

ANAHTARLAMALI VE ÖNGÖRÜLÜ VEKTÖR KUANTALAMA İLE ÇOK ÇÖZÜNÜRLÜKLÜ GÖRÜNTÜ SIKIŞTIRMA

Mehmet YAKUT, Sıtkı ÖZTÜRK, Cihan KARAKUZU

Kocaeli Üniversitesi, Mühendislik Fakültesi, Elektronik ve Haberleşme
Mühendisliği Bölümü, İZMİT, e-posta: myakut@kou.edu.tr,
sozturk@kou.edu.tr, cihankk@kou.edu.tr

ÖZET

Bu çalışmada çok çözünürlüklü görüntü temsili için piramit temsildekine benzer şekilde, yeni vektör oluşturma biçimi önerilmiştir. Burada tanımlanan yeni vektör oluşturma biçimi ile ardışıl vektör bileşenleri arasında yüksek öngöretilibilirlik elde edilmektedir. Ayrıca önerilen vektör biçimi için anahtarlamalı kod tablolu, öngörüülü vektör kuantalama yöntemi geliştirilmiştir. Düşük çözünürlük düzeyine ilişkin vektör kuantalanmış bilgi kullanılarak daha yüksek çözünürlük düzeyine kullanıcı istegine bağlı olarak geçirilmektedir. Geliştirilen yöntem yavaş internet servisleri üzerinden görüntülerin kullanıcı isteği ile kademeli olarak yüksek çözünürlük düzeylerinde izlenmesi, düşük iletim hatları üzerinden suçlu görüntülerinin bulunduğu geniş veri tabanlarında hızlı görüntü arama gibi uygulamalarda kullanmaya uygundur.

Anahtar Kelimeler: Vektör Kuantalama, Çok Çözünürlüklü Görüntü Temsili, Özelliğ Tabanlı Kuantalama, Görüntü Sıkıştırma

MULTISCALE IMAGE REPRESENTATION USING SWITCHED CODEBOOK PREDICTIVE VECTOR QUANTIZATION

ABSTRACT

In this study different vector formation is proposed for multiscale image representation similar to pyramidal representation. Using the vector formation described here higher predictability assured between successive vectors. Switched codebook predictive vector quantizer is developed for the proposed vector formation. User selectable high resolution images are obtained using the information carried on low resolution vector quantized images. The method used here is useful for applications like fast search on criminal database over low rate transmission lines and user selectable progressive viewing of images on slow internet services.

Keywords: Vector Quantization, Multiscale Image Representation, Feature Based Quantization, Image Compression.

1. GİRİŞ

Vektör kuantalama veri iletim hızı-bozulma (rate-distortion) teorisine göre veri sıkıştırma işlemi için kullanışlı bir yöntemdir [1]. Kaynak belleksiz olsa bile skaler kuantalama yerine vektör kuantalama kullanarak daha yüksek başarımlı elde edilebilir [2]. Vektör kuantalama yüksek boyutlarda rasgele biçimli kuantalama bölgelerinin kullanılabilmesine imkan sağlar. Vektör kuantalama yöntemleri, kodvektörlerin en iyi yerleşimi ile lineer bağımlılık ötesinde, tekdüzeligin kaldırılması potansiyeline sahiptir [3]. Bununla birlikte vektör boyutu arttıkça kodvektör tablolarının eniyilemesi için maliyet üstel olarak artmaktadır. Bu yüzden çoğu vektör kuantalama uygulaması küçük vektör boyutları (4x4, 8x8 gibi) ile sınırlanmıştır [4].

Durağan görüntülerin iletimi etkileşimli görüntü sıkıştırma açısından önemli bir konudur. Görüntülerin tarama ile iletiminde, gözlemci bir görüntüyü anlayabilmek için tüm satırların gelmesini beklemek zorundadır. Çok çözünürlüklü görüntü temsili ve piramit kodlamadaki gibi sıkıştırma ile önce görüntünün anlaşılabilir düşük çözünürlüklü bir örneğinin gönderilmesi ve eğer gözlemci daha kaliteli bir görüntü isterse, daha yüksek çözünürlük düzeyine sahip görüntünün iletimi sağlanmaktadır. Daha yüksek çözünürlük düzeyi için iki çözünürlük düzeyi arasındaki farklar gönderilerek bir önceki düzeye ilişkin bilgi kullanılmaktadır [5]. Bu yaklaşımda düşük çözünürlük düzeyine sahip görüntü asıl görüntünün genel özelliklerini taşımakta ve yüksek çözünürlüklü görüntü ise yerel özellikleri (küçük değişiklikler ve detaylar) taşımaktadır.

