

지능형 자동차용 영상인식 SoC 기술동향

Trends in Image Recognition SoC for Smart Vehicles

스마트 & 그린 융합부품소재기술 특집

윤상훈 (S.H. Yoon)	센서인터페이스연구팀 선임연구원
여준기 (C.G. Lyuh)	센서인터페이스연구팀 선임연구원
천익재 (I.J. Chun)	센서인터페이스연구팀 선임연구원
석정희 (J.H. Suk)	센서인터페이스연구팀 선임연구원
노태문 (T.M. Roh)	센서인터페이스연구팀 팀장

목 차

-
- I . 서론
 - II . 자동차용 영상인식 알고리즘
 - III . 영상인식 SoC 기술동향
 - IV . 결론

자동차는 이제는 없어서는 안 될 인간의 생활필수품이 되었다고 하여도 과언이 아닐 정도로 많은 보급이 이루어졌다. 이와 같은 자동차의 보급으로 인하여 사람들은 보다 편리하고 안전한 자동차를 추구하게 되었고 산업체에서는 지능화된 자동차를 통해 고객의 요구에 부응하기 위한 연구와 제품 개발을 계속하고 있다. 지능형 자동차를 위하여 많은 분야의 기술들이 자동차와 융합되어 나타나고 있으며, 그 중에서도 최근 북미에서 발표된 ‘후방 카메라 탑재 의무화’로 인해 영상인식과 자동차의 융합에 많은 관심이 모아지고 있다. 본고에서는 최근 각광을 받고 있는 자동차용 영상인식에 대한 알고리즘 및 영상인식 SoC기술동향 등에 대해서 알아보도록 한다.

1. 서론

과거 자동차는 운송수단으로서 싼 가격에 고장 없이 빠른 속도로 목적지까지 이동하게 하는 것이 고객에 대한 최선의 서비스라 여겨져 산업체에서는 하드웨어적인 기술개발을 위하여 많은 노력을 기울여왔다. 하지만, 최근 들어 기하급수적으로 늘어난 자동차수로 인하여 보다 높은 자동차의 최고속도보다 막히는 길을 피하여 빨리 목적지에 도착할 수 있는 자동차를 선호하게 되었고, 높아진 경제 수준으로 인하여 안전 및 편리성에 대한 관심이 고조되어 사고가 나더라도 운전자가 안전할 수 있는 튼튼한 자동차뿐만 아니라 사고를 미연에 방지하며 운전할 수 있는 똑똑한 자동차에 대한 수요가 늘어나게 되었다. 이로 인해 기존의 하드웨어뿐만 아니라(그림 1)에서 나타난 바와 같이 소프트웨어적인 기술까지 영역이 확대되어 다양한 분야와의 융합을 통한 서비스 개선 연구가 이루어지고 있으며, 혼자만의 자동차가 아닌 서로 함께 운행되고 있는 군집의 자동차로서 서로 간의 네트워크를 형성하고 상호 간의 정보교류를 통해 보다 안전한 운행을 추구하게 되었다.

