

Uydu Verileri ile Bulut Tespiti için Makine Öğrenmesi Yaklaşımı

Sabri KOÇER^{ID} Yasin ER*^{ID}

Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, Türkiye

Makale Bilgisi

ÖZET

Geliş Tarihi: 19.11.2024
Kabul Tarihi: 06.12.2024
Yayın Tarihi: 31.12.2024

Anahtar Kelimeler:

Uydu verisi,
Konvolüsyonel sinir ağları,
Çok katmanlı algılayıcılar,
Bulut maskesi,
Bulut tespiti,
Görünür ve kızılötesi bantlar.

Bu makalede multispektral uzaktan algılama verileri kullanılarak bulut sınıflandırma ve bulut maskesi oluşturma yöntemleri değerlendirilmektedir. Özellikle Çok Katmanlı Algılayıcılar (MLP) ve Konvolüsyonel Sinir Ağları tabanlı bir model olan CS-CNN üzerinde durulmuştur. MLP, piksel düzeyinde sınıflandırmalar için ileri beslemeli yapısıyla etkili bir yöntem olarak öne çıkarken; CS-CNN, mekânsal bağlamı entegre ederek özellik çıkarma ihtiyacını ortadan kaldıran bir segmentasyon yeteneği sunmaktadır. Çalışmada, bulut tespiti için farklı spektral bantların katkıları da incelenmiştir. Elde edilen sonuçlar, CS-CNN'nin geleneksel eşik tabanlı yöntemlere kıyasla daha yüksek doğruluk ve esneklik sağladığını göstermektedir. Ayrıca, makine öğrenimi tabanlı yaklaşımların, EUMETSAT bulut maskesi gibi geleneksel algoritmalarla karşılaştırıldığında üstün performans sergilediği vurgulanmıştır.

Machine Learning Approach for Cloud Detection with Satellite Data

Article Info

ABSTRACT

Received: 19.11.2024
Accepted: 06.12.2024
Published: 31.12.2024

Keywords:

Satellite data,
Convolutional neural network,
Multilayer perceptron,
Cloud mask,
Cloud detection,
Visible and infrared bands.

This paper evaluates cloud classification and cloud masking methods using multispectral remote sensing data. In particular, Multilayer Perceptrons (MLP) and CS-CNN, a Convolutional Neural Network based model, are emphasized. While MLP is an effective feed-forward method for pixel-level classifications, CS-CNN offers a segmentation capability that eliminates the need for feature extraction by integrating spatial context. In the study, the contributions of different spectral bands for cloud detection were also investigated. The results show that CS-CNN provides higher accuracy and flexibility compared to traditional threshold-based methods. It is also emphasized that machine learning-based approaches exhibit superior performance compared to traditional algorithms such as the EUMETSAT cloud mask.

Bu makaleye atıfta bulunmak için:

Koçer, S., & Er, Y. (2024). Uydu verileri ile bulut tespiti için makine öğrenmesi yaklaşımı. *Aerospace Research Letters (ASREL)*, 3(2), 142-157. <https://doi.org/10.56753/ASREL.2024.2.5>

*Sorumlu Yazar: Yasin ER, yasineryasiner@gmail.com



GİRİŞ

Uzaktan algılamanın en çok kullanılan yöntemi elektromanyetik dalgalardır, ancak ses de dahil olmak üzere diğer taşıyıcı ortamlar da kullanılabilir. Elektromanyetik spektrumun “görünür”, “yakın kızılötesi” ve “kızılötesi” bölgeleri METEOSAT ikinci nesil (MSG) uyduları tarafından ölçülmektedir. Elektromanyetik dalgalar ya yansıyan güneş ışığı ya da yüzeyden ve/veya atmosferik partiküllerden yayılan karasal radyasyondan kaynaklanır. Kızılötesi “Atmosferin Tepesi” (TOA) radyansları uydu sensörleri tarafından ölçülür. Parlaklık Sıcaklığı (BT) bu radyansları ifade etmenin bir yoludur. Yerden yansıyan yüzey radyasyonu bazen bulutlarda dolayı uyduya ulaşamaz ve tamamen emilir. Bu durumda ölçülen radyasyonun kaynağı yer yüzeyi değil bulutun tepe noktasıdır. IR 10.8 µm kanalı ve VIS 0.6 µm kanalı kullanılarak otomatik bulut maskeleye için bir algoritma geliştirilmesini amaçlanmaktadır. Algoritma, dinamik eşik değerleri kullanarak açık gökyüzü parlaklığının belirlenmesini ve bulutlu piksellerin tanımlanmasını içermektedir (Huckle, 2009).

MSG Sistemi bir Uzay Segmenti ve bir Yer Segmentinden oluşmaktadır. MSG-1, MSG -2 ve MSG -3 olarak adlandırılan üç uydu serisine dayalı olarak en az 12 yıllık sistem ömrü boyunca veri, ürün ve hizmet sağlamak üzere tasarlanmıştır.

MSG Uzay Segmenti ESA tarafından yürütülmektedir. ESA aynı zamanda MSG-1 olarak adlandırılan ilk uydunun geliştirilmesi ve tedarik edilmesi sorumluluğunu üstlenmiştir. MSG-2 ve MSG-3 uydularının tedariğini EUMETSAT adına yürütmüştür.

MSG Yer Segmenti EUMETSAT tarafından geliştirilmiştir. EUMETSAT'ın Genel Merkezinde bulunan merkezi tesislerden ve uzak yer istasyonlarından oluşan bir kontrol, edinim, ön işleme ve dağıtım yer segmentinden oluşmaktadır (Aminou, n.d.).

Çok sayıda uzman, halihazırda erişilebilir olan teknolojiyi kullanarak çeşitli otomatik segmentasyon yöntemleri incelemiştir. Daha önceki sistemlerde matematiksel modelleme ve tespit filtreleri gibi geleneksel teknolojiler kullanılmaktayken, özelliklerin çıkarılmasına yönelik makine öğrenimi teknikleri birincil yöntem olarak kullanılmaya başlanmıştır. Böyle bir sistemin oluşturulmasında ana odak noktası her zaman bu bileşenlerin geliştirilmesi ve çıkarılması olmuştur. Çünkü bu sistemlerin karmaşıklığı benimsenmelerinin önünde büyük bir engel olarak görülmüştür (Koçer et al., 2022).

Bulutlar Dünya'daki yaşamın birçok yönünü etkilediğinden ve iklimimiz için çok önemli olduğundan, bir dizi uygulama alanı için son derece hayati öneme sahiptir (Dröner et al., 2018a). Birçok bulut maskesi algoritması için eşik tabanlı kontroller kullanılmıştır. Görünür (VIS), yakın kızılötesi (NIR), kısa dalga kızılötesi (SWIR) ve termal kızılötesi (TIR) dalga boyu aralıklarındaki birçok uydu kanalı, bu algoritmalar tarafından bulutları ve kar/buz örtüsünü tespit etmek için kullanılır. Örneğin MOD35, 10 yansıma bandı ve 9 termal kızılötesi banttan oluşan 19 bant kullanır. Bu algoritmalar genellikle eşik testlerinin birleştirilmesi esasına dayanır. Bu değerlendirmelerde genellikle uzman deneyimlerinden, bulutlu veya açık gökyüzü istatistiklerinden ve model simülasyonlarından elde edilen eşikler kullanılır (Chen et al., 2018a). Farklı ışınım nitelikler, bulutun dikey profilinin sudan karışık (su ve buz) faza ve buza dönüşmesinden ve bulut parçacık boyutu dağılımının yükseklikle değişmesinden kaynaklanır. Bulutların güneş radyasyonunu yansıtma ve Dünya'dan gelen ısıyı hapsedme yeteneği, Dünya'nın iklimini düzenlemede kritik öneme sahiptir.