Belli özellikteki görüntülerin taranması gerekiğinde ve geniş görüntü veritabanlarında bir nesnenin aranması söz konusu olduğunda çok çözünürlüklü görüntü temsili ve kademeli görüntü iletimi önemli bir konu olarak karşımıza çıkmaktadır. Düşük ve yüksek çözünürlüklü görüntülerin vektör kuantalanarak temsil edilmesi geniş görüntü veritabanlarının iletiminde iletim bit hızını önemli ölçüde azaltmaktadır. Gerektiğinde asıl görüntü ile yüksek çözünürlüklü görüntü arasındaki bozulma bilgisi de örneğin, Huffman gibi değişken uzunluklu bir kodlama metodu ile kodlanarak asıl görüntü elde edilebilmektedir.

Vektör kuantalama, vektör boyutu büyütüldükçe iletim hızı-bozulma sınırına yaklaşıldığı için ilgi çekmektedir [3,5]. Çok sıkıştırma uygulamasının temel sıkıntısı karmaşıklık, hesap ve bellek maliyetidir. Hesaplama ve bellek

İhtiyacı iletim hızı ve bozulma ile üstel olarak artmaktadır. Yapısal olmayan vektör kuantalama uygulamalarında kodvektör tabloları görüntü veritabanı karakteristiklerinin tümünü temsil edebilmek için eğitilir [6]. Çoğu zaman yerel karakteristiklerin ihmali edilmesi gerekmektedir. Ancak çok çözünürlüklü görüntü temsili kullanıldığında düşük çözünürlüklü görüntü asıl görüntüye ilişkin genel özellikler taşıırken, yerel özelliklerle ilgili çok kaba bilgi içermektedir [7]. Genelde görüntüye ilişkin detaylar düşük genlikli olup, düşük çözünürlüklü görüntü ile asıl görüntünün farkı şeklinde ele alınmaktadır [1]. Bu çalışmada, düşük çözünürlüklü görüntü görüntüye ilişkin detayların kodlanmasında kullanılan kodvektör tablolarının seçiminde belirleyici rol oynamaktadır. Kaba yerel görüntü özellikleri, yapay sinir ağları yardımıyla, ince detayların temsilinde kullanılacak kodvektör tablolarını belirlemektedir. Yapay sinir ağları yerine düşük çözünürlüklü görüntüdeki vektöre ilişkin ortalama ışık yoğunluğu, vektör bileşenlerindeki hareketlilik, yönlü varyanslar kodvektör tablolarını belirlemekte kullanılmıştır. Aksi takdirde düşük çözünürlüklü görüntüdeki hangi özellik için kaç bit kullanılacağı ve bunların en iyilemesi de ayrı bir problem olarak karşımıza çıkacaktır [9].

2. YENİ VEKTÖR OLUŞTURMA BİÇİMİ VE ÖNGÖRÜLÜ VEKTÖR KUANTALAMA İLE KULLANILMASI

Burada gerçekleşen vektör kuantalama uygulamasında ardışıl vektörlerin bileşenleri arasındaki öngörülebilirlik yeni vektör oluşturma yöntemi ile arttırlılmıştır. Yeni vektör oluşturma biçiminde vektör için ilişki azalmakla birlikte (bu azalma çok çözünürlüklü temsil yöntemleri için kaçınılmazdır), fark vektör bileşenleri için skaler öngörülebilirlik ve buna paralel fark kodvektör tablolarında özel bir kümelenme yapısı olmaktadır. Düşük çözünürlüklü görüntüden seçilerek kuantalanan vektör aynı zamanda fark kodvektör tablolarının seçilmesinde tabii seçici rolü üstlenmektedir. Yeni vektör oluşturma yaklaşımında ardışıl vektörlerin tüm bileşenleri birbirleri ile bitişik olduğundan, kuantalanacak vektörün bileşenleri önceden kuantalanmış vektör ve vektörlerden öngörülmektedir. Öngörüde kullanılacak vektör sayısı hesaplama maliyeti kodlama sistemini aşırı yüklemeyecek şekilde seçilmektedir. Bu yöntemle iki boyutlu karmaşık vektör öngörü yöntemleri yerine kayıpsız JPEG görüntü sıkıştırmada

kullanılan basit öngörü yaklaşımının kullanılabilmesi önemli bir avantajdır. Fark kodvektör tablolarının seçimi her kodvektör tablosu birbirinden bağımsız eğitildiğinden aşırı hesaplama maliyeti getirmemektedir. Bağımsız kod vektör tablosu eğitimi eğitim zamanından da avantaj sağlamaktadır. Kuantalama için kullanılacak en uygun kodvektör de yalnızca yapay sinir ağı tarafından seçilen kodvektör tablosunda arandığından kodvektör arama zamanı azalmaktadır.

