

PAPER DETAILS

TITLE: Gerçek Zamanlı Endüstriyel Nesne Tanimada Kameraların Kullanılması

AUTHORS: Sedat MELTEK, Bayram ÇETİSLİ

PAGES: 212-217

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/193913>

Gerçek Zamanlı Endüstriyel Nesne Tanımda Kameraların Kullanılması

Sedat METLEK^{*1,2}, Bayram CETİŞLİ¹

¹Süleyman Demirel Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü / ISPARTA

²Mehmet Akif Ersoy Üniversitesi, Burdur Meslek Yüksekokulu / BURDUR

Alınış Tarihi:27.02.2012, Kabul Tarihi:07.07.2012

Özet: Bu çalışmada kameralı bir sistemin renk algılayıcılı bir sisteme göre, gerçek zamanlı nesne tanımda daha hızlı çalıştığı gösterilmektedir. Bu amaç doğrultusunda Festo firmasının ürettiği birbirine bağlı dört deney setine donanımsal ve yazılımsal olarak müdahale edilmiştir. CMOS kamera, görüntü işleme yöntemleri ve Bayes sınıflayıcı kullanılarak nesnelerin daha kısa zamanda ve doğru bir şekilde sınıflandırılması sağlanmıştır. Deney setinin çıkış kısmında yapılan sınıflandırma, PLClerle (Programlanabilir Mantık Denetleyicileri) kontrol edilmektedir. Bu işlem, yeni düzenekte bilgisayarla paralel port üzerinden denetlenmektedir. Elektromekanik kontrollü pnömatik kolların kontrolü için ayrıca bir elektronik sürücü devresi tasarlanmıştır. Renk algılayıcının yerine yerleştirilen renkli kamera ile yaklaşık üç kat daha hızlı bir sınıflandırma başarısı elde edilmiştir.

Anahtar Kelimeler: Endüstriyel otomasyon, gerçek zamanlı görüntü işleme, Bayes sınıflayıcı.

The Use of Cameras for Real-Time Industrial Object Recognition

Abstract: In this study, it is shown that the system with a camera runs faster than a color sensor system in real time. For this purpose, interconnected set of four experiments produced by Festo manufactures have been treated as a hardware and software. By using CMOS camera, image processing methods and Bayesian classifier, the real time object recognition has been achieved more realistic and less time consuming. Classification procedures, located at the outlet of the experimental set, were done with PLCs (Programmable Logic Controller). This operation is controlled with computer using parallel port in the new system. An extra electronic driver circuit is designed for the control of electro-mechanical controlled pneumatic arms. A three time faster classification success is obtained by the camera that is put in the place of color sensor.

Key Words: Industrial automation, real-time image processing, Bayesian classifier.

Giriş


Endüstriyel seri üretimlerde nesnelerin çok hızlı, el değmeden ve doğru bir biçimde sınıflandırılması en önemli problemlerden biridir. Hata belirleme, paketleme, robot kontrol ve kalite kontrol gibi işlem basamaklarında görsel ölçümlere göre bazı önemli kararlar verilmekte ve ürünler bantlar üzerinden yönlendirilmektedir (Lino, 2008).

Renk algılamada, maliyetleri düşürmek için kameralar yerine daha çok renk algılayıcıları tercih edilmektedir. Renk algılayıcılar ya her renk için ayrı ayrı algılayıcı gerektirmekte ya da renklerde sadece belli ton aralığını ve belli renkleri algılayabilmektedirler. Ancak günümüzde kameralı görüntü işleme sistemlerinin maliyetleri de oldukça hızlı düşmektedir. Kameralarla çok geniş spektrumlarda renk analizi yapılabilmekte ve nesne hakkında daha fazla öznelilikler elde edilebilmektedir (Dworkin ve Nye, 2006), (Fazel Zarandi vd., 2009).

Temelde bilgisayar, kamera ve çerçeve tutucu (frame grabber) karttan oluşan ve görüntü işleme tekniklerini kullanan teknoloji ve metotlara makine görme ya da yapay görme denilmektedir (Jain vd., 1995), (Kang vd., 2007). Makine görme sistemleri, görüntüyü alıp çok hızlı bir şekilde uygun algoritmalar ile işleyip cismin sınıfını anında belirleyebilmektedir (Metlek 2009). Sadece geleneksel otomasyon sistemlerinde değil özel

uygulamalarda da tercih edilmektedirler (Savran vd., 2010). Bu özel uygulamalara örnek olarak, iris tanıma, yüz tanıma, robot kontrol, otomatik hata belirleme verilebilir (Davies, 2005), (Xiao, 2007).