OCA (Optimal Cloud Analysis): Meteosat İkinci Nesil (MSG) uydularında bulunan Dönen Geliştirilmiş Görünür ve Kızılötesi Görüntüleyici (Spinning Enhanced Visible and Infrared Imager, SEVIRI) cihazından bulut özelliklerini tahmin etmek için kullanılan bir algoritmadır. OCA, tüm ölçümleri ve önemli bulut parametrelerini eş zamanlı olarak ele alan ve bir çözüm elde etmek için optimal tahmin tekniğini kullanan bir yaklaşımdır (Meyer, n.d.).

OCA (Optimal Cloud Analysis) ürünü Haziran 2013'ten beri saatlik frekansta çalışmaktadır. Bu ürün, EUMETCast (EUMETSAT tarafından işletilen çeşitli (çoğunlukla uydu tabanlı) meteorolojik verilerin dağıtım programı) istasyonları ve EUMETSAT (Avrupa Meteoroloji Uydularından İşletme Teşkilatı) veri merkezi aracılığıyla Avrupa ve Afrika üzerinde gerçek zamanlı olarak veri sağlamaktadır. OCA yönteminde, sıcak kanallardan (görünür 0.6 ve 0.8 mm ve yakın kızılötesi 1.6 mm) gelen yansımalar, termal kanallardan (kızılötesi kanallar) gelen yansımalar ve Avrupa Orta Vadeli Hava Tahmin Merkezi (ECMWF) tarafından üretilen meteorolojik sayısal modellerden gelen tahmin verileri kullanılır. Ayrıca bulut tepe basıncı (CTP) ve bulut maskesi (CLM) gibi bazı MSG (Meteosat Second Generation) uydu ürünleri de bu algoritmalarda kullanılmaktadır (Hadizadeh et al., 2019).

Key ve Intrieri (2000) tarafından, Ulusal Okyanus ve Atmosfer İdaresi (NOAA) uydularının Gelişmiş Çok Yüksek Çözünürlüklü Radyometresinde (AVHRR) 8.7 μm 'nin bulunmaması durumunda, 10.8 μm ve 12.0 μm 'ye ek olarak 3.7 μm 'nin uygulanmasıyla bulut fazının belirlenmesi kaydedilmiştir. Ancak, 3.7 μm görüş/aydınlatma geometrisi, yüzey yansıması, bulut ve yüzey sıcaklıkları gibi pek çok faktörden etkilendiği için onların yöntemi yeterli olmamıştır (Key & Intrieri, 2000). Operasyonel hava hizmetlerinde kullanılan konvektif hücre tespit algoritmaları genellikle tek kızılötesi kanal verilerine dayanmaktadır. Bu yöntemlerin dezavantajları nedeniyle, konvektif bulutların otomatik olarak tanınması amacıyla Meteosat SEVIRI kanallarının 0.6 μm ve 1.6 μm farkı ile ürün tanımlamak için bir girişimde bulunulmuştur (Mahović & Zeiner, 2009).

YÖNTEM

Bulut maskesi, bulutlu ya da bulutsuz olarak kategorize edilen açıkça işaretlenmiş bölümlere sahip bir haritadır. Başka bir deyişle, uydu görüntülerinde hangi piksellerin bulutları temsil ettiğini belirleyen bir veri katmanıdır (Bechini & Cremonini, 2007).

Bu çalışma, Evrişimli Sinir Ağları (CNN) kullanarak hızlı bulut segmentasyonu için MSG/SEVIRI verilerini kullanan bir çalışma sunmaktadır. SEVIRI'nin 15 dakikalık zamansal çözünürlüğü ve 2004'ten beri veri bulunması nedeniyle CNN'lerin eğitimi ve değerlendirmesi için bol miktarda veri bulunmaktadır (Dröner et al., 2018b).

CS-CNN modeli, giriş parametresi olarak; üç farklı senaryoyu göz önünde bulundurarak farklı kanalların etkisini değerlendirmek için üç farklı giriş kanalı konfigürasyonu ile eğitilir. Bu senaryolar; 11 kanalın tümünün dahil edilmesi, sadece 8 adet termal kanalın dahil edilmesi ve güneş ışınımından etkilenmeyen 7 termal kanalın dahil edilmesi ile konfigüre edilerek modelin eğitilmesi üzerine oluşturulmuştur.

CS-CNN modelinin çıktısı, her pikselin belirli bir bulut sınıfına atandığı bir segmentasyondur. Model, her piksel için dört olası sınıfı temsil eden beş boyutlu bir olasılık vektörü üretir:

Bulutsuz: Piksel bulut veya kar/buz içermemektedir.

Bulutla Kirlenmiş: Piksel kısmen bulutlu (karışık) veya yarı saydam bulutludur.

Bulutla Dolu: Piksel tamamen opak bulutlarla doludur.

Kar/Buzla Kirlenmiş: Piksel kar veya buz içermektedir.

CNN'lerde parametreler seçilirken, sağlanan verilerin boyutu ve türü göz önünde bulundurulmalıdır. Kurulan algoritmanın performansı ara testlerde daha düşük filtre seçimi ile düşer, ancak daha büyük filtre seçimi ile önemli ölçüde iyileşmez. Aşırı uyum (Overfitting) olasılığını azaltmak amacıyla bırakma (Dropout) için optimum değer kullanılmalıdır (Kacar et al., 2023).

CNN kullanılan sınıflandırmada temel veri kümesi küçüldükçe, veri artırımının katkısı giderek

daha belirgin hale gelir. Ancak, veri kümesi çok küçükse veri artırımı sınıflandırma performansını artırmaz. Ayrıca, sınıflandırma nispeten az veri kullanılarak artırıldıktan sonra yapıldığında sınıflandırma performansı kötüleşir (Oztimur Karadag & Erdas Cicek, n.d.).

Orijinal veri kümeleriyle veya daha fazla veriyle, derin öğrenme modeli daha iyi performans gösterir; ancak, özellikle veri ön işleme prosedürlerinin bir sonucu olarak performansı düşer (Hacıbeyoglu et al., 2024).

Çok katmanlı algılayıcı (MLP) sinir ağları kullanarak MSG/SEVIRI gündüz bulut maskeleye için bir model sunmaktadır. Model, bulut ve açık gökyüzünü sınıflandırmak için önceden tanımlanmış değeri haritalamak üzere eğitildiğinde %88.96'lık bir tespit doğruluğu elde etmiştir (Taravat et al., 2015).

Radyatif transfer simülasyonlarına dayalı ayrıca bir sinir ağı bulut maskeleye algoritması sunulmaktadır. Bu algoritma, CALIOP bulut maskesi ile doğrulanmış ve özellikle ince bulutların tanımlanmasında iyileştirmeler göstermiştir (Chen et al., 2018b).

EUMETSAT tarafından işletilen dört MSG uydusunun (Meteosat-8, 9, 10 ve 11) ilk üçünden gelen veriler, Ocak 2004 - Aralık 2015 dönemini kapsayan CLAAS-2 (CM SAF Cloud Property Dataset using SEVIRI - Edition 2) veri kaydında yer almaktadır. MSG uyduları benzer konumlarda bulunduğundan dolayı SEVIRI görüntüleme geometrileri uydular arasında biraz farklılık göstermekte ve bu durum CLAAS-2 veri kaydının oluşturulmasında dikkate alınmaktadır.

