

Araştırma Makalesi / Research Article  
e-ISSN 2667-4165 (<https://dergipark.org.tr/akuumbd>)

## Gerçek Zamanlı Konveyör Sistemlerinde Fourier Dönüşümü Tabanlı Desen Kontrolü ve Benzerlik Ölçütlerinin Karşılaştırmalı Analizi

Ammar MAHMUTOĞLU<sup>1</sup>

<sup>1</sup> Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, Afyonkarahisar.

e-posta: [ammarmahmutoglu@gmail.com](mailto:ammarmahmutoglu@gmail.com)

Geliş/Received : 30.04.2026 ; Kabul/Accepted : 24.05.2026 ; Revize/Revised : 23.05.2026

### Öz

**Anahtar Kelimeler**  
Fourier Dönüşümü;  
Normalized Cross-Correlation (NCC);  
Cosine Similarity (CS)

Bu çalışma, Fourier dönüşümüne dayalı olarak endüstriyel ortamlarda desen tanıma sisteminin geliştirilmesini amaçlamaktadır. Geliştirilen sistem, hem statik görüntüler hem de gerçek zamanlı videolar üzerinde çalışacak şekilde tasarlanmıştır. Sistem, hareket hızına bağlı olarak belirlenen zaman aralıklarında video akışından kareler almakta, her bir kare için frekans spektrumu çıkarmakta ve bu spektrumları referans bir kare ile karşılaştırarak kusurlu desenlerin tespitini gerçekleştirmektedir. Desen benzerliğinin değerlendirilmesinde kosinüs benzerliği ve normalize çapraz korelasyon (NCC) olmak üzere iki farklı yöntem kullanılmıştır. Operasyonel esneklik sağlamak amacıyla PyQt5 tabanlı bir kullanıcı arayüzü geliştirilmiştir. Deneysel sonuçlar, NCC yönteminden elde edilen bulguların daha yüksek doğruluk sunduğunu ve gerçek koşullara daha yakın sonuçlar ürettiğini göstermektedir.

## Fourier Transform-Based Pattern Control and Comparative Analysis of Similarity Criteria in Real-Time Conveyor Systems

### Abstract

**Keywords**  
Fourier Transform;  
Normalized Cross-Correlation (NCC);  
Cosine Similarity (CS)

This study proposes the development of a Fourier transform-based pattern recognition system for industrial environments. The proposed system is capable of operating on both static images and real-time video streams. In the video processing stage, frames are acquired at time intervals determined by the motion speed of the conveyor or moving object. For each captured frame, the frequency spectrum is extracted and compared with a reference spectrum to identify defective patterns. Pattern similarity is evaluated using two different approaches: cosine similarity and normalized cross-correlation (NCC). In addition, a PyQt5-based graphical user interface is implemented to enhance operational flexibility and usability. Experimental results indicate that the NCC-based approach achieves higher accuracy and yields results that are more consistent with real-world conditions.

## 1. Giriş

Günümüzde veri temelli otomatik karar alma sistemleri, otomasyon ve kontrol uygulamalarında önemli bir konuma sahiptir. Bu sistemler, özellikle PID ve bulanık mantık tabanlı kontrol yaklaşımları çerçevesinde motor kontrolü ve çeşitli dinamik sistemlerin denetiminde yaygın olarak kullanılmaktadır (Sonugür, 2025). Bir otomatik karar alma sisteminin tasarımı üç temel aşamadan oluşmaktadır. İlk aşamada veriler sensörler, kameralar veya farklı kaynaklar aracılığıyla toplanmaktadır. İkinci aşamada elde edilen veriler, verinin türüne bağlı olarak çeşitli veri işleme yöntemleri kullanılarak analiz edilmektedir. Sayısal veriler yapay sinir ağları ile modellenirken, görüntü veya video tabanlı veriler görüntü işleme algoritmaları ile işlenmektedir.

Son aşamada ise makine öğrenmesi, derin öğrenme veya alternatif yaklaşımlar kullanılarak karar verme algoritmaları tasarlanmaktadır. Doğrusal olmayan ve tahmin edilmesi güç veri yapıları için kaotik sistem tabanlı karar alma yöntemleri de kullanılabilir (Keles et al., 2023).

Desen tanıma (pattern recognition), bilgisayarlı görme ve görüntü işleme alanlarının temel araştırma konularından biri olup, farklı nesne ve yapıların otomatik olarak algılanması, ayırt edilmesi ve sınıflandırılması sürecini kapsamaktadır. Günümüzde güvenlik sistemlerinden biyometrik doğrulamaya, endüstriyel kalite kontrolden tıbbi görüntü analizine kadar pek çok alanda aktif olarak kullanılmaktadır. Özellikle artan veri miktarı ve yüksek çözünürlüklü görüntüleme sistemlerinin yaygınlaşması, daha güçlü ve yenilenebilir desen tanıma yöntemlerine olan ihtiyacı artırmıştır (IntKyn. 1).

