğini düşündürür (Fischer & Knutti, 2016).

The thermodynamic Clausius-Clapeyron relation (Allan & Soden, 2008; Donat et al., 2013; Guerreiro et al., 2018), and comprehensive model simulations (Masson-Delmotte, V. et al., 2021) suggest that the frequency and severity of heavy rainfall are expected to increase in a warming atmosphere (Fischer & Knutti, 2016).

Ancak bu artışların mekânsal örüntülerinin heterojen ve karmaşık olmasının beklendiği belirtilmelidir (Ali et al., 2018; Traxl et al., 2021).

It should be noted, however, that the spatial patterns of these increases are expected to be heterogeneous and complex (Ali et al., 2018; Traxl et al., 2021).

Buna bağlı olarak şiddetli yağış olaylarının doğru tahmini afetlerin önlenmesi ve etkilerinin azaltılması için giderek daha kritik hâle gelecektir.

Correspondingly, accurate forecasts of heavy rainfall events will become ever more crucial for disaster prevention and mitigation.

Basitçe:

- Şiddetli yağış hem küçük hem büyük ölçekli süreçlere bağlı: tahmini zor.
- Yağış dağılımı çarpık: çoğu gün az yağış, nadiren çok yağış.
- Isınan iklimde şiddetli yağış artacak; doğru tahminin önemi büyüyor.

Kendi cümlenle yaz: ana bulgu, tek cümle, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Şiddetli yağış hem küçük hem büyük ölçekli süreçlere bağlı: tahmini zor.

§2 Giriş, paragraf 2

Parça sitede

Sayısal hava tahmini (NWP) modelleri atmosferin dinamiğini yöneten akışkanlar dinamiği denklemlerini çözer.

Numerical weather prediction (NWP) models solve the fluid dynamical equations governing the dynamics of the atmosphere.

Şiddetli yağış olaylarının tahmini dahil hava tahmini için vazgeçilmezdirler.

They are essential for weather forecasting, including the prediction of heavy rainfall events.

Son on yıllarda sağlanan büyük gelişmelere karşın (Bauer et al., 2015), modellerin çoğunda, özellikle yağışta, önemli hata kaynakları sürmektedir (Boyle & Klein, 2010).

Despite the large improvements made over the past decades (Bauer et al., 2015), considerable sources of error remain in most of the models, in particular for rainfall (Boyle & Klein, 2010).

Yaklaşık 20 km çözünürlüklü küresel NWP modelleri ilgili küçük ölçekli süreçlerin çoğunu açıkça çözümleyemez.

Global NWP models, with a resolution of about 20 km, cannot explicitly resolve many of the relevant small-scale processes.

Bu süreçlerin ızgara altı parametrizasyonlar olarak, yani açıkça çözümlenen (ızgara ölçekli) değişkenlerin fonksiyonları biçiminde yazılarak modele katılması gerekir.

These processes need to be included as sub-grid parameterizations, that is, they are written as functions of the explicitly resolved (gridscale) variables.

Yağış oluşumunda rol oynayan önemli süreçlerin bu parametrizasyonları, şiddetli yağış olaylarının büyüklüğünün olduğundan az ya da çok tahmin edilmesine yol açabilecek yanlılıklar ve hatalar getirir (Wilcox & Donner, 2007).

These parameterizations of important processes involved in the generation of rainfall introduces biases and errors that can lead to an under- or overestimation of the magnitudes of heavy rainfall events (Wilcox & Donner, 2007).

Basitçe:

- NWP modeli fizik denklemlerini ızgarada çözer.
- 20 km'lik ızgara konvektif bulutu göremez; onu yaklaşık formülle (parametrizasyon) temsil eder.
- Yağış hatasının ana kaynağı bu yaklaşık formüllerdir.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

My sentence + (Author, year)

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** NWP modeli fizik denklemlerini ızgarada çözer.

§3 Giriş, paragraf 3

Parça sitede

Bu tür yanlılıkları düzeltmek için benzetilen model çıktısına yaygın olarak son işleme yöntemleri uygulanır (Berg et al., 2012; Maraun, 2016; Wilks, 2011; Xu, 1999).