Otomatik sınıflandırmada nesne seçme işlemleri yapay zekâ yöntemlerini kullanan makine görme sistemleri ile yapılmaktadır (Kang vd., 2007). Seri üretimde gerçek zamanlı çalışıldığından sistemlerin çok kısa zamanda sonuç üretmesi gerekmektedir. Bu nedenle makine görmede karmaşık ve yavaş çalışan yöntemler tercih edilemez. Makine görmedeki bir kamera; tanıma işleminin yanı sıra, nesnenin kamera altında olup olmadığını denetlemek için bir algılayıcı gibi de kullanılabilir. Şekil 1'de makine görme sistemi gösterilmektedir. Bu sistemde kamera altına gelen cismin resmi çekilir ve bu bilgi bilgisayara gönderilir. Bilgisayarda koşulan yazılım bu cismin ne olduğuna karar verir ve cisim ilgili yere taşır.



Şekil 1. Makine Görme Sistemi.

*sedatmetlek@mehmetakif.edu.tr

Algılayıcı ve kameralı sistemlerin çalışma şekilleri benzerdir. Ancak algılayıcı sistemde bazı farklılıklar vardır. Örneğin algılayıcı sistemler, her öznetelik için ayrı algılayıcı gerektirir ve hassasiyet aralığı dardır. Kamera sisteminde ise öznetelik bilgisi resme uygulanan farklı dönüşümlerle çıkartılabilmektedir.

Makine görmenin birçok yararı vardır. Birincisi; sınıflandırma işleminde hata oranı daha düşüktür. Daha önce yapılan araştırmalarda; örneğin meyve tasnifi uygulamalarında aynı işlemler insan eliyle yapılmış ve ardından aynı ürünler kullanılarak makine görme sistemleri ile sınıflandırılmıştır. İki işlem kıyaslandığında makine görme ile yapılan sınıflandırmada hata oranının çok daha düşük olduğu tespit edilmiştir (Nagata ve Qixin, 1998), (Unay ve Gosselin, 2002).

Sistemin ikinci yararı da sınıflandırma işleminin çok hızlı gerçekleştirilmesidir. Hız, sınıflandırma işlemlerinde, ticari açıdan vazgeçilemeyecek önemli bir unsurdur. Sınıflandırma işlemlerini daha çabuk yapabilmek için görüntüyü hızlı ve doğru bir şekilde analiz etmek gerekmektedir. Nagata'ya göre elma seçme işleminde görüntünün alınarak işlenmesi ve sonucun netleştirilip sınıflandırmanın sonuçlandırılması, saniyenin üçte biri sürede gerçekleşmektedir (Nagata ve Qixin, 1998).

Ayrıca makine görme sistemleri esnektir. Bir problem için tasarlanan sistem, bazı değişikliklerle başka problemlere rahatlıkla uyarlanabilir. Otomatik tanıma sistemleri sürekliliği, standart bir yapıyı veya kaliteyi garanti eder.

Bu çalışmanın amacı daha önce algılayıcılar ile kontrol edilen bir otomasyon sisteminin, makine görme kullanılarak, daha kısa zamanda ve yüksek doğrulukta ayırt etmesini sağlamaktır.

Materyal ve Metot

Çalışma kapsamında Festo marka 648811, 648812, 648817, 648821 model deney düzenekleri birleştirilmiştir. Bu deney düzeneğinin üzerinde kırmızı, gri ve siyah renkte silindirik cisimler bulunmaktadır. Çalışmada daha önce renk algılayıcılar ile çalışan otomasyon sisteminin, sayısal kamera ve resim işleme teknikleri kullanılarak kontrolü sağlanmıştır.

Çalışmada kullanılan kamera Basler Gigabit Ethernet kameradır. Kamera CMOS teknolojili algılayıcılara sahip olup 1296 x 966 piksel çözünürlüğe sahip renkli bir kameradır.