Geleneksel bilgisayarlı görme yaklaşımlarında, desen tanıma süreci genellikle öznitelik çıkarımı (feature extraction) ve sınıflandırma olmak üzere iki temel aşamada ele alınır. Bu yöntemlerde görüntülerden renk histogramları, kenar bilgileri, köşe noktaları, doku parametreleri ve geometrik şekil özellikleri gibi uzamsal (spatial domain) özellikler elde edilir. Elde edilen bu öznitelikler,

karar ağaçları, en yakın komşu (k-NN), destek vektör makineleri (SVM) gibi klasik makine öğrenmesi algoritmaları kullanılarak sınıflandırılır. Bu yaklaşımda başarımlar büyük ölçüde seçilen özniteliklerin ayırt ediciliğine bağlıdır.

Bununla birlikte, yapay zekâ ve özellikle derin öğrenme tabanlı yöntemler, son yıllarda desen tanıma alanında önemli bir paradigma değişimine yol açmıştır. Bu yaklaşımlarda sistem, belirli bir desene ait ayırt edici özellikleri manuel olarak tanımlamak yerine, büyük veri kümeleri üzerinden otomatik olarak öğrenmektedir. Özellikle evrimsel sinir ağları (CNN) gibi mimariler, görüntü içerisindeki karmaşık örüntüleri çok katmanlı yapıları sayesinde hiyerarşik olarak temsil edebilmekte ve yüksek doğruluk oranları sağlayabilmektedir. Bu yöntemler, karmaşık ve doğrusal olmayan ilişkilerin modellenmesinde geleneksel tekniklere kıyasla daha üstün performans gösterebilmektedir (IntKyn. 2).

Desen tanıma yalnızca uzamsal alanda değil, aynı zamanda frekans alanında da gerçekleştirilebilmektedir. Frekans alanı yaklaşımlarında görüntü, Fourier dönüşümü gibi matematiksel araçlar kullanılarak spektral bileşenlerine ayrıştırılır. Bu dönüşüm sayesinde görüntüdeki periyodik yapılar, yönelimler ve tekrar eden desenler daha belirgin hale gelir. Elde edilen spektrum, görüntünün frekans içeriğini temsil eder ve farklı görüntülere ait spektral temsiller karşılaştırılarak benzerlik analizi yapılabilir. Özellikle belirli frekans bileşenlerinin baskın olduğu desenlerde, frekans alanı analizi ayırt edici ve daha kararlı sonuçlar verebilmektedir.

Spektral temsiller arasındaki benzerlik, korelasyon katsayıları, normalize çapraz korelasyon (NCC) veya kosinüs benzerliği gibi metrikler aracılığıyla nicel olarak değerlendirilebilir. Bu sayede iki desen arasındaki ilişki ve benzerlik derecesi sayısal olarak ifade edilebilmekte ve belirli bir eşik değeri kullanılarak sınıflandırma kararı verilebilmektedir. Frekans alanında gerçekleştirilen karşılaştırmalar, özellikle aydınlatma değişimlerine ve bazı gürültü

türlerine karşı daha dayanıklı sonuçlar sunabilmektedir.

Sonuç olarak, desen tanıma yöntemleri uzamsal alan, frekans alanı ve yapay zekâ tabanlı yaklaşımlar olmak üzere farklı perspektiflerden ele alınabilmektedir. Her yöntemin avantajları ve sınırlılıkları bulunmakta olup, uygulama alanına ve problem yapısına bağlı olarak uygun yöntemin seçilmesi gerekmektedir. Bu çalışma kapsamında, frekans alanı temelli analiz yöntemleri incelenmekte ve Fourier dönüşümü kullanılarak elde edilen spektral temsiller üzerinden desenler arası benzerlik değerlendirmesi gerçekleştirilmektedir. Bu yaklaşımın doğruluğu ve etkinliği, farklı karşılaştırma metrikleri kullanılarak analiz edilmekte ve sonuçlar literatürdeki yöntemlerle karşılaştırmalı olarak sunulmaktadır.

Bu çalışmada, görüntülerin uzamsal (piksel) alanlardan frekans alanına dönüşümü Fourier dönüşümü kullanılarak gerçekleştirilmiş ve elde edilen spektrumlar, benzer desenleri tanımak ve referans desene göre farklı desenleri karşılaştırmak amacıyla Normalized Cross-Correlation (NCC) ve cosine similarity yöntemleri ile analiz edilmiştir. Bu yaklaşım, derin öğrenme yöntemlerinin yerine tercih edilmiştir; çünkü Fourier tabanlı yöntemler daha basit, işlemci üzerinde hafif ve maliyet açısından düşük bir çözüm sunarken, derin öğrenme ve yapay zekâ modelleri genellikle yüksek işlemci gücü ve daha fazla kaynak gerektirmektedir. Dolayısıyla, Fourier dönüşümüne dayalı bu yöntem, özellikle küçük ölçekli işletmelerde uygulanabilirliği ve erişilebilirliği artırmaktadır.


## 2. Materyal ve Metot

Bu çalışmada, görüntüler mekânsal alandan frekans alanına dönüştürülmek üzere Fourier dönüşümü kullanılmıştır. Elde edilen spektrumlar üzerinden desenler arasındaki benzerliklerin analizi için Normalized Cross-Correlation (NCC) ve Cosine Similarity (CS) yöntemleri uygulanmıştır. Bu sürecin etkin bir şekilde yürütülmesi amacıyla PyQt5 kullanılarak bir kullanıcı arayüzü geliştirilmiş ve

makalenin sonunda kullanılan yöntemlerin ayrıntıları sunulmuştur.