Post-processing methods are commonly applied to the simulated model output to correct for such biases (Berg et al., 2012; Maraun, 2016; Wilks, 2011; Xu, 1999).

Geleneksel yaklaşımlar yanlılıkları benzetilen ve gözlenen değişkenin uzun dönem istatistikleri arasındaki farklarla ilişkilendirir.

Traditional approaches relate the biases to differences in long-term statistics of the simulated and observed variable.

Bunlar arasında kantil eşleme (QM), dağılımın tamamında yanlılığı düzeltmeye izin verdiği için hava ve iklim modeli uygulamalarında özellikle yaygınlaşmıştır (Cannon et al., 2015; Déqué, 2007; Gudmundsson et al., 2012; Tong et al., 2021).

Among them, quantile mapping (QM) has become particularly popular for weather and climate model applications (Cannon et al., 2015; Déqué, 2007; Gudmundsson et al., 2012; Tong et al., 2021), as it allows to correct for biases over the entire distribution.

Ancak bu yöntemler genel uzun dönem istatistikleri düzeltirken, hem modellenen hem gözlenen eş zamanlı olaylardaki mekânsal yanlılıkları doğrudan düzeltmez.

While correcting the general long-term statistics, these methods, however, do not directly correct for spatial biases in synchronous events that are both modeled and observed.

Basitçe:

- Son işleme = model çıktısını gözlemle karşılaştırıp düzeltmek.
- Klasik yol kantil eşleme: uzun dönem dağılımı düzeltir.
- Eksiği: tek tek olaylarda yağışın yanlış yere düşmesini düzeltmez.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Son işleme = model çıktısını gözlemle karşılaştırıp düzeltmek.

§4 Giriş, paragraf 5

Parça sitede

Derin sinir ağlarından (DNN) yağış gibi kesikliliği yüksek ve kalın kuyruklu dağılıma sahip bir değişkeni çıkarmaları istendiğinde, yaygın olarak kullanılan ortalama kare hata (MSE) kayıp fonksiyonuyla eniyileme çoğu zaman dağılımın ortalamasına iyi bir yaklaşım verir.

When DNNs are tasked to infer a variable with large intermittency and a heavy-tailed distribution, such as rainfall, the optimization with the widely employed mean squared error (MSE) loss function often leads to a good approximate of the distribution's mean.

Bir örnek yığını üzerinden basitçe ortalama alındığından kayba en sık görülen değerler hâkim olur; hedef dağılımın kuyruğundaki aykırı değerlerin katkısı ise görece küçük kalır.

By simply averaging over a sample batch, the loss is dominated by the most frequent values, while outliers in the tail of the target distribution only have a comparably small contribution.

Model esas olarak ortalamaya yakın en sık değerleri doğru tahmin etmeye odaklandığından, bu durum mekânsal örüntülerin bulanıklaşmasına ve kuyruktaki yüksek değerlerin daha az doğru tahmin edilmesine yol açabilir.

This can lead to blurring of the spatial patterns and a less accurate prediction of the high values in the tail, as the model focuses mainly on accurate predicting the most frequent values near the mean.

Basitçe:

- Sıradan hata ölçüsüyle (MSE) eğitilen ağ ‘ortalama gün’ü öğrenir.
- Nadir şiddetli yağış kayba az katkı verir; ağ onu ihmal eder.
- Sonuç: bulanık haritalar ve zayıf kalan şiddetli yağış tahmini — veri dengesizliği sorunu.

Kendi cümlenle yaz: ana bulgu, tek cümle, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Sıradan hata ölçüsüyle (MSE) eğitilen ağ ‘ortalama gün’ü öğrenir.

§5 Tartışma, paragraf 1

Parça sitede

Kısa menzilli sayısal hava topluluk tahminlerinden şiddetli yağışı modellemek için bir DNN sunduk.

We introduced a DNN to model heavy rainfall from short-range numerical weather ensemble forecasts.

Eğitim verisinin güçlü istatistiksel dengesizliğini gidermek için ağırlıklı bir MSE'yi yapısal benzerlik ölçüsüyle birleştiren bir kayıp fonksiyonu (WMSE-MS-SSIM) tanıtıldı.