İncelenen cisimlere ait resimlerdeki renk değerlerinin, ışık miktarındaki değişimlere bağlı olarak değişkenlik gösterdiği tespit edilmiştir. Örneğin gündüz yapılan ölçümler ile gece yapılan ölçümler arasında farklar çıkmıştır. Bu nedenle ortamdaki ışık miktarını sabitlemek için kameranın bulunduğu kısım tamamen bir kabinle kapatılmıştır. Cisimlerin aydınlatılması için halka


biçiminde doğrudan aydınlatmalı beyaz renkte LED bir ışık kaynağı kullanılmıştır.

Şekil 2'deki sistemde yer alan 648811 nolu deney setindeki cisim haznesine, kırmızı, gri ve siyah renkteki cisimler rastgele yerleştirilmektedir. Deney setinde bulunan elektro-pnömatik kol bu cisimleri alıp bir sonraki 648812 nolu sette yer alan asansöre, aşağı konumunda yerleştirmektedir. Daha sonra cisim asansörle yukarıya çıkartılmaktadır. Cisim yukarıya geldiğinde algılayıcı bunu algılamakta ve 648817 nolu deney setinde yer alan aşağıya doğru olan eğimli bandın üzerine, pnömatik bir kol yardımıyla itilmektedir. Alttan üflenlen hava ile aşağıya doğru kaymaya başlayan cisim 648821 nolu deney setindeki renk algılayıcısının önüne kadar gelmektedir.




Şekil 2. Festo Deney Setleri.

Yürüyen bandın başına gelen cisim, Şekil 3'te gösterildiği gibi cismi tutan piston sayesinde renk algılayıcısının önünde bekletilmektedir.



Şekil 3. Kabin içinde yer alan Festo sınıflandırma ünitesi.



Şekil 4. Programın Akış Diyagramı


Algılayıcının önünde duran cismin rengini, renk algılayıcısı algıladıktan sonra algılama bilgisini PLCye göndermektedir. PLC cismin renk bilgisini aldıktan sonra yürüyen bant üzerindeki cismi tutan kolu geri çekmekte ve cismi ilgili olduğu banda yönlendirmektedir. Cisim bu yürüyen bant üzerinden ilgili banda geçmekte ve geçtiği

bilgisi yine bir başka algılayıcı tarafından algılanıp yeni bir cisim için işlem tekrar başlatılmaktadır.

Bu çalışmada anlatılan düzenekte bulunan renk algılayıcısı yerine sisteme bir kamera ve bilgisayar eklenmiştir. Kameranın altına gelen cismin rengi Şekil 4'de akış diyagramı gösterilen program yardımıyla belirlenmektedir.

Cismin rengine karar verildikten sonra bilgisayarın paralel portundan, hazırlanan elektronik devreye sinyal gönderilmektedir. Elektronik sürücü devre şeması Şekil 5'de verilmektedir.

Elektronik devrede, tutucu pistonu ve iki adet mekanik kolu kontrol etmek için kullanılan röleler yer almaktadır.



Şekil 5. Elektro-mekanik elemanların sürücü devresi.

Bayes Sınıflayıcısı

Bayes sınıflayıcı, istatistikî bir yöntem olup, bilinen sınıf etiketleri ve veri uzayına göre önceden elde edilen normal sınıf dağılımlarından yararlanılarak, yeni gelen örneklerin nasıl sınıflayacağını belirler. Bayes ile sınıflamada, sonuçların anlamlı olabilmesi için her sınıfta en az 10 örnek olması gerekmektedir. Aksi takdirde normal bir dağılımdan bahsedilemez. İki ve çoklu sınıf olmasına göre Bayes sınıflayıcısı farklı ele alınmaktadır.

Buna göre iki sınıflı bir problem için; C sınıf etiketleri, d boyutlu herhangi bir $\mathbf{x}$ örneği ise $\mathbf{x}$ 'in C sınıfında olma olasılığı;

$$P(C | \mathbf{x}) = \frac{P(C)p(\mathbf{x} | C)}{P(\mathbf{x})}, \quad (1)$$

ile belirlenebilir. Burada $P(C)$ verilen veri uzayında etiketi C olan örnek sayısının toplam örnek sayısına olan oranı ile belirlenen bir olasılıktır. $P(C | \mathbf{x})$ ise $\mathbf{x}$ verildiğinde, bunun C sınıfında olma olasılığıdır.