### 2.1 Fourier dönüşümü

Fourier dönüşümü, belirli koşullar altında herhangi bir sinyalin farklı frekanslardaki sinüs ve kosinüs bileşenlerine ayrıştırılmasını sağlayan temel bir matematiksel araçtır. Bu özellik sayesinde, sinyalin frekans bileşenleri üzerinden temsil edilmesi mümkün olmakta ve teorik olarak orijinal sinyal, bilgi kaybı veya eklenmesi olmaksızın yeniden elde edilebilmektedir. Fourier dönüşümünün önemli özelliklerinden biri lineerliktir; buna göre, iki sinyalin toplamının dönüşümü, bu sinyallerin ayrı ayrı dönüşümlerinin toplamına eşittir. Ayrıca, zaman alanında üst üste binen sinyaller, frekans alanında ayrıştırılabilmekte; bu durum farklı frekans bileşenlerinin ayırt edilmesini kolaylaştırarak girişim etkilerinin azaltılmasına ve sinyalin daha doğru analiz edilmesine olanak sağlamaktadır (Delsuc & O'Connor, 2024).



Şekil 1. Fourier dönüşümü (IntKyn. 4).

$$f(u) = \int_{-\infty}^{\infty} f(x) e^{-i2\pi\xi x} dx \quad (1)$$

Fourier dönüşümü, bilgisayarlı görme uygulamalarında da etkin bir şekilde kullanılabilir. Bu kapsamda, manyetik rezonans görüntüleme (MRG) verilerinin frekans spektrumunun analizi önemli bir örnek teşkil etmektedir. Özellikle düşük hassasiyet gerektiren durumlarda, Hızlı Fourier Dönüşümü (FFT) algoritmasının performansı, hesaplama maliyeti ile doğruluk arasında bir denge kurulacak şekilde blok boyutunun optimize edilmesiyle iyileştirilebilmektedir (Deveshwar et al., 2026). Fourier dönüşümü, görüntü işleme uygulamalarında

aydınlatma iyileştirme amacıyla da kullanılabilir. Bu bağlamda, frekans alanında genlik bileşenlerinin uygun şekilde ayarlanması ve artırılması, görüntünün parlaklık ve kontrast özelliklerinin iyileştirilmesine katkı sağlamaktadır; zira bu bileşenler görüntüdeki aydınlık seviyeleri ile doğrudan ilişkilidir (Wang et al., 2023).

Frekans alanındaki temsiller, görüntülerden belirli özelliklerin çıkarılmasında yaygın olarak kullanılmaktadır. Bu bağlamda, yüksek frekans bileşenleri genellikle kenarlar ve ince detaylarla ilişkilendirilirken, düşük frekans bileşenleri görüntünün genel yapısını ve aydınlatma bilgisini temsil etmektedir. Bu nedenle, kenar tespiti uygulamalarında yüksek frekans bileşenlerinden yararlanılmakta; gürültü azaltma işlemlerinde ise yüksek frekans bileşenlerinin etkisi bastırılmaktadır. Ancak, yüksek frekansların azaltılması veya düşük frekans bileşenlerine ağırlık verilmesi, görüntüde bulanıklığa ve ince detayların kaybına yol açabilmektedir. Ayrıca, frekans alanı analizine dayalı bu yöntemler, modern derin öğrenme modelleri ile bütünleştirildiğinde, su altı görüntülerinin iyileştirilmesi ve yağmur damllarından kaynaklanan bozulmaların giderilmesi gibi zorlu görüntü işleme problemlerinde etkili sonuçlar sunabilmektedir (Jiang et al., n.d.).

## 2.2 Normalized Cross-Correlation (NCC)

Normalized Cross-Correlation (NCC), desenler arasındaki benzerliği ölçmek ve daha büyük bir görüntü içinde küçük bir deseni tespit etmek için yaygın olarak kullanılan bir yöntemdir. Bu yaklaşım, görüntüdeki piksellerin her birinin bir vektör ögesi olarak temsil edildiği doğrusal bir vektör yapısına dönüştürülmesine dayanır. Ardından her vektör ögesinden ortalama değer çıkarılır ve vektörler arasındaki standart iç çarpım (dot product) hesaplanır. Ortalama değer çıkarma işlemi, NCC'nin aydınlatma değişimlerinden bağımsız olarak çalışabilmesini sağlamaktadır (Ayubi et al., 2024; Lewis, n.d.). Aşağıdaki denklem, NCC yöntemine göre benzerlik ölçümünün hesaplanma prensibini göstermektedir (Lewis, n.d.; Marušić et al., n.d.).

$$Y(u, v) =$$

$$\frac{\sum_{x,y} [f(x, y) - \bar{f}_{u,v}] [t(x - u, y - v) - \bar{t}]}{\sqrt{\sum_{x,y} [f(x, y) - \bar{f}_{u,v}]^2 \sum_{x,y} [t(x - u, y - v) - \bar{t}]^2}} \quad (2)$$

Bu ifade, aşağıda gösterildiği üzere daha basit bir formda temsil edilebilir.

$$NCC = \frac{\sum(I_1 - \mu_1)(I_2 - \mu_2)}{\sqrt{\sum(I_1 - \mu_1)^2 \sum(I_2 - \mu_2)^2}} \quad (3)$$

Hesaplama süresini optimize etmek amacıyla, Integral Image yöntemi kullanılarak NCC uygulanabilir. Bu yaklaşım sayesinde, her piksel için ayrı ayrı işlem yapmak yerine, her görüntü yaması (patch) için yalnızca dört değer kullanılarak benzerlik ölçümü gerçekleştirilebilir; bu da toplam hesaplama süresini önemli ölçüde azaltmaktadır (Lewis, n.d.).