안전성과 편리성을 추구하는 똑똑한 자동차는 ‘지

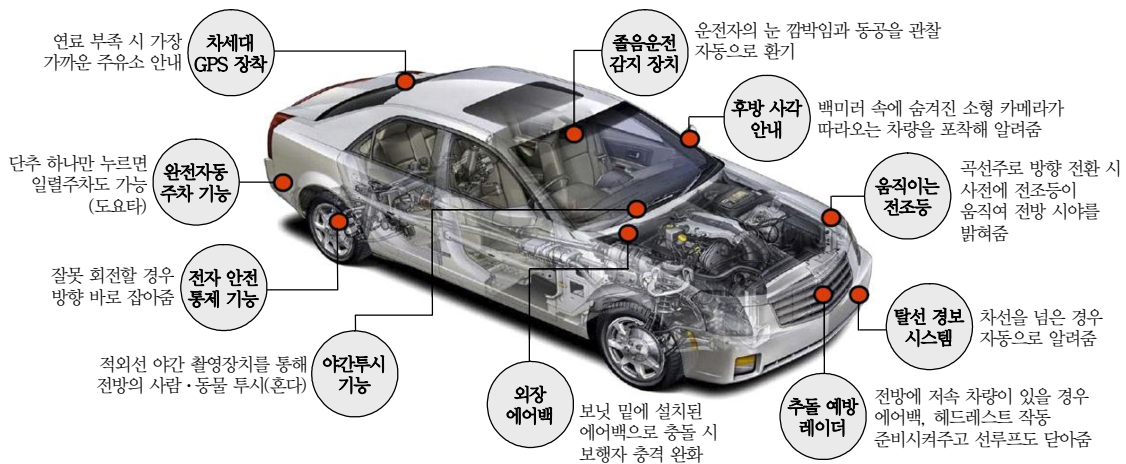


(그림 1) 자동차 서비스 패러다임의 변화

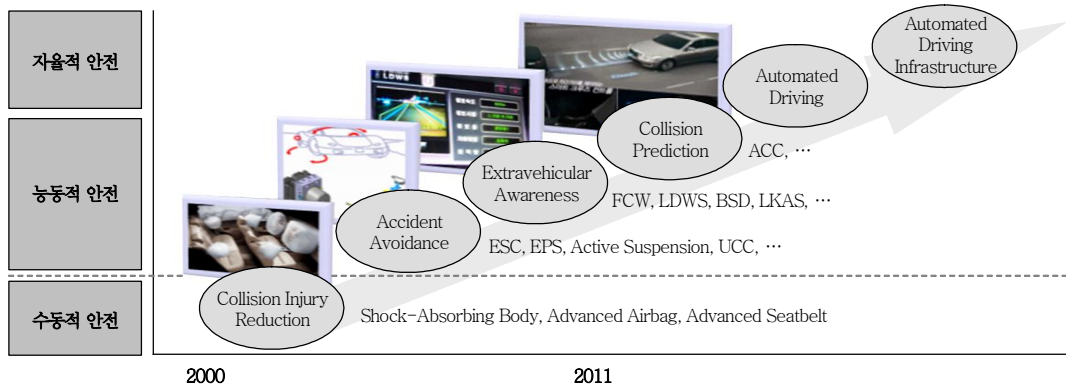
능형’이라는 수식어로 대변되어 차세대 자동차는 ‘지능형 자동차’로 인식되고 있으며, 지능형 자동차는(그림 2)에서 나타난 바와 같은 각종 기능을 개발 및 탑재하여 운전자의 편리와 안전을 도모하고 있다[1].

자동차의 편리와 안전을 위한 지능형 자동차 시스템은(그림 3)에서 보이는 바와 같이 초기의 안전벨트, 에어백, 충격흡수차체 등과 같이 자동차 사고가 발생하였을 때 피해를 최소화하기 위한 수동적인 시스템으로부터 사고의 회피를 위한 시스템(ESC, EPS 등), 주변 차량 및 차선 감지를 통한 안전성 향상 시스템(FCW, LDWS 등), 차량 간 거리 측정 등을 통한 무인 자동 운행(ACC 등) 시스템 등으로 발전하여 왔고 향후에는 무인 자동 운전 시스템으로 발전하여 나갈 것으로 예상된다[2].

주변 차량 및 차선의 인식, 전방 차량의 인식 및 차



(그림 2) 지능형 자동차의 안전과 편리를 위한 기능들



(그림 3) 자동차 안전 시스템의 발전 방향

량과의 거리 측정, 도로 주변의 보행자 인식 등은 지능형 자동차의 ‘지능향상’을 위한 핵심 기술로 LRR, SRR 등의 센서가 주로 사용되어 왔다. 그러나, 최근 들어 자동차용 영상인식 SoC 개발의 선두업체인 Mobileye에서 개발한 EyeQ2, EyeQ3 등이 탑재된 영상인식 기반 차량 안전 시스템들이 속속 BMW 등의 차량에 장착되고 있다[3]. 또한, 미 교통부에서 발표한 후방보조 카메라 탑재 의무화 방침[4]에 따라 영상을 이용한 시스템의 개발이 활기를 띠고 있으며, 수요의 증가에 따라 시스템의 대량 생산을 위한 SoC의 개발이 본격화될 것으로 예상되고 있다.