$p(\mathbf{x}|C)$ ise C etiketli sınıfta $\mathbf{x}$ 'e benzer örneklerin olasılığını göstermektedir.

Bayes sınıflayıcısı isteğe göre K sınıfta da olabilir. Bu durumda $\mathbf{x}$ örneğinin her sınıfta olabileceği olasılığı dikkate alınmalıdır. $\mathbf{x}$ örneğinin herhangi bir C_i sınıfında olma olasılığı;

$$P(C_i|\mathbf{x}) = \frac{P(C_i)p(\mathbf{x}|C_i)}{\sum_{j=1}^K P(C_j)p(\mathbf{x}|C_j)} \quad (2)$$

ile belirlenir (Gose ve Johnsonbaugh 1996).

Çok Boyutlu Öznitelikler

Öznitelik sayısı birden fazla olduğunda olasılık hesabı farklı yapılmaktadır. Öznitelikler arasındaki ilişkinin mutlaka değerlendirilmesi gerekir. Bu durumda normal dağılımın ortalama değer μ ve öz değişinti matrisi Σ hesaplanmalıdır. Buna göre örneğin sınıflara aitlik olasılığı, Eşitlik (3)'teki gibi ortaya çıkar.

$$P(C_i|\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^d \det(\Sigma_i)}} e^{-\frac{1}{2}(\mathbf{x}-\mu_i)^T \Sigma_i^{-1}(\mathbf{x}-\mu_i)} \quad (3)$$

Burada d öznitelik sayısını göstermektedir ve $\mathbf{x}$ örneği d boyutludur.

Bulgular


Renk belirleme algoritması oluşturulurken ilk önce eğitim seti hazırlanmıştır. Eğitim setinde her renk cisimden 15'er tane olmak üzere toplam 45 resim kullanılmıştır. Burada ilk olarak şu bulguya rastlanıldı. Eğer kameranın bulunduğu ortamda ışık belli bir seviyede tutulmadıysa eğitim setinde ne kadar fazla örnek sayısı olursa olsun sistem kararlı bir biçimde çalışmamaktadır. Bundan dolayı kameranın bulunduğu ortam mutlak suretle kapatılıp ışık seviyesi sabit miktarda tutulmalıdır.

Araştırma bulgularında dikkat çeken bir başka nokta da normalde insan gözü ile birbirinden büyük farkla ayrılan kırmızı ve gri renkli cisimlerin kameralı nesne tanımlamada kolay ayırt edilemediği olgusudur. Kırmızı ve gri cisimlerin tek tek renk analizleri yapıldığında, beklenenin aksine, kırmızı renk ortalama değerleri birbirine çok yakın çıkmaktadır. Yeşil ve mavi renklerde ise kırmızı ve siyah cisimler karışmaktadır. Bu noktada sadece tek renkle sınıflandırma yapmak doğru olmayacaktır. Bu da makine görmesi ile insan görmesi arasındaki farkı göstermiştir. Araştırma öncesinde de böyle durumlarla karşılaşılabilirdiği ve bundan dolayı makine görme sistemlerinde işlem yapılacaksa normal görme ile ilgili her şeyin bir kenara bırakılması gerektiği bilinmekteydi. Yeşil ve mavi renkler de cisimlerin ayrıştırılmasında önemli rol oynamaktadırlar. Çizelge 1'de kırmızı, gri ve siyah cisimlerin RGB renk uzayındaki ortalama değerleri verilmektedir.


Çizelge 1. Üç ayrı cismin RGB ortalama değerleri.

Cisim	Renk		
	Kırmızı	Yeşil	Mavi
Kırmızı	77	23	23
Gri	88	103	115
Siyah	11	21	19


Sırasıyla Şekil 6, Şekil 7, Şekil 8'de ise kırmızı, gri ve siyah cisimlere ait RGB renk dağılımları verilmektedir.



Şekil 6. Cisimlerin kırmızı renk dağılımı.




Şekil 7. Cisimlerin yeşil renk dağılımı.



Şekil 8. Cisimlerin mavi renk dağılımı.