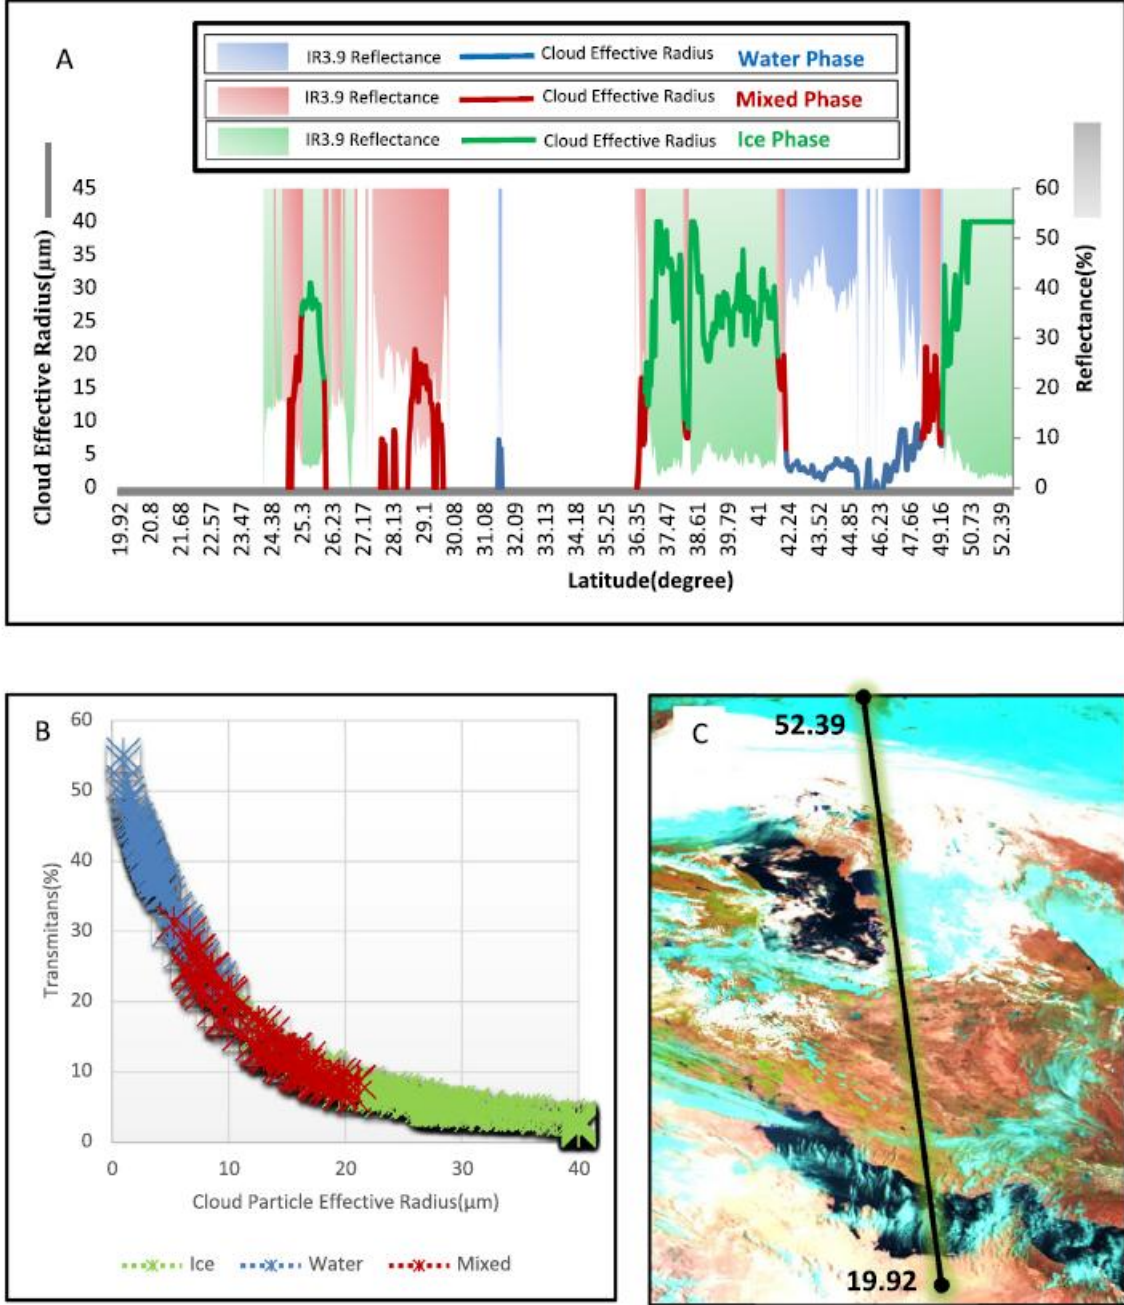
NoWCasting ve çok kısa vadeli tahminleri desteklemek için Uydu Uygulama Aracı (SAFNWC) geliştirilmiştir. Bu araçta, MSG/SEVIRI görüntülerinde Nowcasting ile uyumlu 12 üründen oluşan bir koleksiyon kullanılmıştır. Bu SAFNWC/MSG yazılım paketinde kullanılan bulut maskesi (CMA) ve bulut tipi (CT) algoritmaları kullanılmaktadır. Test dizisi coğrafi konum ve aydınlatma koşullarına dayanırken, eşiklerin çoğu radyatif transfer modelleri kullanılarak yardımcı verilerden (klimatoloji haritaları, atlaslar ve sayısal hava tahmin (NWP) modeli tahmin alanları) dinamik olarak hesaplanır (Derrien & Le Gléau, 2005).

Orta kızılötesi kanaldaki parlaklık ve sıcaklık artışı nedeniyle, parçalanmış bulutlu pikseller sıklıkla sahte yangın pikselleriyle ilişkilendirilir. Bununla birlikte, bir yangın pikseli, özellikle bulut sınırlarında, uygun olmayan bulut maskeleye nedeniyle tespit edilemeyebilir. EUMETSAT, SEVIRI görüntülerine ek olarak bir bulut maskesi (CLM) ürünü sunmaktadır. MSG-SEVIRI spektral kanalları kanal 8 (IR 9.7) ve kanal 12 (HRV) hariç olmak üzere bu maskenin hesaplanmasında kullanılmıştır. SEVIRI görüntülerinin CRPSM tarafından özel olarak kullanılması, yangınları erken bir aşamada (0,1 hektardan daha küçük boyutlarda) tespit etmek için yüksek bir hassasiyet gerektirmektedir. Bunun için kanal 4'te (3,9 µm) tespit edilen parlaklıktaki değişiklikler takip edilmektedir. (Saunders & Kriebel, 1988).

Gelişmiş Çok Yüksek Çözünürlüklü Radyometre (AVHRR) uyduları için bulut-parçacık etkin yarıçapı ile IR3.7 kanalının yansıtıcılığı arasındaki ilişkinin bir yaklaşımı (Kaufman & Nakajima, 1993) tarafından önerilmiştir.

Şekil 1

Karşılaştırma, 22 Mart 2017 tarihinde saat 06:45'te Orta Doğu'da 3,9 mm dalga boyu yansımaları kullanılarak elde edilen bulut parçacığı etkin yarıçapının kesitini göstermektedir. (A ve B) Su fazı bulutları mavi nokta, çizgi ve bölge ile gösterilmiştir. Karışık (buz) faz bulutları kırmızı (yeşil) nokta, çizgi ve bölge ile gösterilmiştir. (C) MSG1 (IODC) uydusunun doğal RGB kompozit görüntüsü.