Gerçeklenen uygulamada başlangıç kodvektörü ile yapay sinir ağı kullanılarak fark kodvektör tablosu seçilmekte ve izleyen 15 vektör için aynı fark kodvektör tablosu kullanılmaktadır. Yapay sinir ağı kullanarak izleyen her vektör için fark kodvektör tablosu seçme işlemi gerçekleştirilebilmektedir. Bu yolla yerel özelliklere bağlı olarak fark kodvektör tabloları arasında geçişler yapılmaktadır. Ancak bu yaklaşım vektör kuantalayıcı eğitim sürecini aşırı derecede uzatmaktadır ayrıca kuantalama hızını yavaşlatmaktadır. Uygulamada fark kodvektör tablosu sayısı düşük çözünürlüklü görüntünün kuantalanmasında kullanılan kodvektör sayısı kadar olabilmektedir. Özellikle eğitim seti boyutları küçükse, gerekenden fazla sayıda kodvektör tablosu kullanmak fark kodvektör tablolarında bir çok kodvektör boşta kalmasına ve bunlara rasgele değer atanmasına neden olmaktadır. Eğitim seti büyük seçildiğinde ise eğitim süreci çok uzun zaman almaktadır. Bu yüzden kuantalanacak görüntüleri yeterince temsil edecek farklılıkta görüntü eğitim seti olarak kullanılarak uygun eğitim gerçeklenebilir. Uygulamada yapay sinir ağı kullanarak kodvektör tablosu seçme işlemi cod tablosu belleğinin etkin olarak kullanılabilmesine ve kodvektör tablosu boyutu yanında bozulma düzeyi seçiminde esneklik kazandırmaktadır [10].

2.1. Vektör Oluşturma İşlemi:

Bu çalışmada kullanılan vektör oluşturma yöntemi Şekil 1'de görülmektedir. '0' ile numaralandırılmış kutucuklar başlangıç vektörünü göstermektedir. '1' ile numaralandırılmış kutucuklar bir sonraki kuantalanacak vektörü ve diğer numaralı kutucuklar da sırasıyla izleyen vektörleri göstermektedir. Bu vektör oluşturma yöntemi ile ardışıl vektörlerin bileşenlerinin birbirlerinden öngörülebilirliği artmaktadır. Aynı zamanda ilk vektör izleyen vektörlere ilişkin yapısal genel bilgi taşıdığından farklıların kuantalanmasında kodvektör tablosu seçici işlevi görmektedir. Başlangıç vektörü herhangi köşeden başlayarak da seçilebilmekte izleyen vektörler zikzaklar ile oluşturulabilmektedir.

9	10	11	12	9	10	11	12	9	10	11	12	9	10	11	12
8	1	2	13	8	1	2	13	8	1	2	13	8	1	2	13
7	0	3	14	7	0	3	14	7	0	3	14	7	0	3	14
6	5	4	15	6	5	4	15	6	5	4	15	6	5	4	15
9	10	11	12	9	10	11	12	9	10	11	12	9	10	11	12
8	1	2	13	8	1	2	13	8	1	2	13	8	1	2	13
7	0	3	14	7	0	3	14	7	0	3	14	7	0	3	14
6	5	4	15	6	5	4	15	6	5	4	15	6	5	4	15
9	10	11	12	9	10	11	12	9	10	11	12	9	10	11	12
8	1	2	13	8	1	2	13	8	1	2	13	8	1	2	13
7	0	3	14	7	0	3	14	7	0	3	14	7	0	3	14
6	5	4	15	6	5	4	15	6	5	4	15	6	5	4	15
9	10	11	12	9	10	11	12	9	10	11	12	9	10	11	12
8	1	2	13	8	1	2	13	8	1	2	13	8	1	2	13
7	0	3	14	7	0	3	14	7	0	3	14	7	0	3	14
6	5	4	15	6	5	4	15	6	5	4	15	6	5	4	15