## 2.3 Cosine Similarity (CS)

Cosine similarity (CS), metin veya görsel verileri vektör uzayında temsil ederek benzerlik analizi gerçekleştiren bir yöntemdir. Bu yaklaşımda, veriler çok boyutlu vektörler olarak ifade edilmekte ve benzerlik ölçümü, bu vektörler arasındaki açının kosinüs değeri üzerinden hesaplanmaktadır (Rinjeni et al., 2024; You & Fraiberger, 2025). CS, vektörlerin noktasal çarpımı ve normlarına dayalı olarak NCC ile benzerlik gösterir. Ancak NCC, ortalama çıkarma adımı sayesinde aydınlatma değişimlerine karşı daha dayanıklıdır; bu nedenle CS, NCC'nin basit bir versiyonu olarak değerlendirilemez (Ayubi et al., 2024; Lewis, n.d.). Aşağıda, Cosine Similarity (CS) ölçümünün hesaplanma yöntemi sunulmaktadır (Rinjeni et al., 2024).

$$\cos\theta = \frac{\sum_1^n a_i \cdot b_i}{\sqrt{\sum_1^n a_i^2 \sum_1^n b_i^2}} \quad (4)$$

## 2.4 Benzerlik Eşik Değeri

Mermer desenleri arasındaki benzerlik analizleri, kullanılan yöntemle ilgili olarak farklı eşik değerleri ve doğruluk oranlarıyla değerlendirilmektedir. Karmaşık ve rastgele doğal taş dokularında, piksel bazlı birebir eşleşme yerine yapısal ve istatistiksel benzerlik ölçütleri kullanılmaktadır.

Yapısal benzerlik analizlerinde kullanılan SSIM ve STSIM yöntemlerinde, iki mermer yüzeyinin benzer kabul edilebilmesi için eşik değerinin genellikle %70–%85 (0.70–0.85) aralığında olması yeterli görülmektedir (Zujovic et al., 2013). Fourier dönüşümü tabanlı spektral analizlerde ise aynı sınıfa ait mermerlerin yüksek faz benzerliği gösterdiği, farklı sınıfların ise yaklaşık %64 seviyesinde kaldığı belirlenmiştir. Bu nedenle spektral karşılaştırmalarda karar eşiği yaklaşık 0.64–0.65 olarak kabul edilmektedir (Chanchí-Golondrino et al., 2024). Ayrıca yapay zekâ tabanlı sınıflandırma yöntemleri, mermer desenlerinin tanımlanmasında yüksek başarı sağlamaktadır. Yapay Sinir Ağları (ANN) ve Kendini Düzenleyen Haritalar (SOM) gibi yöntemlerde doğruluk oranlarının %90'ın üzerine çıktığı ve bunun yüksek performans göstergesi olarak değerlendirildiği bildirilmektedir (Hailesslassie et al., 2019). Bu verilere dayanarak, benzerlik eşiğinin alt sınırı %70 olarak belirlenmiş; benzerlik oranı %85'in üzerinde olan örüntüler ise yüksek düzeyde benzerlik gösteren örüntüler olarak değerlendirilmiştir.

## 2.5 PyQt5

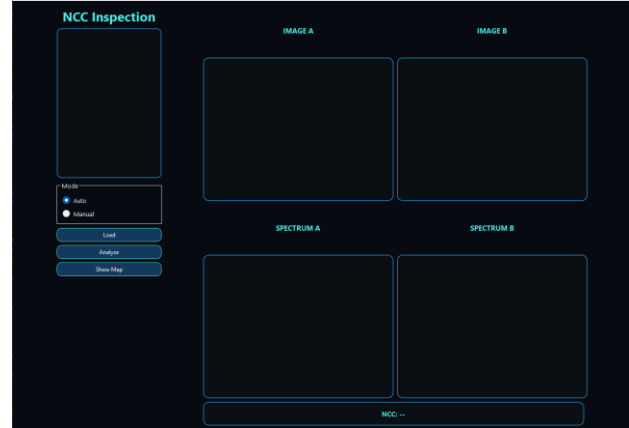
PyQt5, Qt v5 için geliştirilmiş kapsamlı bir Python bağlama (binding) setidir. 35'in üzerinde modül ile uygulanmış olan bu kütüphane, Python'un C++'a alternatif olarak, iOS ve Android de dahil olmak üzere desteklenen tüm platformlarda uygulama geliştirmesine imkân sağlamaktadır. Ayrıca PyQt5, kullanıcıların mevcut C++ tabanlı uygulamaların işlevselliğini yapılandırmasına veya geliştirmesine olanak tanıyacak şekilde bu uygulamalara gömülebilmektedir (IntKyn. 3).