MODIS (Moderate Resolution Imaging Spectroradiometer): Terra ve Aqua uydularında bulunan ve Dünya'nın atmosferini, kara yüzeyini ve okyanuslarını gözlemlemek için kullanılan bir görüntüleme spektrometresidir. MODIS, bulut özelliklerini (optik kalınlık, efektif parçacık yarıçapı ve termodinamik faz dahil) belirlemek için algoritmalar kullanır (Benas et al., 2017).

Bu çalışmada, MODIS Terra sensöründen 2009 ve 2010 yıllarında toplanan veriler kullanılmıştır. Eşleşen MOD03 coğrafi konum ve MOD35 bulut maskesi verileriyle birlikte dünyanın dört bir yanından 30'dan fazla MOD021KM yansıma veri noktası seçilmiştir. Bulut gölgesi konumlarını hesaplamak için,

bulut maskesi tarafından sağlanan bulutların konumları ve azimut ile güneş ve görüş açıları dahil olmak üzere coğrafi konum verileri kullanılır. Ardından, eğitim örnekleri toplamak üzere, belirli kanallarda spektral eşik tabanlı otomatik bir eğitim örneği veri çıkarma prosedürü gerçekleştirilir. Son olarak, bulut gölgelerinin tam konumlarını tespit etmek için bir Destek Vektör Makinesi (SVM) sınıflandırma prosedürü kullanılır (Zhang et al., 2013).

UYGULAMA ALANLARI

Bulutlar iklim tahminlerinde önemli bir rol oynamaktadır. İklim tahminleri, tahmin edilen parçalanmış bulut örtüsü veya bulutlarla kaplı alanı etrafındaki önemli belirsizlik nedeniyle zordur. Gelecekteki iklim tahminlerini geliştirmek amacıyla, Avrupa Bulut Örtüsü veri seti, bulut örtüsü ile diğer çevresel değişkenler arasındaki istatistiksel ilişkileri belirlemede kullanılabilir (Svennevik et al., 2024).

Bulutlar ve radyasyon etkileşim içinde olduğundan, parçalı bulut örtüsündeki (CFC) veya gökyüzünün bulutlarla kaplı yüzdesindeki değişikliklerin küresel ısınma üzerinde bir etkisi olacağı tahmin edilmektedir. Bu durum, güneş enerjisi üretimi ve tarım da dahil olmak üzere toplum ve çevre üzerinde etkili olacaktır (Svennevik et al., 2024).

İklimi etkileyen atmosfer, okyanuslar, kara yüzeyi ve buz fiziği ile ilgili diferansiyel denklemler, sayısal iklim modelleri (NCM) kullanılarak çözülür. NCM'ler iklim tahmini için çok önemli araçlardır. Sıcaklık ve basınç gibi bazı değişkenler doğru bir şekilde tahmin edilebilir, ancak parçalı bulut örtüsü gibi diğer değişkenler çok daha büyük belirsizliklerle bağlantılıdır (Zelinka et al., 2020).

Toplum, insan kaynaklı iklim değişikliğinin yakınlığı konusunda bilinçlendirilmiştir. İklim değişikliğinin dünyanın çeşitli bölgeleri üzerindeki etkisi bölgesel iklim modelleri kullanılarak değerlendirilebilir. Bu modellerin ölçümlerle doğrulanması çok önemlidir. Bu durumda, yüksek zamansal çözünürlüğe sahip küresel veriler sağladıkları için uydu verileri oldukça yardımcı olmaktadır (Huckle, 2009).

Bitki örtüsünün yoğunluğunu ve sağlığını ölçmek için kullanılan NDVI (Normalize Edilmiş Fark Vejetasyon İndeksi) hesaplamalarında, bulutlu pikseller hatalı sonuçlara yol açabilir. Bulut maskeleri kullanılarak bu pikseller maskelenir ve NDVI hesaplaması sadece bulutsuz pikseller üzerinden yapılır, bu da daha doğru sonuçlar elde edilmesini sağlar (Meyer, n.d.; Rasmussen et al., 2011).

Okyanus rengi, suyun içindeki klorofil ve diğer maddelerin konsantrasyonu hakkında bilgi sağlar. Bulutlar, okyanus yüzeyinden yansıyan ışığı etkileyerek renk ölçümlerinde hatalara neden olabilir. Bulut maskeleri, bulutlu pikselleri tanımlayarak bu piksellerin analizlerden çıkarılmasını ve okyanus rengi ölçümlerinin doğruluğunun artmasını sağlar (Ackerman et al., 2006; Choi et al., n.d.).

Kara yüzeyi sıcaklığı, iklim değişikliği, su kaynakları yönetimi ve tarım gibi birçok alanda önemli bir parametredir. Bulutlar, termal kızılötesi sensörler tarafından ölçülen kara yüzeyi sıcaklığını etkileyerek daha düşük sıcaklık değerlerine yol açabilir. Bulut maskeleri, bulutlu pikselleri tanımlayarak bu piksellerin analizlerden çıkarılmasını ve kara yüzeyi sıcaklığı ölçümlerinin doğruluğunun artırılmasını sağlar (Rasmussen et al., 2011).


BULUT SEGMENTASYONU EVRİŞİMSEL SİNİR AĞI (CS-CNN)

CS-CNN, multispektral uzaktan algılama verilerinden yüksek çözünürlüklü mekânsal sınıflandırmalar elde etmek için etkili bir yöntemdir. Bu model, mekânsal bilgileri dahil etmek için yalnızca ham veriler üzerinde çalışır ve önceden tanımlanmış özelliklerin oluşturulmasına ihtiyaç duymaz. CS-CNN'nin temel amacı, multispektral uzaktan algılama verilerini kullanarak bulut maskeleri oluşturmaktır. Mimari, multispektral uydu görüntülerini girdi olarak alır ve her pikseli uygun bir bulut

sınıfına atayan bir segmentasyon sonucu üretir. CS-CNN, bu tür görevler için önceden tasarlanmış bir yapıya veya önceden eğitilmiş bir modele bağımlı değildir (Dröner et al., 2018b).

Şekil 2

CS-CNN Mimarisi



Ağ için kullanılan giriş, Şekil 2'nin sol tarafında sunulmuştur. Çalışma alanının boyutu, 508x508 piksel uzamsal çözünürlükle uyumlu olacak şekilde belirlenmiştir. Her sahne seçilen kanalların sayısı, girişin derinlik boyutunu oluşturur. Giriş katmanını, birden fazla konvolüsyon katmanından oluşan öğrenme blokları takip eder. Tablo 1'de her bloğa verilen etiketler (A-I), konvolüsyon katmanı blokları ve bu blokların bağlantı yapıları hakkında bilgi sağlar. Şekil 2'nin sağ tarafında ise her piksel için her sınıfa ait olasılıkların yer aldığı hesaplanmış bulut sınıfları gösterilmektedir.