Yüksek çözünürlük düzeyi
görüntü bloğu (16x16)

X _{n0}	X _{n0}	X _{n0}	X _{n0}
X _{n0}	X _{n0}	X _{n0}	X _{n0}
X _{n0}	X _{n0}	X _{n0}	X _{n0}
X _{n0}	X _{n0}	X _{n0}	X _{n0}

Düşük çözünürlük düzeyi
görüntü bloğu (4x4)

Şekil 1. Yeni spiral tarama biçimli vektör oluşturma

2.2 Yapay Sinir Ağı İle Kodvektör Tablosu Seçimi:

Kendinden düzenli özellik alanları prensibi ile çalışan kodvektör tablosu seçici yapay sinir ağlarının özel bir sınıfıdır. Bu ağ türünde öğrenme işlemi yarışa dayalı olup aynı sınıfa ait girişler için yalnızca bir yapay sinir ağı hücresi aktif olmaktadır [12]. Yarışa dayalı öğrenme kuralı, kazanan hepsini alır kuralı olarak da bilinir. Yapay sinir ağı hücreleri yarışa dayalı eğitim süreci ile çeşitli giriş sınıflarına göre ayarlanır [13]. Bu çalışmada yarışa dayalı öğrenen yapay sinir ağı önceden kodlanan kodvektörün taşıdığı bilgiyi kullanarak fark kodvektör tablosunu seçmek üzere eğitilmektedir.

Kendinden düzenli özellik alanları tabanlı yapay sinir ağı da bir tür vektör kuantalayıcı olarak değerlendirilebilir, bu ağ yapısı literatürde öğrenen vektör kuantalayıcı olarak da isimlendirilmektedir [14]. Kazanan hücre giriş vektörü x ile w_i ağırlıkları arasındaki öklid uzaklığı yardımıyla belirlenir (Eşitlik.1). Kazanan (en yakın öklid uzaklığındaki) hücreye ilişkin ağırlıklar w_i eşitlik 2 yardımıyla güncellenir. Burada η öğrenme oranını göstermektedir.

$$i(x) = \arg \min \|x(n) - w_j\| \quad \text{for } j = 1, 2, \dots, N \quad (1)$$

$$w_j(n+1) = \begin{cases} w_j(n) + \eta(n)[x - w_j(n)] & \text{j. hücre aktif ise} \\ w_j(n) & \text{diger durumda} \end{cases} \quad (2)$$

Bu çalışmada 16 girişli ve 4, 8, 16, 32, 64 çıkışlı yapay sinir ağları eğitilerek kodvektör tablosu seçiminde kullanılmıştır. Öğrenme hızı başlangıçta 0.05 seçilerek eğitim adımları ilerledikçe 0.0001 kadar düşürülmüştür. Güncellemeye işlemindeki bir kısıtlama herhangi bir hücreye ilişkin ağırlıklar toplamının 1'e eşit olmasıdır. Aynı zamanda ağırlıkların ve girişin 1'e normalize olduğu varsayılmaktadır [13].

3. ÇOK ÇÖZÜNÜRLÜKLÜ GÖRÜNTÜ TEMSİLİ İÇİN ANAHTARLAMALI VE ÖNGÖRÜLÜ VEKTÖR KUANTALAYICI

Görüntü önce düşük ve yüksek çözünürlüklü bileşenlere ayrılır. Asıl görüntü alçak geçiren filtreden geçirilerek $\frac{1}{4}$ oranında seyrek örneklenir. Alçak geçiren filtre olarak ayrılabilir Gaussian özellikli filtre uygulanmıştır [7]. Önce düşük çözünürlüklü görüntü kodvektör tablosu genel Lloyd algoritması kullanılarak eğitildikten sonra vektör kuantalanır [8,16]. Kodvektör tablosundan en uygun kodvektörün bulunmasında en kısa öklid uzaklığı kriteri kullanılmıştır.