본고에서는 영상을 이용한 자동차 안전 시스템의 핵심인 자동차 및 보행자 인식용 SoC 개발을 위한 알고리즘 및 SoC의 개발 동향을 파악하고, 향후의 알고리즘 및 SoC의 발전 방향에 대하여 전망해보고자 한다.

II. 자동차용 영상인식 알고리즘

1. 자동차용 영상인식 알고리즘 개요


자동차용 영상인식 알고리즘은 크게 물체의 부분 부분을 검출하고 각 부분의 검출 에너지를 모아 대상 물체 여부를 판별하는 part 기반 인식 방식과 영상을 일정한 크기의 윈도우를 이용하여 특징벡터를 만들

고 특징벡터를 분류하는 슬라이딩 윈도우 기반 인식 방식으로 나눌 수 있다. 각각의 방식은 인식률과 복잡도에 있어서 장단점을 가지고 있으며, 본고에서는 규칙적인 연산의 반복을 기본으로 하여 하드웨어 구현이 용이한 슬라이딩 윈도우 기반 방식을 위주로 설명하도록 한다.

슬라이딩 윈도우 기반 방식은 기본적으로 크기가 고정되지 않은 물체를 정해진 크기의 윈도우로 검출하기 위하여 영상의 크기를 조절하는 영상 스케일링, 잘라진 윈도우 내의 영상을 이용해 약속된 방식을 통하여 벡터화 하는 특징벡터 추출, 추출된 벡터의 분류, 분류된 결과의 정제를 위한 물체 국부화(object localization)로 구현될 수 있다[5],[6].

2. 영상스케일링 기술


슬라이딩 윈도우 기반 인식 방식에서 크기가 고정되지 않은 물체의 검출을 위하여 윈도우의 크기를 고정시키고 영상의 크기를 (그림 4a)와 같이 변화시켜가며 추출 및 분류 작업을 수행하거나, (그림 4b)와 같이 검출 윈도우의 크기를 다양하게 하고 원래의 영상에서 대상 물체를 작업을 수행할 수 있다. 또한, 위의 두 방식의 복합된 방식으로 (그림 4c)와 같이 영상과 윈도우의 스케일을 동시에 조절하게 할 수도 있다



(a) 영상 스케일링



(b) 윈도우 스케일링



(c) 복합 스케일링

(그림 4) 영상 스케일링의 예

[6]. 복합 방식의 경우 영상에서 특징벡터를 추출하기 위해 적용해야 할 전처리 과정을 줄일 수 있으며, 윈도우의 크기에 따른 특징벡터를 인접크기의 윈도우에서 사용된 특징벡터를 간단히 변환하여 생성시켜 벡터추출을 위한 연산을 줄여줄 수도 있어 인식 속도를 크게 향상시킬 수 있다[7].


3. 영상 특징벡터 추출

특정 크기의 윈도우 내에 있는 영상을 이용하여 검출 대상과 비검출 대상을 구별하기 위해서는 각각의 영상의 특징을 잘 대변할 수 있도록 설명해주는 기술자(descriptor)가 필요하다. 특징 기술자는 다양

한 형태를 가질 수 있으나, 정형화된 형태의 벡터로 기술하여 단일한 크기의 입력을 받아들이는 분류 장치를 통해 대상 여부를 판별할 수 있도록 해주는 것이 일반적이다. 이와 같은 특징벡터들을 추출하는 방법은 매우 다양하며, 각각의 방식들은 서로 다른 특징을 가지고 있어 서로 함께 사용되기도 한다. 본 절에서는 현재 대표적으로 사용되는 벡터 추출 알고리즘들에 대하여 설명하도록 한다.

가. Haar-like 특징벡터

Haar-like 특징벡터는 (그림 5a)에서 보이는 바와 같은 형태의 간단한 필터를 사용한다. 여기서 흰 부분과 검은 부분은 각각 1과 -1의 계수를 의미하며, 필터 연산은 덧셈과 뺄셈만으로 구현 가능하다. 필터의 종류와 크기는 훈련에 의하여 결정되며, 각 필터의 크기는 달라도 적분영상(integral image)을 이용하면 크기에 상관없이 동일한 연산 수를 이용하여 필터연산을 수행할 수 있다[8]. Haar-like 특징벡터는 (그림 5b)에서와 같이 특정 물체와 배경의 색상에 차이가 존재하는 특성을 이용한다. 하지만, 카메라와 주변 환경에 따라 색상의 차이는 변화하게 되므로 이와 같은 영향을 최소화하기 위하여 히스토그램 등화기, 정규화기 등을 통하여 환경에 강인한 특성을 만들기도 한다. Haar-like 특징벡터는 생성 방식이 매우 간단하여 고속 처리에 용이한 장점이 있어 실시간 얼굴 인식 등의 주 알고리즘으로 많이 사용되어 왔다.