Tablo 1

Bulut Segmentasyonu Mimarisi

Blok	Katman Tipi	Çıkış Boyutu	Atlama Bağlantısı
Giriş	Giriş	{7,8,11} × 508 × 508	
A	3 × 3 conv, relu	32 × 506 × 506	
A	3 × 3 conv, relu	32 × 504 × 504	I
A	3 × 3 conv, stride2	32 × 252 × 252	
B	3 × 3 conv, relu	64 × 250 × 250	
B	3 × 3 conv, relu	64 × 248 × 248	H
B	3 × 3 conv, stride2	64 × 124 × 124	
C	3 × 3 conv, relu	128 × 122 × 122	
C	3 × 3 conv, relu	128 × 120 × 120	G
C	3 × 3 conv, stride2	128 × 60 × 60	
D	3 × 3 conv, relu	256 × 58 × 58	
D	3 × 3 conv, relu, dropout	256 × 56 × 56	F
D	3 × 3 conv, stride2	256 × 28 × 28	
E	3 × 3 conv, relu	512 × 26 × 26	
E	3 × 3 conv, relu, dropout	512 × 24 × 24	
E	3 × 3 deconv, relu	256 × 48 × 48	
F	3 × 3 conv, relu	256 × 46 × 46	
F	3 × 3 conv, relu	256 × 44 × 44	
F	3 × 3 deconv, relu	128 × 88 × 88	
G	3 × 3 conv, relu	128 × 86 × 86	
G	3 × 3 conv, relu	128 × 84 × 84	
G	3 × 3 deconv, relu	64 × 168 × 168	
H	3 × 3 conv, relu	64 × 166 × 166	
H	3 × 3 conv, relu	64 × 164 × 164	
H	3 × 3 deconv, relu	32 × 328 × 328	
I	3 × 3 conv, relu	32 × 326 × 326	
I	3 × 3 conv, relu	32 × 324 × 324	
Çıkış	3 × 3 deconv, relu	5 × 324 × 324	

Tablo 1, CS-CNN modelinin farklı katmanlarını, bu katmanların türlerini, çıkış boyutlarını ve atlama bağlantılarını (skip connection) listelemektedir. Her bir sütunun detaylı açıklaması şu şekildedir:

Blok: CS-CNN modeli, her biri belirli bir işlevi yerine getiren bir dizi konvolüsyon katmanı bloğundan oluşmaktadır. A'dan I'ya her blok, model içinde belirli bir aşamayı temsil eder.

Katman Türü: Bu sütun, her blokta bulunan katmanların türünü belirtir. CS-CNN modeli, aşağıdaki katman türlerini kullanır:

- **Giriş:** Modelin girdi verilerini (çok spektral uydu görüntüleri) temsil eder.
- **conv:** Konvolüsyon işlemi gerçekleştiren katmanları temsil eder. Bu katmanlar, girdi verilerindeki özellikleri çıkarmak için kullanılır. Tablodaki "3x3 conv" ifadesi, 3x3 piksellik bir konvolüsyon çekirdeği kullanıldığını belirtir.
- **relu:** ReLU (Rectified Linear Unit) aktivasyon fonksiyonunu uygulayan katmanları temsil eder. ReLU, modelin doğrusal olmayan ilişkileri öğrenmesini sağlar.
- **stride:** Konvolüsyon işlemi sırasında kullanılan adım sayısını belirtir. "stride 2" ifadesi, konvolüsyon çekirdeğinin her adımda 2 piksel kaydırıldığını gösterir.
- **deconv:** Tersine çevrilmiş konvolüsyon (transposed convolution) işlemi gerçekleştiren katmanları temsil eder. Bu katmanlar, modelin çıkış boyutunu artırmak ve segmentasyon haritasını oluşturmak için kullanılır.
- **dropout:** Aşırı uyumu (overfitting) önlemek için bazı nöronları rastgele olarak devre dışı bırakan katmanları temsil eder.
- **Çıkış:** Modelin son çıkış katmanını temsil eder.

Çıkış Boyutu: Bu sütun, her bloktan sonra elde edilen çıkış verilerinin boyutunu belirtir. Örneğin, "32x506x506" ifadesi, bloğun çıktısının 32 kanal, 506 piksel genişlik ve 506 piksel yükseklik olmak üzere üç boyutlu bir tensör olduğunu gösterir.

Atlama Bağlantısı: Atlama bağlantıları (skip connections), modelin farklı katmanları arasında doğrudan bağlantılar kurarak bilginin daha etkili bir şekilde akmasını sağlar.

Tablo 1, CS-CNN modelinin mimarisini ve her katmanın rolünü anlamak için önemli bilgiler sunmaktadır. Modelin farklı katmanları, konvolüsyon, alt örnekleme ve üst örnekleme işlemleri aracılığıyla girdi verilerini işler ve nihayetinde her pikselin bir bulut sınıfına atandığı bir segmentasyon haritası üretir. Atlama bağlantıları, modelin daha doğru ve sağlam sonuçlar elde etmesine yardımcı olur.

Tablo 2

Sahne İstatistikleri CS-CNN Senaryosu

Sınıf	Doğruluk	HSS	POD	FAR	POFD	Bias
Birleştirilmiş	0.942	0.905				
Bulutsuz	0.961	0.920	0.957	0.047	0.036	1.004
Bulutla Kirlenmiş	0.973	0.885	0.886	0.082	0.013	0.968
Bulutlu	0.950	0.898	0.946	0.060	0.047	1.006
Kar / Buz	0.999	0.824	0,788	0.124	0.0002	0.913

Tablo 2’de, CS-CNN’in örnek sahne için yüksek performanslı olduğu görülmektedir. Birleştirilmiş doğruluk 0.942 ve HSS (Heidke Skill Score) 0.905’tir, bu da modelin bulut ve yüzey tiplerini doğru bir şekilde sınıflandırmada başarılı olduğunu göstermektedir.

- Bulutsuz sınıfı için HSS 0.920’dir, bu da modelin bulutsuz bölgeleri tespit etmede oldukça başarılı olduğunu göstermektedir.
- Bulutla kirlenmiş sınıfı için HSS 0.885’tir ve bu da kısmen bulutlu bölgeleri tespit etmede de iyi bir performans sergilediğini göstermektedir.
- Kar/buz sınıfı için HSS 0.824’tür, bu da kar/buz kaplı bölgeleri tespit etmede nispeten daha düşük bir performansa sahip olduğunu göstermektedir.

CS-CNN’in, örnek sahne için genel olarak iyi bir performans sergilediği görülmektedir. Yüksek doğruluk ve HSS değerleri, modelin bulut ve yüzey tiplerini doğru bir şekilde sınıflandırabildiğini göstermektedir. Bununla birlikte, kar/buz sınıfı için HSS değerinin daha düşük olması, bu sınıfın tespit edilmesinde bazı zorluklar olduğunu düşündürmektedir.

ÇOK KATMANLI ALGILAYICI (MULTILAYER PERCEPTRON, MLP) SİNİR AĞLARI MODELİ

Piksel bazlı sınıflandırmalar için en etkili yapının Çok Katmanlı Algılayıcı (MLP) olduğu belirlenmiştir (Christopher M. Bishop, 1995). MLP, ileri beslemeli yapay sinir ağlarını temel alan bir sınıflandırıcıdır. Bu yapıda, çıkış katmanı hariç tüm algılayıcılar yalnızca ileri yönde bağlanır ve bir katmandaki her algılayıcı bir sonraki katmandaki tüm algılayıcılarla bağlantılıdır (Taravat et al., 2015).