## 3. Bulgular

Bu bölümde, PyQt5 kullanılarak bu çalışma kapsamında geliştirilmiş kullanıcı arayüzü ile NCC ve Cosine Similarity (CS) yöntemleri kullanılarak gerçekleştirilen desen karşılaştırma sonuçları sunulacaktır. Ayrıca, modelin gerçek zamanlı bir simülasyon videosu üzerinde test edildiğinde sergilediği performans da değerlendirilecektir.

### 3.1 Arayüz

Bu çalışma kapsamında özel olarak bir kullanıcı arayüzü tasarlanmış olup, aşağıda sunulmaktadır.

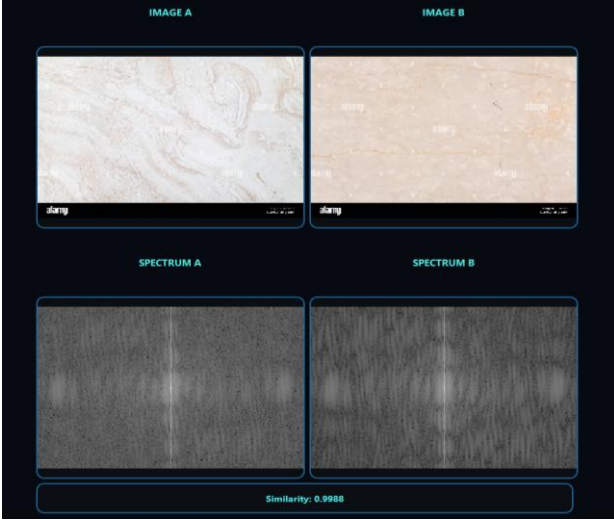


Şekil 2. Sistemin arayüzü.

Şekil 2'de gösterildiği üzere, sistem iki farklı çalışma moduna sahiptir: otomatik ve manuel. Otomatik modda, sisteme bir görüntü kümesi sağlanmakta ve sistem bu küme içerisindeki en benzer iki modeli belirlemektedir. Manuel modda ise, karşılaştırılacak iki model kullanıcı tarafından seçilmekte ve sistem bu modeller arasındaki benzerlik düzeyini hesaplamaktadır. Görüntülerin sisteme yüklenmesi için "Load" butonu kullanılmakta ve ilgili görüntüler veya desenler seçildikten sonra sistemin çalışma modu belirlenmektedir. Otomatik mod seçildiğinde, sisteme yalnızca iki görüntü sağlanması gerekmektedir. Spektrumun elde edilmesi ve benzerlik ölçümünün gerçekleştirilmesi için "Analyze" butonuna basılmaktadır. Bu işlem sonucunda, giriş görüntüleri "IMAGE A" ve "IMAGE B" pencerelerinde, bunlara ait spektrumlar ise sırasıyla "SPECTRUM A" ve "SPECTRUM B" pencerelerinde görüntülenmektedir. Elde edilen benzerlik sonucu, kullanıcı arayüzünün alt kısmında yer alan "NCC" panelinde sunulmakta; ayrıca "Show Map" butonu aracılığıyla benzerlik haritası harici bir pencerede görselleştirilebilmektedir.

### 3.2 Cosine similarity (CS) yönteminin sonuçları

Bu çalışmada, yaklaşık 100 farklı görüntü üzerinde hem CS hem de NCC yöntemleri kullanılarak testler gerçekleştirilmiştir. Kullanılan Veri kümesi, hem benzer hem de görsel olarak farklı desenleri içermektedir. Bu bölümde ise, CS yöntemi kullanılarak elde edilen desen benzerliği sonuçlarına ait bazı örnekler sunulmaktadır.

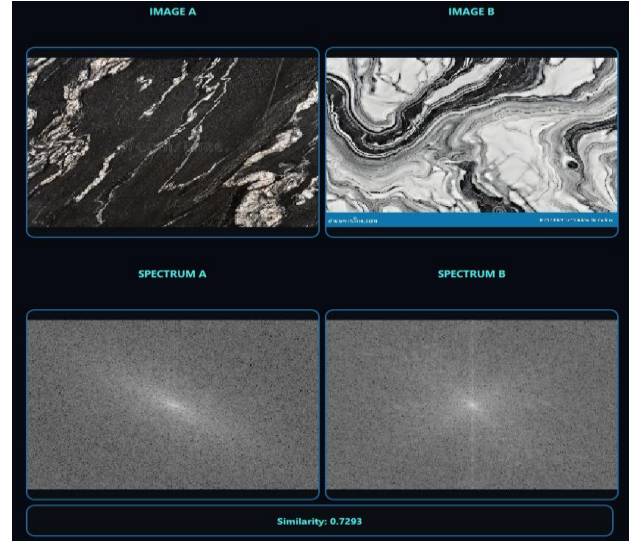


**Şekil 3.** İki desen arasındaki CS benzerlik ölçümü. Şekil 3'te gösterildiği gibi, her iki modelin arayüztrurları birbirine oldukça benzerdir; bu nedenle elde edilen benzerlik oranı bire yakındır. Cosine Similarity (CS) yöntemi, görüntülerin mutlak renk değerlerinden bağımsız olarak desen benzerliğine odaklandığından, iki görüntüdeki piksel ışık yoğunluğu dağılımlarının benzerliğini temsil eden bir benzerlik haritası oluşturulmuştur. Başka bir deyişle, her pikselin gerçek renk değerleri doğrudan karşılaştırılmaz; bunun yerine her bölgedeki ışık değerlerinin dağılım benzerliği değerlendirilir. Yukarıda incelenen iki görüntü arasındaki benzerlik haritası, Şekil 4'te sunulmuştur.