Öklid normuna göre eğer ($d_i < d_j$) tüm j değerleri için ve $d_i = \|x - x_i\|$ ise x giriş vektörü kodvektör x_i ile kuantalanır.

$$\begin{aligned}
 1. \quad \hat{X}(m,n) &= X(m-1,n) \\
 2. \quad \hat{X}(m,n) &= X(m,n-1) \\
 3. \quad \hat{X}(m,n) &= X(m-1,n-1) \\
 4. \quad \hat{X}(m,n) &= X(m,n-1) + X(m-1,n) - X(m-1,n-1) \\
 5. \quad \hat{X}(m,n) &= X(m,n-1) + (X(m-1,n) - X(m-1,n-1))/2 \\
 6. \quad \hat{X}(m,n) &= X(m,n-1) + (X(m,n-1) - X(m-1,n-1))/2 \\
 7. \quad \hat{X}(m,n) &= (X(m-1,n) + X(m,n-1))/2
 \end{aligned} \tag{3}$$

İlk vektör kuantalandıktan sonra fark kodvektör tablosu yapay sinir ağı yardımıyla seçilir ve sonraki vektör ilk vektörden öngörlür. Yapılan öngörü ile asıl görüntü farkı yapay sinir ağı ile seçilen fark kodvektör tablosu kullanılarak kuantalanır. Vektör öngörüsü için eşitlik (3)'te verilen basit JPEG öngörü modlarından uygun olanı kullanılır [4]. Yapılan işlemleri sıralarsak, önce seyrek örneklenmiş görüntüdeki ilk vektör kuantalanır Eşitlik(4). Burada Q(.) kuantalama işlemini ve \hat{X} , X'in kuantalanmış halini göstermektedir.

$$\hat{X}_{LP} = Q(X_{LP}) \tag{4}$$

ve i_n indisli yapay sinir ağına uygulanır, aynı zamanda alıcıya gönderilir veya kaydedilir. Eşitlik (5) yardımıyla kuantalanacak bitişik vektör önceki kuantalanan vektörden öngörlür. Vektörlerin öngörülmesinde kullanılacak vektörler Tablo 1'deki gibi seçilir.

Tablo 1. Öngörü işleminde kullanılan vektörler

Kodlanacak vektör no	Doğrusal öngörü vektörleri	JPEG türü öngörü vektörleri
0	No	no
1	0	0 mod1
2	0,1	0,1 mod7
3	0,1,2	0,1,2 mod5
4	1,2,3	0,3 mod7
5	2,3,4	0,3,4 mod5
6	3,4,5	0,5 mod7
7	4,5,6	0,5,6 mod5
8	5,6,7	0,1,7 mod5
9	6,7,8	1,8 mod7
10	7,8,9	1,8,9 mod 5
11	8,9,10	1,2,10 mod5
12	9,10,11	2,11 mod 7
13	10,11,12	2,11,12 mod 5
14	11,12,13	2,3,13 mod 5
15	12,13,14	3,4,14 mod5

$$\tilde{X}(n+1) = P(\hat{X}_{LP}(n), \hat{X}_{LP}(n-1), \hat{X}_{LP}(n-2)) \quad (5)$$

Eşitlik 5'te $P(\cdot)$ öngörü işlemini, \tilde{X} ise X 'in öngörüsünü göstermektedir. i_n indisli uygulanan yapay sinir ağı yardımı ile en uygun fark kod vektör tablosu seçilerek fark vektör eşitlik (6)'da görüldüğü gibi kuantalanır.

$$\hat{X}(n+1) = Q[X(n+1), \tilde{X}(n+1)], \quad Cb[F(i_n)] \text{ yi kullanarak} \quad (6)$$

Eşitlik 6'da $F(i_n)$, i_n indisli kodvektöre bağlı olarak kodvektör tablosu seçme fonksiyonunu ve $Cb[\cdot]$ seçilen kodvektör tablosunu göstermektedir. Sonuç olarak en uygun farkkodvektör indisli alıcıya gönderilir. Kodvektör tablosu seçiminde ve öngöründe yalnızca seyrek örneklenmiş görüntünün kod vektörleri ve indisleri kullanıldığından ayrıca başlık biti göndermeye gerek yoktur.

4. VEKTÖR BİLEŞENLERİNİN ÖNGÖRÜ HESABI

Bölüm 3'de ele alınan vektör oluşturma yöntemi kolaylıkla L2 normu piramit görüntü temsiline uygulanabilir. L2 normu görüntü temsilinde görüntü alçak geçiren filtreden geçirilir ve her iki boyutta $\frac{1}{2}$ oranında seyrek örneklenecek elde edilir. En düşük çözünürlüklü görüntü (örneğin 32x32) vektör kuantalanır. Sonra birinci düzey ile ikinci düzey arasındaki fark vektörler şekil 1'de görülen öngörü yaklaşımı da kullanılarak kuantalanır. İlk düzey ikinci düzey için başlangıç bilgi kaynağı ve kodvektör tablosu seçici görevi görür. Eşitlik 7, 8, 9, 10'da görüldüğü gibi önceki kuantalanan vektörlerin taşıdığı bilgi kuantalanacak vektörün öngörüsünde kullanılmaktadır. Şekil 1'de ki önerilen vektör oluşturma yapısı kullanılarak kuantalanacak vektör bileşenleri, yalnızca komşu noktalar yardımıyla, hassas bir yaklaşıkla öngörülebilir.