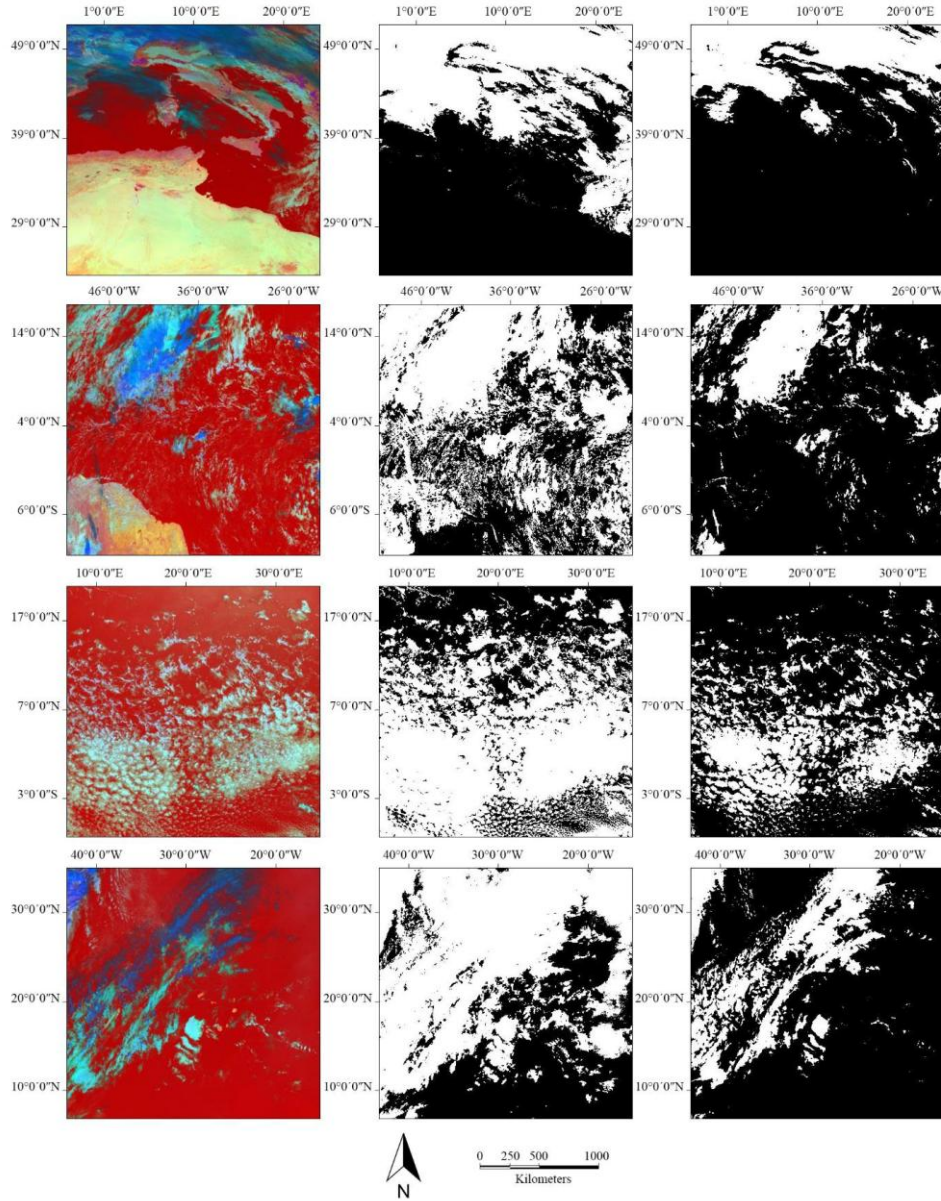
Gün ışığında bulut tespiti için 0,6 ve 0,8 μm görünür bantları, 1,6 μm yakın kızılötesi, 3,9 μm kızılötesi, 6,2 μm su buharı kanalları ve 10,8 μm kızılötesi dahil olmak üzere ek spektral kanal verileri kullanılmıştır (Derrien & le Gléau, 2010). IR 3.9 μm kanalı, alçak bulutların belirlenmesinde kritik bir role sahipken, görünür kanallar aerosol saçılmasını (ör. pus, duman, toz, polen vb.) tespit etmek için gereklidir (Bennouna et al., 2010; Derrien & Le Gléau, 2005). 0,6 ve 0,8 μm 'deki iki görünür kanal, bulutları benzer şekilde tanımlasa da kara yüzeyleri 0,8 μm 'de daha parlak, deniz yüzeyleri ise 0,6 μm 'de daha güçlü bir yansıma gösterir (Bennouna et al., 2010). Bu nedenle, bulutlar ile yüzey hedefleri arasında belirgin bir kontrast sağlamak amacıyla bu iki görünür kanal seçilmiştir.

1,6 μm NIR kanalı, kar, buz ve su bulutlarını ayırt etmek için kullanılırken, su buharı kanalı (6,2 μm) ince bulutların sıcaklık ölçümleri için kullanılmıştır (Bennouna et al., 2010). 10.8 μm kızılötesi kanalı ise, hem yüzey ve bulut tepe sıcaklıklarının hem de volkanik kül ve sirus bulutlarının tespit edilmesinde önemli bir rol oynamaktadır (Prata, 1989).

Makine öğrenimi sınıflandırıcısının sonuçları, EUMETSAT bulut maskesi (CLM) ile karşılaştırıldığında görsel inceleme ile doğrulanmıştır (Şekil 3). MLP sinir ağları, test veri seti üzerinde %88,96 doğruluk oranı ile komisyon (yanlış sınıflandırılan örnekler) ve ihmal (sınıflandırılmayan örnekler) hatalarını sırasıyla %1,68, %3,88 ve %11,04 standart sapma ile hesaplamıştır. Buna karşılık, MPEF CLM için ortalama doğruluk %86,10 olup komisyon ve ihmal hataları sırasıyla %2,47, %7,27 ve %13,90 standart sapma ile ölçülmüştür.

Şekil 3

Meteosat İkinci Nesil SEVIRI Görüntülerinin RGB Kombinasyonu, MLP NN, EUMETSAT Bulut Haritası



Şekil 3'te Meteosat ikinci nesil SEVIRI görüntülerinde bulut tespiti için çok katmanlı algılayıcı sinir ağları (MLP-NN) modelinin etkinliğinin gösterilmesi amaçlanmaktadır. Şekil 3 üç farklı görüntü içermektedir:

Birinci Sütun: 10.8 µm (R), 1.6 µm (G) ve 0.6 µm (B) bantlarının birleştirilmesiyle oluşturulan Meteosat ikinci nesil SEVIRI görüntülerini göstermektedir. Bu renkli kompozit görüntü, bulutların ve yer yüzeyi özelliklerinin görselleştirilmesine yardımcı olur.

İkinci Sütun: MLP sinir ağı modeli tarafından sınıflandırılmış pikselleri göstermektedir. Siyah renk bulutsuz pikselleri, beyaz renk ise bulutlu pikselleri temsil etmektedir.

Üçüncü Sütun: EUMETSAT'ın Meteorolojik Ürün Çıkarma Aracı (MPEF) tarafından sağlanan bulut maskesi ürünlerini gösterir. Siyah renk bulutsuz pikselleri, beyaz renk ise bulutlu pikselleri temsil

etmektedir.

Şekil 3, MLP modelinin EUMETSAT bulut maskesine kıyasla çeşitli koşullar altında kabul edilebilir bulut tespit sonuçları elde ettiğini görsel olarak göstermektedir. Model hem parlak kalın bulutları hem de ince veya daha az parlak bulutları tespit edebilmektedir. Bu gözlem, MLP modelinin SEVIRI görüntülerinden bulutları tespit etmedeki etkinliğini desteklemektedir.

Görsel Karşılaştırma: Şekil 3, MLP modelinin ve EUMETSAT bulut maskesinin sonuçlarını yan yana görselleştirerek doğrudan bir karşılaştırma imkânı sunar. Bu görsel karşılaştırma, iki yöntemin performansını değerlendirmek için temel oluşturur.

MLP Modelinin Başarısı: MLP modelinin görsel incelemeye dayalı olarak kabul edilebilir tespit sonuçları elde ettiği görülmektedir. Bu, modelin gerçek bulut örtüsünü yakalamada başarılı olduğunu göstermektedir.

Kalın ve İnce Bulutların Tespiti: MLP modelinin hem kalın hem de ince bulutları tespit edebildiği görülmektedir. Bu, modelin farklı bulut tiplerini ayırt etme yeteneğini göstermektedir.