**Şekil 4.** Şekil 3'teki desenlerin ışık değerlerinin dağılım benzerliğini gösteren CS benzerlik haritası.

Şekil 5'te ise, renk özellikleri bakımından farklılık gösteren ve birbirine benzemeyen iki model için Cosine Similarity (CS) yöntemi ile elde edilen sonuçlar sunulmaktadır.



**Şekil 5.** Cosine Similarity (CS) yöntemi ile benzer olmayan iki desen arasındaki benzerlik ölçümü.

Şekil 5'te, iki desenin spektrumlarının nispeten benzer olduğu gözlemlenmektedir; bu durum, renk farklılıklarına rağmen görüntüler arasındaki benzerlik oranında da kendini göstermektedir. İki görüntü arasındaki benzerlik haritası ise Şekil 6'da sunulmuştur.



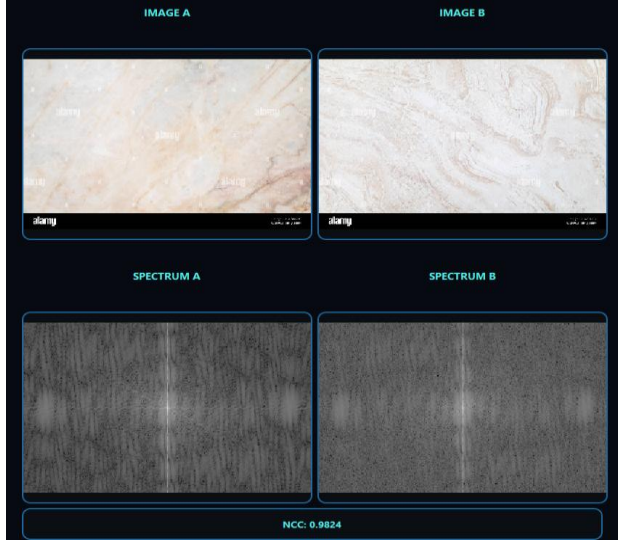
**Şekil 6.** Şekil 5'teki desenlerin ışık değerlerinin dağılım benzerliğini gösteren CS benzerlik haritası.

Yukarıda gösterilen haritada, farklı renkler iki görüntü arasındaki ışık yoğunluğu benzerliğinin derecesini temsil etmektedir. Kırmızı renk yüksek benzerliği, mavi renk ise belirgin farklılığı ifade eder. Yeşil renk, düşük düzeyde bir farklılığı göstermektedir ve her rengin tonları, ilgili benzerlik derecesinin şiddetini yansıtmaktadır.

### 3.3 Normalized cross-correlation (NCC) yönteminin sonuçları

Bu bölümde, Normalized Cross-Correlation (NCC) yöntemi kullanılarak elde edilen sonuçlar

sunulmaktadır. Önceki bölümde izlenen yaklaşıma benzer şekilde, öncelikle birbirine nispeten benzer iki desene ait sonuçlar verilmekte, ardından birbirinden farklı iki desene ilişkin bulgular sunulmaktadır. Şekil 7’de, benzer iki desene ait sonuçlar yer almaktadır.



Şekil 7. Normalized cross-correlation (NCC) yöntemi kullanılarak, birbirine nispeten benzer iki desenin arasındaki benzerlik ölçülmüştür.

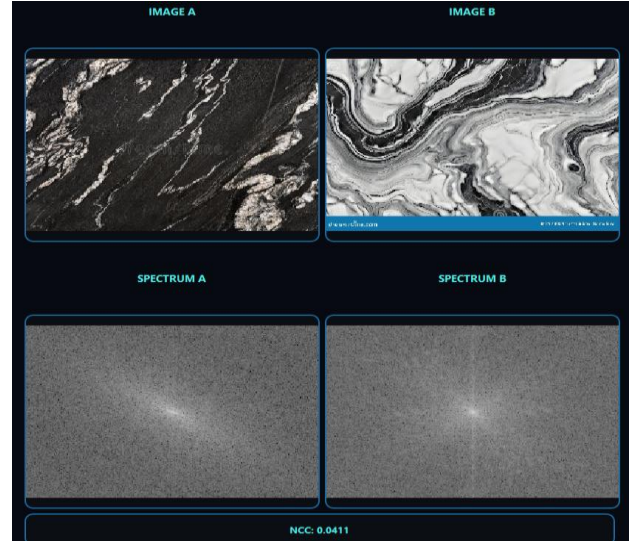
Yukarıdaki incelenen iki desenin ışık değerlerinin dağılım benzerliğini gösteren benzerlik haritası aşağıdaki şekilde gösterilmektedir.



Şekil 8. Şekil 7’deki desenlerin ışık değerlerinin dağılım benzerliğini gösteren NCC benzerlik haritası.


Şekil 8’deki yer alan renk dağılımından da anlaşılacağı üzere, desenler arasında yalnızca yapısal benzerlik değil, aynı zamanda aydınlatma özellikleri bakımından da yüksek düzeyde bir benzerlik bulunmaktadır. Şekil 9’da ise, şekil ve renk özellikleri

açısından nispeten farklılık gösteren iki desen üzerinde NCC yöntemi ile elde edilen sonuçlar sunulmaktadır.