Eşitlik 7'de görüldüğü gibi x_0 vektör bileşeni öngörtürken yalnızca x_{n0} bileşeni kullanılmaktadır. Sonraki vektör bileşeninin öngörüsünde ise x_1 bileşeni eşitlik 8'de görüldüğü gibi x_0 ve x_{n0} 'dan öngörmektedir. Benzer şekilde sonraki vektör bileşenleri x_2 ise x_1 , x_2 ve x_{n0} dan öngörmektedir ve x_3 de eşitlik 9'daki gibi en yakın komşu noktalar kullanılarak öngörmektedir. Benzer şekilde x_6 eşitlik 13'deki gibi x_5 ve x_0 dan öngörmektedir.

$$\tilde{x}_0 = x_{n0} \quad (7)$$

$$\tilde{x}_1 = \frac{\hat{x}_0 + x_{n0}}{2} \quad (8)$$

$$\tilde{x}_2 = \frac{\hat{x}_1 + \hat{x}_0 + x_{n0}}{3} \quad (9)$$

$$\tilde{x}_3 = \frac{\hat{x}_2 + \hat{x}_1 + \hat{x}_0}{3} \quad (10)$$

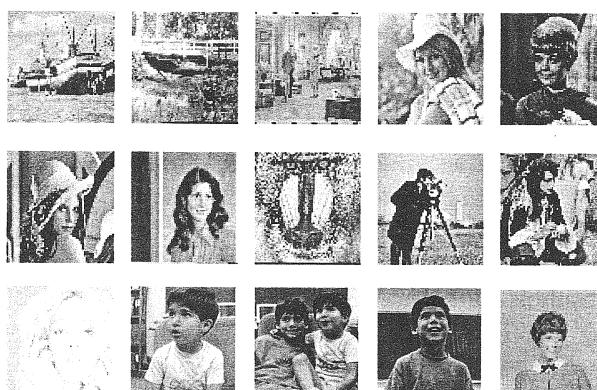
$$\tilde{x}_4 = \frac{\hat{x}_3 + \hat{x}_0}{2} \quad (11)$$

$$\tilde{x}_5 = \frac{\hat{x}_3 + \hat{x}_4 + \hat{x}_0}{3} \quad (12)$$

$$\tilde{x}_6 = \frac{\hat{x}_5 + \hat{x}_0}{2} \quad (13)$$

Çok çözünürlüklü görüntü temsili kullanıldığından iletim hattının uzak ucundaki gözlemci görüntünün bir sonraki düzeyinin iletimi için karar verebilmekte ve bu bize iletim kanalının verimli kullanılmasını sağlamakta ve gereksiz beklemeleri ve veri aktarımını önlemektedir. Aynı zamanda gözlemci kısa sürede tek ekranada birçok görüntüyü izleyerek, ilgilendiği

görüntüyü belirleyip daha detaylı görme imkanına kavuşturmaktadır. İletim kanalı gerekmedikçe detay bilgilerin aktarımı için kullanılmamaktadır ve kanalın kullanım etkinliği artmaktadır. Önerilen vektör kuantalama için şekil 4'deki blok diyagramı kullanılmaktadır. Benzer şekilde kullanılacak kod çözücü yapısında da bir değişiklik olmayacağından emin olabiliriz.