Tablo 3

Farklı modeller için farklı modeller için doğrulukların minimum, maksimum ve ortalama değerleri (% olarak).

Model	Mean	Min	Max	St.Dev	MeanComm	MeanOmm
MLP NN	88.96	85	91.8	1.68	3.88	11.04
MPEF CLM	86.10	82	89.2	2.47	7.27	13.90

SONUÇ

Bulut tespiti için, ışımsal transfer simülasyonlarıyla desteklenen sinir ağı tabanlı bir bulut maskesi algoritması, eşiklere dayalı geleneksel yöntemlere kıyasla daha üstün bir performans sergileyen bir çözüm sunmaktadır. Uyarlanabilir yapısı sayesinde, farklı sensörlerle çalışabilir ve bu özelliğiyle uydu uzaktan algılama için değerli bir araç haline gelir. Multispektral uydu verilerini doğru ve verimli bir şekilde işleyerek bulut sınıflandırması yapma potansiyeli taşıyan bir diğer yaklaşım ise CS-CNN yöntemidir. Çok Katmanlı Algılayıcılar (MLP), ileri beslemeli yapay sinir ağı yapıları sayesinde, piksel bazlı sınıflandırma görevlerinde yüksek doğruluk sağlayarak, özellikle uzaktan algılama uygulamalarında güvenilir ve etkili bir çözüm sunmaktadır.

Çok Katmanlı Algılayıcılar (MLP) ve Bulut Segmentasyonu Konvolüsyonel Sinir Ağları (CS-CNN), uzaktan algılama uygulamalarında sınıflandırma ve segmentasyon için iki farklı güçlü yaklaşımdır. MLP, ileri beslemeli yapay sinir ağı yapısıyla, piksel bazlı sınıflandırmalarda yüksek doğruluk sağlayan, nispeten basit ve anlaşılır bir mimariye sahiptir. Bununla birlikte, yalnızca piksel düzeyinde işlem yapması ve mekânsal bağlamı doğrudan kullanamaması, özellikle karmaşık sahnelerde sınırlayıcı olabilmektedir. Öte yandan, CS-CNN, hem mekânsal hem de spektral bilgileri etkili bir şekilde birleştirerek özellik çıkarma gereksinimi olmadan yüksek doğruluklu segmentasyonlar üretmektedir. Bu durum, CS-CNN'yi özellikle bulut maskesi oluşturma gibi daha karmaşık duyarlı uzaktan algılama görevleri için daha yenilikçi ve uyarlanabilir bir yöntem haline getirmektedir. Dolayısıyla, MLP daha basit ve hızlı çözümler için uygunken; CS-CNN, mekânsal detayların ve bağlamsal bilgilerin kritik olduğu senaryolarda üstün bir alternatif sunmaktadır.

REFERENCES

- Ackerman, S., Strabala, K., Menzel, P., Frey, R., Moeller, C., Gumley, L., Baum, B., Seemann, S. W., & Zhang, H. (2006). *Discriminating Clear-Sky From Cloud With Modis Algorithm Theoretical Basis Document (MOD35) MODIS Cloud Mask Team*.
- Aminou, D. M. (n.d.). *The MSG system Comparison LEO and GEO satellites View project Meteosat Third Generation View project*. <https://www.researchgate.net/publication/241275071>
- Bechini, R., & Cremonini, R. (2007). *2007_MSG_cloud_mask_algorithm_validation_using_data_by_MODIS-libre*.
- Benas, N., Finkensieper, S., Stengel, M., Van Zadelhoff, G. J., Hanschmann, T., Hollmann, R., & Meirink, J. F. (2017). The MSG-SEVIRI-based cloud property data record CLAAS-2. *Earth System Science Data*, 9(2), 415–434. <https://doi.org/10.5194/essd-9-415-2017>
- Bennouna, Y. S., Curier, L., Piazzola, J., de Leeuw, G., Roebeling, R., & de Valk, P. (2010). An automated day-time cloud detection technique applied to MSG-SEVIRI data over Western Europe. *International Journal of Remote Sensing*, 31(23), 6073–6093. <https://doi.org/10.1080/01431160903376399>
- Chen, N., Li, W., Gatebe, C., Tanikawa, T., Hori, M., Shimada, R., Aoki, T., & Stamnes, K. (2018a). New neural network cloud mask algorithm based on radiative transfer simulations. *Remote Sensing of Environment*, 219, 62–71. <https://doi.org/10.1016/j.rse.2018.09.029>
- Chen, N., Li, W., Gatebe, C., Tanikawa, T., Hori, M., Shimada, R., Aoki, T., & Stamnes, K. (2018b). New neural network cloud mask algorithm based on radiative transfer simulations. *Remote Sensing of Environment*, 219, 62–71. <https://doi.org/10.1016/j.rse.2018.09.029>
- Choi, Y.-S., Ho, C.-H., Ahn, M.-H., & Kim, Y.-M. (n.d.). *Remote Sensing of Cloud Properties from the Communication, Ocean and Meteorological Satellite (COMS) Imagery*. <https://www.researchgate.net/publication/239847339>
- Christopher M. Bishop. (1995). *Neural Networks for Pattern Recognition*. Clarendon Press.
- Derrien, M., & Le Gléau, H. (2005). MSG/SEVIRI cloud mask and type from SAFNWC. *International Journal of Remote Sensing*, 26(21), 4707–4732. <https://doi.org/10.1080/01431160500166128>
- Derrien, M., & le Gléau, H. (2010). Improvement of cloud detection near sunrise and sunset by temporal-differencing and region-growing techniques with real-time SEVIRI. *International Journal of Remote Sensing*, 31(7), 1765–1780. <https://doi.org/10.1080/01431160902926632>
- Drönner, J., Korfhage, N., Egli, S., Mühling, M., Thies, B., Bendix, J., Freisleben, B., & Seeger, B. (2018a). Fast cloud segmentation using convolutional neural networks. *Remote Sensing*, 10(11). <https://doi.org/10.3390/rs10111782>
- Drönner, J., Korfhage, N., Egli, S., Mühling, M., Thies, B., Bendix, J., Freisleben, B., & Seeger, B. (2018b). Fast cloud segmentation using convolutional neural networks. *Remote Sensing*, 10(11). <https://doi.org/10.3390/rs10111782>
- Hacıbeyoglu, M., Arıcı, F. N., & Karaaltun, M. (2024). Intrusion Detection System Application with Machine Learning. *Afyon Kocatepe University Journal of Sciences and Engineering*, 24(5), 1165–1179. <https://doi.org/10.35414/akufemubid.1455995>
- Hadizadeh, M., Rahnema, M., Kamali, M., Kazemi, M., & Mohammadi, A. (2019). A new method to estimate cloud effective radius using Meteosat Second Generation SEVIRI over Middle East.