To address the strong statistical imbalance of the training data, a loss function is introduced that combines a weighted MSE with a structural similarity measure (WMSE-MS-SSIM).

Önerilen WMSE-MS-SSIM kayıp fonksiyonunun, yaygın kullanılan iki kayıp fonksiyonu olan MSE ve MS-SSIM'in tek başına kullanımına göre yüksek değerler bakımından eğitimi belirgin biçimde iyileştirdiği bulundu.

The proposed WMSE-MS-SSIM loss function is found to substantially improve the training with respect to high values compared to using the MSE and MS-SSIM individually, which are two commonly used loss functions.

Karşılaştırma için IFS ortalamasının ridge regresyon modeliyle son işlemesinin herhangi bir iyileşme sağlamadığını gösteriyoruz.

For comparison, we show that post-processing the IFS mean with a ridge regression model does not lead to any improvements.

Bu, U-Net gibi doğrusal olmayan bir DNN mimarisinin önemini gerekçelendirir.

This motivates the importance of a non-linear DNN architecture such as the U-Net.

Dahası sonuçlarımız U-Net mimarisinin yağışın çok ölçekli mekânsal yapısını gerçekten doğru yakalayabildiğini düşündürür.

Moreover, our results suggest that the U-Net architecture is indeed capable of capturing the multi-scale spatial structure of rainfall accurately.

Basitçe:

- Yeni kayıp fonksiyonu nadir şiddetli yağışa ağırlık veriyor.
- Doğrusal yöntem (ridge) iyileştirmedi; doğrusal olmayan ağ (U-Net) iyileştirdi.
- Projedeki ‘sinir ağı doğrusal düzeltmeden iyi mi?’ sorusunun literatürdeki dayanağı.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Yeni kayıp fonksiyonu nadir şiddetli yağışa ağırlık veriyor.

§6 Tartışma, paragraf 3

Parça sitede

Birçok yazarın belirttiği gibi, bir tahminin tüm özelliklerini yakalayan tek bir ölçü yoktur; bu da tamamen veriye dayalı hava tahminlerinin değerlendirilmesini özellikle zorlaştırır (Ebert-Uphoff & Hilburn, 2020; Rasp & Thuerey, 2021; Ravuri et al., 2021).

As noted by several authors, a single metric that captures all characteristics of a forecast does not exist, which renders the evaluation of purely data-driven weather forecasts particularly challenging (Ebert-Uphoff & Hilburn, 2020; Rasp & Thuerey, 2021; Ravuri et al., 2021).

Özellikle yerleşik ölçülerde çoğu zaman varsayılan fiziksel tutarlılık, sinir ağı tabanlı tahminlerde her zaman güvence altında değildir.

In particular, physical consistency, that is often assumed in established metrics, is not always guaranteed in neural network-based predictions.

Bu çalışmada DNN başarımı, hem sürekli hem kategorik birkaç ölçüyle elle değerlendirildi.

In this study, the DNN performance was manually evaluated using several metrics, both continuous and categorical.

Daha uygun ve kapsamlı değerlendirme ölçülerinin ya da bunların birleşimlerinin geliştirilmesinin gelecekteki araştırmaların önemli bir yönü olacağına inanıyoruz.

We believe that the development of more suitable and comprehensive evaluation metrics, or combinations thereof, will be an important direction of future research.

Bu, çeşitli tahmin nitelikleri bakımından tamamen otomatik hiperparametre ayarına olanak tanırdı; ancak bu, bu çalışmanın kapsamı dışındadır.

It would enable a fully automatic hyperparameter tuning with respect to the various forecast qualities, which is, however, outside the scope of this study.

Basitçe:

- Tek bir başarı ölçüsü yetmez: hem sürekli (RMSE) hem kategorik (CSI) ölçü kullan.
- Sinir ağı fiziksel tutarlılığı her zaman korumaz.
- Projede birden çok ölçü (MAE, RMSE, yakalama oranı) seçmenin gerekçesi.