Bir başka bulgu da kamera sistemi ile çalışan sistemin iş yapabilme zamanıdır. Bu çalışmada birbiri ile farklı görevleri olan üç farklı program yazılmıştır. Bunlardan iki tanesi MATLAB'da yazılmış bir tanesi de Visual Basic'de (VB) yazılmıştır. VB'de yazılan programın görevi kameradan resmi alıp bilgisayarda belirtilen klasöre yazmaktır. Çalışmada iki ayrı programlama dilinin kullanılması nedeni, Basler markalı kameranın MATLAB tarafından tanımlı olmamasıdır. Bu nedenle kamera arayüzü için VB kullanılmıştır. Portların kontrolü ve görüntü işleme için MATLAB'a ait hazır fonksiyon ve araç kutularının olması, MATLAB kullanımını gerektirmiştir. Şekil 9'da sistem çalışırken VB'de hazırlanan arayüz görülmektedir.

MATLAB'da hazırlanan programın görevi de çekilen resim üzerinden nesneyi tespit ederek bunun renk dağılımlarını belirlemek ve ilgili renk bilgisini paralel porta göndermektir. Farklı üç program çalıştırılmasına rağmen işlemler o kadar hızlı yapılmıştır ki, yazılan programlarda aralara bekletme koymak gerekmiştir. Bu durum sayısal değerlere çevrildiğinde, görüntü işleme yönteminin algılayıcı sistemden üç kat daha hızlı olduğu ortaya çıkmaktadır (Bkz. Şekil 10).



Şekil 9. VB arayüzü.


Sistem sınıflandırma açısından değerlendirildiğinde aşağıda belirtilen amaçlara ulaşması istenilmektedir.

- Renk analizini yapmak,
- Gerçek zamanlı olarak çalışmasını sağlamak,
- Algılayıcı sisteminden daha hızlı ve yüksek doğruluk oranına ulaşmaktır.

Sistem çalıştırıldığında önce kameranın altına cismin gelip gelmediği tespit edilir ve daha sonra da gelmiş ise bu cismin resmini çekip, hangi sınıfa ait olduğu tespit edilmiştir. Yapılan ilk denemelerde kameranın altında bulunan cismin resmi alındığında, alttaki bandın üzerindeki çizgili desenlerden dolayı, aynı cismin resmi tekrar çekildiğinde farklı sonuçlar çıkmıştır. Bundan dolayı resimde sadece işlem yapılacak olan kısmın alınmasının daha faydalı olacağı kanısına varılmıştır.

Bütün karar verme işlemleri, yazılan programlarda beklemler kullanılmasına rağmen 1 saniyenin altında gerçekleştirilmiştir. Bu durum Şekil 10'da gösterilmiştir.

Aynı işlemler sadece renk algılayıcısı ile tekrar gerçekleştirildiğinde ise Şekil 10'daki değerler elde edilmiştir. Algılayıcıların aynı renkte başka cisimler ile denendiği durumlarda, sistemin renkleri algılayamadığı durumlar olmuştur. Fakat kamera sisteminde kameranın önüne aynı renkte yada yakın renklerde başka bir cisim konulduğunda sistem bunu algılayabilmiştir.



Şekil 10. Sınıflandırmada zaman-miktar karşılaştırması.

Gerekli uygun mekanik sistemler hazırlandığı takdirde bir dakikada yaklaşık 30 adet cismin sınıflandırmasının mümkün olduğu görülmüştür. Kamera ile sınıflandırma işlemi çok hızlı yapılmaktadır. Fakat mekanik sistem bu hıza erişememektedir. Bu işlemlerin hızlı gerçekleştirilmesinde kameranın bir saniyede alabileceği en çok kare sayısı önem kazanmaktadır.

Kamera kullanılan sistemde, her cisim için üç renk uzayı da kontrol edildiği için sınıflandırma işlemi %100 başarı ile sağlanmıştır. Sistemde kullanılan tüm cisimler, hatasız olarak tanınmaktadır. Yapılan sistemde eğitim seti kullanıldığı için aynı şekillerde üç farklı renkte daha başka cisimleri de sınıflandırabileceği görülmüştür.

Sonuç

Sistemde kameranın bulunduğu kısım dış ortamdaki ışıktan tamamen izole edilmelidir. İzole edilmediği takdirde ışık miktarındaki değişimlerden sistem etkilenmektedir. Bu etkilenme kameranın alacağı görüntülerden elde edeceği değerler ile sistemin eğitiminde kullanılan görüntü değerlerinin çok farklı çıkmasına neden olmaktadır. Bundan dolayı mutlaka kameranın bulunduğu ortam kapatılarak ortamdaki ışık miktarı sabitlenmelidir.