Şekil 9. NCC yöntemi ile benzer olmayan iki desen arasındaki benzerlik ölçümü.

Yukarıdaki şekilde, iki farklı mermer deseni arasındaki karşılaştırma sunulmaktadır. Şekilde görüldüğü üzere, NCC yöntemi, iki mermer deseni arasındaki farklılıkları ayırt etme ve tanımlama konusunda başarılı bir performans sergilemektedir. Bu durum, CS yöntemi ile elde edilen sonuçların aksine, Şekil 5’i inceleyerek açık bir şekilde gözlemlenebilmektedir.








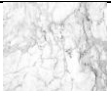



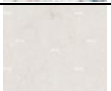







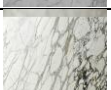


Şekil 10. Şekil 9’teki desenlerin ışık değerlerinin dağılım benzerliğini gösteren NCC benzerlik haritası.

Yukarıdaki NCC benzerlik haritası incelendiğinde, CS benzerlik haritasına kıyasla küçük farklılıklar gözlemlenmektedir; ancak bu farklılık, spektrumlar arasındaki benzerlik oranlarında görülen fark kadar belirgin değildir.

### 3.4 NCC ile CS arasındaki karşılaştırma

Tablo 1’de, her biri iki görüntü içeren on farklı numune üzerinde NCC ve CS yöntemleri kullanılarak gerçekleştirilen testlerin sonuçlarının bazı örnekleri karşılaştırmalı olarak sunulmaktadır.

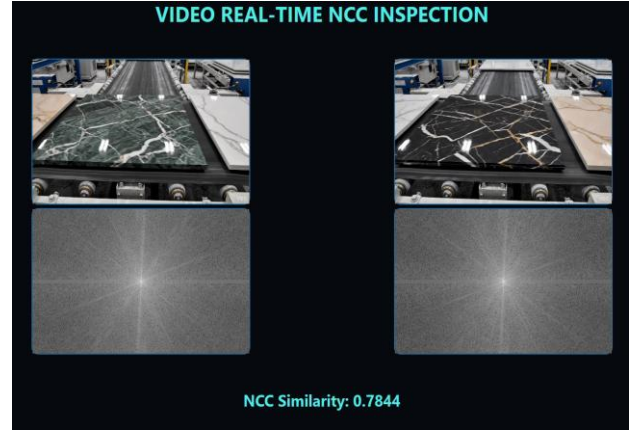
**Tablo 1.** NCC ile CS karşılaştırma tablosu.

Numune NO	NCC	CS	Resim 1	Resim 2
1	0.0538	0.9962		
2	0.0873	0.9961		
3	-0.0309	0.9929		
4	0.0337	0.9901		
5	0.0421	0.9969		
6	0.9974	0.9998		
7	0.9998	1.0000		
8	0.9995	1.0000		
9	0.8567	0.9940		
10	0.9653	0.9986		

Yukarıdaki tabloda sunulan test sonuçlarında, ilk beş örnekte farklı desenler karşılaştırılarak elde edilen bulguların doğruluğu değerlendirilmiştir. Altıncı ile sekizinci örnekler arasında, Fourier dönüşümünün renk bilgisinden ziyade desen özelliklerine odaklandığını göstermek amacıyla, aynı desenlerin farklı renk varyasyonları karşılaştırılmıştır. Dokuzuncu ve onuncu örneklerde ise, yüksek derecede benzerlik gösteren desenler analiz edilmiştir.

### 3.5 Gerçek zamanlı simülasyonu

Bu bölümde, modelin yapay zekâ ile üretilmiş bir video üzerinde gerçekleştirilen gerçek zamanlı simülasyon testine ait sonuçlar sunulmaktadır. Ayrıca, elde edilen sonuca ilişkin bir önizleme şekil 11’de verilmektedir.



**Şekil 11.** Gerçek zamanlı çalışma simülasyonunda NCC yönteminin sonucunu gösteren bir resim.

Modelin doğruluğu, sabit desenler üzerinde test edildikten sonra, gerçek dünya koşullarına yakın bir değerlendirme sağlamak amacıyla zamanın video ile simülasyonu üzerinden Normalized Cross-Correlation (NCC) yöntemi kullanılarak analiz edilmiştir. Yukarıdaki şekilde gösterildiği gibi elde edilen sonuçların yaklaşık doğruluk değeri 0,7844 olarak bulunmuştur.

### 4. Tartışma ve Sonuç

Bu çalışmada, frekans spektrumlarının karşılaştırılması yoluyla desenler arasındaki benzerliğin belirlenmesinde Normalized Cross-Correlation (NCC) ve Cosine Similarity (CS) yöntemlerinin performansı değerlendirilmiştir. Elde edilen bulgular, benzer desenlerin tanınmasında her iki yöntemin de birbirine yakın sonuçlar verdiğini; ancak farklı desenler söz konusu olduğunda daha belirgin ayrışmaların ortaya çıktığını göstermektedir. Bu bağlamda, aydınlatma değişimlerine karşı daha dayanıklı olması nedeniyle NCC yönteminin doğruluğa daha yakın sonuçlar sunduğu gözlemlenmiştir.