Kendi cümlenle yaz (İngilizce, kaynağa bakmadan): bu parçanın ana bulgusunu tek cümlede, atıfla.

> **My sentence + (Author, year)**

Önce yaz, sonra kontrol et:

- ☐ Cümle yapısı kaynaktan farklı (yamalı yazım yok).
- ☐ Anlam korunmuş; sayı/koşul doğru.
- ☐ (Yazar, yıl) var.

💎 **ÖZ:** Tek bir başarı ölçüsü yetmez: hem sürekli (RMSE) hem kategorik (CSI) ölçü kullan.

Rojas-Campos vd. (2023)

Kart sitede

Künye (APA): Rojas-Campos, A., Wittenbrink, M., Nieters, P., Schaffernicht, E. J., Keller, J. D., & Pipa, G. (2023). Postprocessing of NWP precipitation forecasts using deep learning. Weather and Forecasting, 38(3), 487–497. https://doi.org/10.1175/WAF-D-21-0207.1

Lisans: © AMS — çeviri yok, yalnız özet

- **Ne yapıyor:** İstasyon noktalarında saatlik model yağışını yapay sinir ağlarıyla son işliyor ve klasik yöntemlerle kıyaslıyor.
- **Projede:** Yöntem karşılaştırma düzeni: ham model ↔ klasik düzeltme ↔ sinir ağı; projedeki dörtlü karşılaştırmanın modeli.

Okuma rehberi: başlık → özet → şekiller → sonuç; bulgunun sayfasını not et.

Bulgu ve sayfası (kendi sözünle)



💎 **ÖZ:** İstasyon noktalarında saatlik model yağışını yapay sinir ağlarıyla son işliyor ve klasik yöntemlerle kıyaslıyor.

Kazezyılmaz-Alhan vd. (2021)

Kart sitede

Künye (APA): Kazezyılmaz-Alhan, C. M., Yalçın, İ., Javanshour, K., Aytekin, M., & Gülbaz, S. (2021). A hydrological model for Ayamama watershed in Istanbul, Turkey, using HEC-HMS. Water Practice and Technology, 16(1), 154–161. https://doi.org/10.2166/wpt.2020.108

Lisans: Lisans doğrulanmadı — çeviri yok

- **Ne yapıyor:** Ayamama havzası için kurulmuş bir HEC-HMS modelini anlatıyor (Green-Ampt sızma, Clark birim hidrografı).
- **Projede:** İstanbul'da kentsel havza taşkını bağlamı ve yayımlanmış bir havza modeli örneği.

Okuma rehberi: başlık → özet → şekiller → sonuç; bulgunun sayfasını not et.

Bulgu ve sayfası (kendi sözünle)



💎 **ÖZ:** Ayamama havzası için kurulmuş bir HEC-HMS modelini anlatıyor (Green-Ampt sızma, Clark birim hidrografı).

Vannitsem vd. (2021)

Kart sitede

Künye (APA): Vannitsem, S., Bremnes, J. B., Demaeyer, J., Evans, G. R., Flowerdew, J., Hemri, S., Lerch, S., Roberts, N., Theis, S., Atencia, A., Ben Bouallègue, Z., Bhend, J., Dabernig, M., De Cruz, L., Hieta, L., Mestre, O., Moret, L., Plenković, I. O., Schmeits, M., … Ylhaisi, J. (2021). Statistical postprocessing for weather forecasts: Review, challenges, and avenues in a big data world. Bulletin of the American Meteorological Society, 102(3), E681–E699. https://doi.org/10.1175/BAMS-D-19-0308.1

Lisans: © AMS — çeviri yok, yalnız özet

- **Ne yapıyor:** Hava tahmini son işleme yöntemlerinin geniş bir derlemesi.
- **Projede:** ‘Son işleme’ kavramının ve doğrusal düzeltme yöntemlerinin genel çerçevesi.

Okuma rehberi: başlık → özet → şekiller → sonuç; bulgunun sayfasını not et.

Bulgu ve sayfası (kendi sözünle)



💎 **ÖZ:** Hava tahmini son işleme yöntemlerinin geniş bir derlemesi.