Şekil 2. Kod tablosu eğitiminde kullanılan görüntü örnekleri ve birden fazla görüntünün birlikte gösterilmesi

5. SONUÇLAR VE DEĞERLENDİRME

Öngörülü vektör kuantalama kullanılarak çok çözünürlüklü görüntü temsili sağlanmış ve genel vektör kuantalama ile karşılaştırıldığında görüntüye bağlı olarak 1.1dB ile 2.2dB tepe işaret gürültü oranında iyileşme sağlanmıştır. Bunun yanında çok çözünürlüklü yapının sağladığı avantajlar ile gereksiz veri iletiminin önlenmesi ve grup görüntülerin hızlı gözlenmesi olanağı elde edilmiştir. Geliştirilen yöntemle 64 ve üzeri kodvektör tablosu boyutları ve 16 ve üzeri fark kodvektör tablosu sayısı için oldukça verimli sonuçlar elde edilmiştir. 16 fark kodvektör tablosu kullanılarak elde edilen sonuçlar tablo 2'de gösterilmiştir. Tablo 2 kodvektör tablosu boyutlarına göre düzenlenmiştir. Sonuçların tam değerlendirmesi için tablo 2'de gösterilen sonuçlarda düşük çözünürlüklü görüntülere ilişkin kullanılması gereken başlık bitleri dikkate alındığında Lena görüntüsü için tablo 2'deki koyulaştırılmış değerler kullanılmıştır. Diğer görüntüler için de aynı satır kaymaları ile daha gerçekçi değerlendirme yapılmıştır. Vektör bileşenlerini birbirlerinden ayrı seçerek azalan vektör içi ilişki çoklu kodvektör tablosu kullanılarak giderilmiştir. 4'den fazla sayındaki kodvektör tablosu sayısı için genel vektör kuantalamadan daha iyi sonuçlar elde edilmektedir. 16 kodvektör tablosu kullanıldığından kuantalanacak görüntüye bağlı olmakla birlikte ortalama 1.5dB tepe işaret gürültü oranı iyileşmesi sağlanmaktadır.

Bu uygulamada kodvektör tablosu sayısı 256'ya kadar artırılabilir, ancak bunun için eğitim setinin büyütülmesi gerekmektedir. Eğitim seti büyütüldüğünde eğitim süreci çok uzun sürmektedir. Aynı eğitim seti kullanıldığında ise kullanım dışı kalarak, rasgele değerler alan vektörler bulunmaktadır. Ancak kodvektör tablosu sayısının artırılması eğitim sürecini uzatmak ve bellek gereksinimini artırmak dışında başarıım üzerinde hiçbir olumsuz etki üretmez.

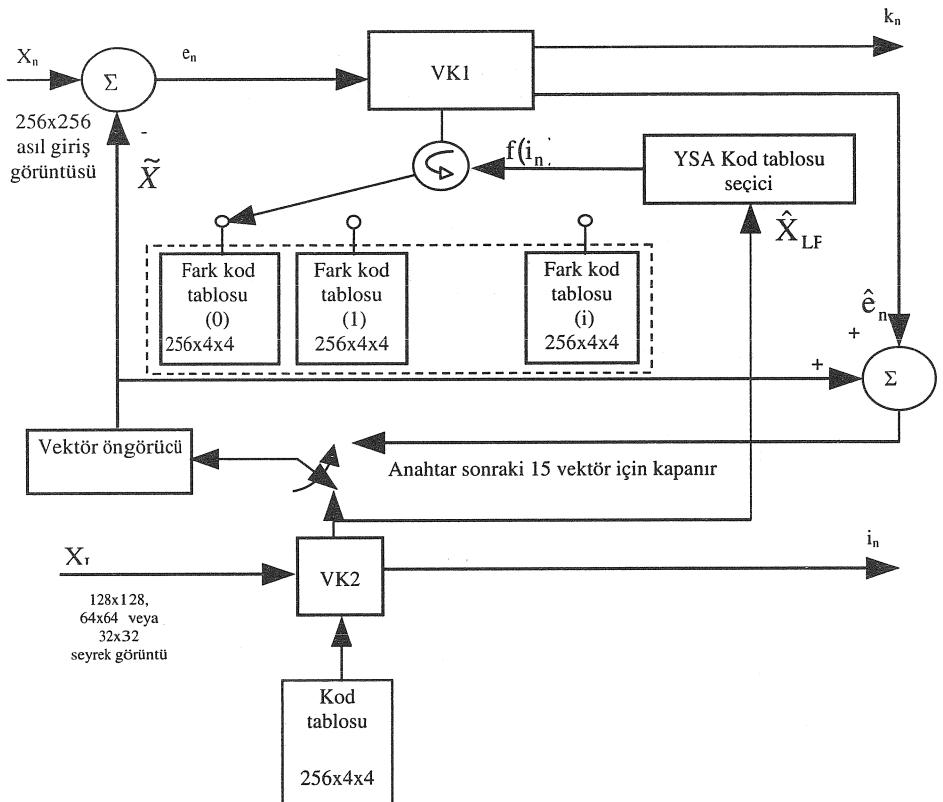
Cök çözünürlülü görüntü temsili gerksiz veri iletiminin sistem üzerinde zararlı etkileri olduğunda kullanılması kaçınılmaz bir durumdur. Geliştirilen bu uygulama için gözlemci kabaca izlediği görüntülerden detayları görmek istemedigine karar vermesi durumunda yaklaşık 15 düşük çözünürlüklü görüntü iletim zamanı kazanılmış olmaktadır. Ayrıca kayıpsız JPEG'de kullanılan ve çarpma işlemi gerektirmeyen basit öngörü yaklaşımı ile yeterince iyi sonuçlara ulaşılabilmektedir. Yöntem daha genel ve geniş bir eğitim seti ile eğitilirse, genel vektör kuantalama uygulamalarından daha başarılı sonuçlar veren, genel en iyi kodvektör tablosu için bir alt küme elde edilebilir.