Ayrıca, desenler arasındaki piksel tabanlı ışık yoğunluğu farklılıklarını görselleştirmek amacıyla oluşturulan benzerlik haritalarında, NCC ve CS yöntemlerinin büyük ölçüde benzer sonuçlar ürettiği

belirlenmiştir. Gerçek zamanlı uygulamayı simüle etmek amacıyla NCC kullanılarak video tabanlı bir test gerçekleştirilmiş ve elde edilen sonuçlar, yöntemin hesaplama performansı açısından yeterli olduğunu göstermiştir. Bu durum, özellikle küçük ölçekli üretim ortamlarında (örneğin mermer süsleme uygulamaları gibi), referans bir desenin sabitlenerek diğer desenlerle anlık karşılaştırmalar yapılmasına olanak tanıyan pratik ve uygulanabilir bir çözüm sunduğunu ortaya koymaktadır.

Bu yöntem, genellikle yüksek donanım gereksinimleri ve geniş veri kümeleriyle eğitilmiş yapay zeka veya derin öğrenme tabanlı modellerin aksine, düşük donanım gereksinimleri ile uygulanabilir olması açısından önemli bir avantaj sağlamaktadır. Ayrıca, yaklaşık 40–50 ms aralığında gerçekleşen hızlı hesaplama süreci sayesinde gerçek zamanlı uygulamalara uygun bir yapı sunmaktadır. Ön eğitim süreci gerektirmemesi ise özellikle küçük ölçekli üretim ortamlarında maliyet, işlem gücü ve veri hazırlama yükünü azaltarak yöntemin pratik ve alternatif bir çözüm olarak kullanılabilmesine olanak tanımaktadır.

Gelecek çalışmalarda, sistemin doğruluğunu artırmak amacıyla Normalized Weighted Cross-Correlation (NWCC) gibi gelişmiş korelasyon yöntemleri kullanılabilir veya Cosine Similarity ile NCC yöntemlerinin kombinasyonu uygulanarak performans iyileştirilebilir.

## 5. Kaynaklar

A Chanchí-Golondrino, G. E., Ospina-Alarcón, M. A., & Saba, M. (2024). Fourier analysis for detecting vegetation in hyperspectral images. *Ingeniería y Competitividad*, 26(3). <https://doi.org/10.25100/iyc.v26i3.13493>

Delsuc, M. A., & O'Connor, P. (2024). The Fourier transform in analytical science. *Nature Reviews Methods Primers*, 4(1). <https://doi.org/10.1038/s43586-024-00326-2>

Deveshwar, N., Rajagopal, A., & Larson, P. E. Z. (2026). A Mixed Precision FFT with applications in MRI. <http://arxiv.org/abs/2512.04317>

Haileslassie, F., Leta, A., Desalegn, G., & Kalayu, M. (2019). Classification of Marble Using Image Processing. *International Journal on Data Science and Technology*, 5(3), 57. <https://doi.org/10.11648/j.ijdst.20190503.11>

Jiang, X., Zhang, X., Gao, N., & Deng, Y. (n.d.). When Fast Fourier Transform Meets Transformer for Image Restoration. Retrieved <https://github.com/deng-ai-lab/SFHformer>.

Keles, Z., Sonugur, G., & Alcin, M. (2023). The Modeling of the Rucklidge Chaotic System with Artificial Neural Networks. *Chaos Theory and Applications*, 5(2), 59–64. <https://doi.org/10.51537/chaos.1213070>

Lewis, J. P. (n.d.). Fast Normalized Cross-Correlation.

Marušić, D., Popović, S., & Kalafatić, Z. (n.d.). Template Matching in Images using Segmented Normalized Cross-Correlation.

Rinjeni, T. P., Indriawan, A., & Rakhmawati, N. A. (2024). Matching Scientific Article Titles using Cosine Similarity and Jaccard Similarity Algorithm. *Procedia Computer Science*, 234, 553–560. <https://doi.org/10.1016/j.procs.2024.03.039>

Sonugür, G. (2025). Efficient speed control of DC motors: imitation learning with fuzzy logic expert systems. *Automatika*, 66(2), 306–320. <https://doi.org/10.1080/00051144.2025.2480425>

Wang, C., Wu, H., & Jin, Z. (2023). FourLLIE: Boosting Low-Light Image Enhancement by Fourier Frequency Information. *MM 2023 - Proceedings of the 31st ACM International Conference on Multimedia*, 7459–7469. <https://doi.org/10.1145/3581783.3611909>

You, D., & Fraiberger, S. (2025). Evaluating Deduplication Techniques for Economic Research Paper Titles with a Focus on Semantic Similarity using NLP and LLMs. <http://arxiv.org/abs/2410.01141>

Zujovic, J., Pappas, T. N., & Neuhoff, D. L. (2013). Structural Texture Similarity Metrics for Image Analysis and Retrieval. In *IEEE TRANSACTIONS ON IMAGE PROCESSING* (Vol. 22, Number 7).

## **İnternet Kaynakları**

1-Applications of Pattern Recognition - GeeksforGeeks, (18.03.2026)

2-How Does AI Recognize Patterns? A Comprehensive Guide | SaM Solutions, (18.03.2026)

3-PyQt5 · PyPI, (22.03.2026)

4-fourier series – TikZ.net, (15.04.2026)