- Advances in Space Research*, 64(4), 933–943. <https://doi.org/10.1016/j.asr.2019.05.035>
- Huckle, R. (2009). *Determination of clouds in MSG data for the validation of clouds in a regional climate model*.
- Kacar, M. S., Yumusak, S., & Kodaz, H. (2023). Price Rank Prediction of a Company by Utilizing Data Mining Methods on Financial Disclosures. *Chinese Journal of Epidemiology*, E106D(9), 1461–1471. <https://doi.org/10.1587/transinf.2022OFP0002>
- Kaufman, Y. J., & Nakajima, T. (1993). Effect of Amazon Smoke on Cloud Microphysics and Albedo-Analysis from Satellite Imagery. *Journal of Applied Meteorology and Climatology*, 32(4), 729–744. [https://doi.org/10.1175/1520-0450\(1993\)032<0729:EOASOC>2.0.CO;2](https://doi.org/10.1175/1520-0450(1993)032<0729:EOASOC>2.0.CO;2)
- Key, J. R., & Intrieri, J. M. (2000). *Cloud Particle Phase Determination with the AVHRR*.
- Koçer, S., Sheikh, B., Jama, A., Er, Y., Dündar, Ö. (2022). *A Comparative Study for Evaluating the Performance of Various Classification Techniques on Brain Tumour*.
- Mahović, N. S., & Zeiner, B. (2009). Application of Meteosat SEVIRI channel difference 0.6 μm -1.6 μm in convective cells detection. *Atmospheric Research*, 93(1–3), 270–276. <https://doi.org/10.1016/j.atmosres.2008.10.023>
- Meyer. (n.d.). *MSG Meteorological Products Extraction Facility Algorithm Specification Document*. <http://www.eumetsat.int>
- Oztimur Karadag, O., & Erdas Cicek, O. (n.d.). International Journal of INTELLIGENT SYSTEMS AND APPLICATIONS IN ENGINEERING Empirical Evaluation of the Effectiveness of Variational Autoencoders on Data Augmentation for the Image Classification Problem. *Original Research Paper International Journal of Intelligent Systems and Applications in Engineering IJISAE*, 2020(2), 116–120. <https://doi.org/10.1039/b000000x>
- Prata, A. J. (1989). Observations of volcanic ash clouds in the 10-12 μm window using AVHRR/2 data. In *International Journal of Remote Sensing* (Vol. 10, pp. 751–761). Informa UK Limited. <https://research.ebsco.com/linkprocessor/plink?id=5d07892b-9bcf-3e96-8007-69a0ac95e0c8>
- Rasmussen, M. O., Göttsche, F. M., Olesen, F. S., & Sandholt, I. (2011). Directional effects on land surface temperature estimation from meteosat second generation for savanna landscapes. *IEEE Transactions on Geoscience and Remote Sensing*, 49(11 PART 2), 4458–4468. <https://doi.org/10.1109/TGRS.2011.2144604>
- Saunders, R. W., & Kriebel, K. T. (1988). An improved method for detecting clear sky and cloudy radiances from AVHRR data. *International Journal of Remote Sensing*, 9(1), 123–150. <https://doi.org/10.1080/01431168808954841>
- Svennevik, H., Hicks, S. A., Riegler, M. A., Storelvmo, T., & Hammer, H. L. (2024). A dataset for predicting cloud cover over Europe. *Scientific Data*, 11(1). <https://doi.org/10.1038/s41597-024-03062-0>
- Taravat, A., Proud, S., Peronaci, S., Del Frate, F., & Oppelt, N. (2015). Multilayer perceptron neural networks model for meteosat second generation SEVIRI daytime cloud masking. *Remote Sensing*, 7(2), 1529–1539. <https://doi.org/10.3390/rs70201529>
- Zelinka, M. D., Myers, T. A., McCoy, D. T., Po-Chedley, S., Caldwell, P. M., Ceppi, P., Klein, S. A., & Taylor, K. E. (2020). Causes of Higher Climate Sensitivity in CMIP6 Models. *Geophysical Research Letters*, 47(1). <https://doi.org/10.1029/2019GL085782>
- Zhang, R., Sun, D., Li, S., & Yu, Y. (2013). A stepwise cloud shadow detection approach combining

geometry determination and SVM classification for MODIS data. *International Journal of Remote Sensing*, 34(1), 211–226. <https://doi.org/10.1080/01431161.2012.712231>

EXTENDED ABSTRACT

Introduction: Cloud detection is essential for applications like climate monitoring and weather forecasting, yet traditional methods often struggle in complex scenarios such as snow-covered regions or mixed cloud types. This study investigates advanced machine learning techniques, specifically Multilayer Perceptrons (MLP) and Convolutional Neural Networks (CS-CNN), to improve accuracy and adaptability in cloud classification. CS-CNN integrates spatial and spectral information without relying on predefined features, offering a significant advancement over traditional methods. By analyzing the contributions of specific multispectral bands and comparing methods, this research highlights CS-CNN's potential as a robust tool for remote sensing applications.

Method: This study employs a comparative analysis to evaluate the effectiveness of machine learning techniques, specifically Multilayer Perceptrons (MLP) and Convolutional Neural Networks (CS-CNN), for cloud detection and classification using multispectral remote sensing data. The data includes visible, near-infrared, and thermal infrared bands, carefully selected to capture critical features of clouds and surface conditions. MLP models are trained as pixel-based classifiers, leveraging feedforward architectures to assign cloud classes to each pixel based on spectral characteristics. Conversely, the CS-CNN model incorporates both spectral and spatial information, utilizing convolutional layers to process multispectral images and extract contextual features. Key spectral bands, such as 0.6 μm , 0.8 μm , 1.6 μm , 3.9 μm , 6.2 μm , and 10.8 μm , are analyzed for their contributions to cloud classification. The performance of these models is evaluated against the EUMETSAT cloud mask (CLM) benchmark through metrics such as accuracy, commission, and omission errors. This approach ensures a robust comparison of methods while demonstrating the potential of CS-CNN for enhanced cloud detection in diverse environmental conditions.

Findings: The analysis reveals that Convolutional Neural Networks (CS-CNN) significantly outperform traditional methods and Multilayer Perceptrons (MLP) in cloud detection and classification tasks. CS-CNN effectively integrates spatial and spectral information, achieving higher accuracy and adaptability in complex scenarios, such as snow-covered areas and mixed cloud types. The model demonstrates superior performance, surpassing the EUMETSAT cloud mask (CLM) in accuracy metrics and reducing both commission and omission errors. Additionally, the study highlights the critical role of specific spectral bands, such as near-infrared and thermal infrared channels, in improving classification precision. These findings underscore CS-CNN's potential as a robust and reliable tool for remote sensing applications.

Discussion: The findings highlight the transformative potential of CS-CNN in addressing long-standing challenges in cloud detection and classification. Unlike traditional threshold-based methods and pixel-level classifiers like MLP, CS-CNN excels by integrating spatial context with spectral information, offering greater accuracy and adaptability. The study emphasizes the importance of specific spectral bands, such as near-infrared and thermal infrared, in distinguishing cloud types and surface features. While the results demonstrate clear advantages, the discussion also considers limitations, such as computational complexity, and the need for further validation across diverse sensors and environmental conditions. These insights pave the way for advancing machine learning applications in remote sensing.

Conclusion: This study demonstrates the superiority of Convolutional Neural Networks (CS-CNN) over traditional methods and Multilayer Perceptrons (MLP) in cloud detection and classification using multispectral remote sensing data. By effectively integrating spatial and spectral information, CS-CNN achieves higher accuracy, adaptability, and robustness in complex scenarios, such as snow-covered regions and mixed cloud formations. The critical role of specific spectral bands in enhancing classification performance is also underscored. These findings highlight CS-CNN's potential as a powerful tool for remote sensing applications, offering a significant step forward in improving the accuracy and efficiency of cloud detection methodologies.

Recommendation: It is recommended that future studies explore the scalability and adaptability of CS-CNN across a wider range of sensors and environmental conditions to further validate its robustness. Incorporating additional spectral bands and experimenting with hybrid models combining MLP and CS-CNN could enhance performance in specific scenarios. Researchers and practitioners in remote sensing are encouraged to leverage CS-CNN for cloud detection tasks, particularly in applications requiring high accuracy and spatial context integration, such as climate monitoring, weather forecasting, and environmental analysis.