Tablo 2. Geliştirilen vektör kuantalayıcı için 16 kodvektör tablosu kullanıldığından elde edilen sonuçlar (değerler tepe işaret gürültü oranı dB olarak verilmiştir)

Kodvektör Tablo_boyutu	Görüntü	GLA VQ_yöntemi (dB)	Geliştirilen_VQ Yöntemi
32	Elaine	26.40dB	28.38dB
32	Lena	24.86dB	26.25dB
32	Boat	24.22dB	25.43dB
64	Elaine	27.16dB	29.15dB
64	Lena	25.80dB	27.18dB
64	Boat	24.86dB	26.07dB
128	Elaine	28.20dB	30.36dB
128	Lena	26.70dB	28.13dB
128	Boat	25.73dB	26.87dB
256	Elaine	29.18dB	30.96dB
256	Lena	27.59dB	29.32dB
256	Boat	26.49dB	27.72dB



Şekil 3. İki düzeyli (256x256, 64x64) ve dört düzeyli (256x256, 128x128, 64x64, 32x32) çok çözünürlüklü vektör kuantalama için Lena görüntüsüne ilişkin 16 kodvektör tablosu ve 256 kodvektör kullanılarak elde edilmiş sonuçlar



Şekil 4. Çok çözünürlüklü görüntü temsili için geliştirilen anahtarlamalı kod tablosu kullanılan öngörlü vektör kuantalayıcı blok diyagramı

KAYNAKLAR

1. Jain K., Image Data Compression; A Review, Proceedings IEEE, 349-389, (1981).
2. Gersho A., Gray R. M., Vector Quantisation and Signal Compression, Kluwer Academic Publishers, (1992).
3. Gray R. M., Vector Quantisation, IEEE ASSP Magazine (1984).
4. Kunt M., Ikonomopoulos A., Kocher M., Second Generation Image Coding Techniques, Proceedings IEEE,73, (1985).
5. Barnes C. F., Rizvi S. A., Nasrabadi N. M., Advances in Residual Vector Quantisation, IEEE Transactions On Image Processing, (1996).
6. Harry H. M., Woods J. W., Predictive Vector Quantisation of Images, IEEE Transactions on Communications, (1985).
7. Wang L., Goldberg M., Progressive Image Transmission Using Vector Quantisation in Pyramid Form, IEEE Transactions on Comm., 37 (12), 1339-1349, (1989).
8. Lim J. S., 2-D Signal and Image Processing, Prentice Hall, (1990).
9. Linde Y., Buzo A., Gray R. M., An Algorithm for VQ Design, IEEE Transactions on Communications, (1980).
10. Wang L., Rizvi S. A., Nasrabadi N. M., A Modular Neural Network Vector Predictor for Predictive Image Coding, IEEE Transactions on Image Processing, 8(7),1198-1217, (1998).
11. Wegmann B., Zetzche C., Feature Spesific Vector Quantisation of Images, IEEE Transactions on Image Processing, (1996).
12. Kohonen T., Learning Vector Quantisation for Pattern Recognition, Helsinki University of Technology, Finland, (1986).
13. Kohonen T., Self Organisation and Associative Memory, Springer Verlag, Newyork, (1988).
14. Kohonen T., The Self-Organizing Map, IEEE Proceedings, (1990).
15. Nasrabadi N. M., King R. A., Image Coding Using Vector Quantisation: A Review, IEEE Transactions on Comm.,36(8), (1988).