Görüntülerin elde edilmesi süresince sistemde kullanılan ışık kaynağının da önemli olduğu sonucuna varılmıştır. Sistemde cismin üzerine doğrudan bir ışık konduğunda ya da kameranın bulunduğu kutu çıkarılıp çok yoğun gün ışığına maruz bırakıldığında elde edilen görüntülerde çok fazla parlama olduğu tespit edilmiştir. Bu da yapılacak tanınmanın çok farklı sonuçlanmasına neden olmuştur.

Çıkan bu sonuçlardan kameranın cisimleri ayırma zamanının, renk algılayıcısının ayırma zamanına göre yaklaşık üçte bir sürede gerçekleştirdiği görülmektedir. Renk analizinden elde edilen değerlerden yola çıkarak da bu yöntemlerin daha farklı cisimlere uygulanabileceği kanısına varılmıştır.

Yapılan çalışmadan yola çıkılarak gelecekte benzeri çalışmalar yapıldığında aydınlatma konusunda problemler yaşanabileceği kanısına varılmıştır. Bu çalışmaya benzer şekilde bir sınıflandırma işlemi yapılacağına öncelikle aydınlatma ve sayısal kamera seçiminin üzerinde durulması gerekmektedir. Gelecekte benzeri sınıflandırma işleminin mermer ve seramik gibi ürünlerin kalite kontrolü amacıyla yapılabileceği düşünülmektedir.

Teşekkür

Süleyman Demirel Üniversitesi CAD-CAM Araştırma Merkezi'ne sağladığı donanımlar ve deney setleri için teşekkür ederiz.

Kaynaklar

- Davies E.R. 2005. Machine Vision, Third Edition: Theory, Algorithms, Practicalities. Publisher, Morgan Kaufmann, 934pp.
- Dworkin, S.B., Nye T.J. 2006. Image processing for machine vision measurement of hot formed parts. Journal of Materials Processing Technology, 174, 1-6.

- Fazel Zarandi, M.H., Zarinbal, M., Izadi, M., 2009. Systematic image processing for diagnosing brain tumors: A Type-II fuzzy expert system approach. Applied Soft Computing, 11, 285-294.
- Gose, E., Johnsonbaugh, R., 1996. Statistical decision making. In: Pattern Recognition and Image Analysis. Prentice Hall PTR, New Jersey, 84 p.
- Jain, R., Kasturi, R., Schunck, B.G., 1995, Machine Vision, Publisher, McGraw-Hill, 549p.
- Kang, T., Ren, K., Pan L., Hongwen. L., 2007. A Study of Broccoli Grading System Based on Machine Vision and Neural Networks. Proc. of the 2007 IEEE Int. Conf. on Mechatronics and Automation 5 – 8 August, Harbin/China.
- Lino, A.C.L., Sanches, J., Fabbro, I.M.D., 2008. Image processing techniques for lemons and tomatoes classification Bragantia, Campinas, 67(3), 785-789.
- Metlek, S., 2009. Üretim Bandı Üzerindeki Renkli Silindirik Parçalarının Makine Görme Sistemiyle Tanımlanması Ve Sınıflandırılması. Yüksek Lisans Tezi, SDÜ, Fen Bilimleri Enstitüsü, Isparta, 87s.
- Nagata, M., Cao Q. Study on Grade Judgment of Fruit Vegetables Using Machine Vision. <http://web02.affrc.go.jp/english/publication/jarq/32-4/32-4-257-265.pdf>. (Erişim Tarihi: 18.01.2012)
- Savran, A., Sankur, B., Bilge, M.T. 2012. Comparative Evaluation of 3D versus 2D Modality for Automatic Detection of Facial Action Units. Pattern Recognition, 45(2), 767-782
- Unay, D., Gosselin, B. 2006. Apple Defect Segmentation by Artificial Neural Networks, Proc. of BeNeLux Conf. on Artificial Intelligence (BNAIC), Namur -Belgium,
- Xiao, Q., 2007. Biometrics-Technology, Application, Challenge, and Computational Intelligence Solutions, IEEE Computational Intelligence Magazine, 2(2), 5–25.