(a) 필터의 예

(b) Feature의 적용 예

(그림 5) Haar-like 특징벡터


나. Histogram of Oriented Gradients

Histogram of Oriented Gradients(HOG)는 최근 들어 슬라이딩 윈도우 기반 알고리즘에서 가장 많이 비교 대상으로 사용되어 온 알고리즘으로 검출 대상 물체에서 나타나는 그레이디언트의 분포 특징을 이용한다. HOG는 셀과 셀을 포함하는 블록으로 구성이 되며, 블록은 경우에 따라 특징의 위치 정보를 포함하기 위하여 인접한 셀들을 서로 공유하여 사용할 수도 있다. 나뉘어진 셀과 블록 내의 각 픽셀에서의 x, y축 그레이디언트(Δx , Δy)를 각각 구하고, 그레이디언트의 크기(M)와 방향(θ)은 식 (1), (2)와 같이 계산한다. 이와 같이 계산된 크기는 블록 단위로 가우시안 윈도우를 거쳐 위치에 따라 다른 중요도를 가지게 하고, 360° 를 P개의 영역으로 나누어 식 (2)를 통해 계산된 방향(θ)이 포함되는 영역에 윈도우를 거친 크기($M \cdot g(x_b, y_b)$) 값을 누적시킨다. 여기서, $g(x_b, y_b)$ 는 블록 내의 위치(x_b, y_b)에 따른 가우시안 계수를 나타낸다.

$$M = \sqrt{\Delta x^2 + \Delta y^2} \quad (1)$$

$$\theta = \tan^{-1} \left(\frac{\Delta y}{\Delta x} \right) \quad (2)$$


(그림 6a)와 같이 그레이디언트 값을 구하고, (그림 6b)와 같이 블록별로 생성된 각 영역별 그레이디언트 누적값을 (그림 6c)와 같이 연결하여 벡터화하고, 정규화 과정을 거치면 HOG 특징벡터가 만들어지게 된다. 정규화로는 L1-norm, L2-norm, L2-Hys, L1-sqrt 등이 사용된다[9]. HOG 특징벡터는 생성과정이 복잡하여 많은 연산이 필요하나 우수한 성능을 나타내어 많이 사용되고 있으며, 그레이디언트의 크기값은 물체의 경계에서 크게 나타나므로 경계에서의 특징 검출에 있어 우수한 특성을 나타낸다.



(그림 6) HOG 특징벡터 생성 과정

다. Co-occurrence HOG


물체의 경우 경계선에서의 그레이디언트 방향은 인접한 픽셀에서의 방향과 매우 밀접한 관계를 가진다. 예를 들어 사람의 정수리에서의 그레이디언트 방향이 위쪽이라면 정수리에서 일정변위를 가지는 귀 부분에서는 옆 방향의 그레이디언트가 발생하게 될 것이 분명하다. Co-occurrence HOG(CoHOG)는 기존의 HOG의 특성에 픽셀 간 그레이디언트 방향 관계를 함께 정보화한다. 먼저 (그림 7)에서와 같이 정해진 오프셋만큼 떨어진 두 픽셀의 그레이디언트에 대하여 각각 P개로 나누어진 방향 영역을 설정하여 총 P^2 개의 방향 영역을 만든다. 그리고, 셀 내에 있는 픽셀 쌍들에 대하여 해당 방향 영역에 속하는 픽셀의 수를 누적하여 P^2 개 차원을 가지는 벡터를 구성하고, HOG에서와 같이 벡터들을 모아 윈도우에 대한 특징벡터를 구성한다. CoHOG는 HOG에 비하여 기본적으로 차원의 수가 많아질 수 있으므로, 셀, 블록 등의 크기를 조절하여 성능과 복잡도를 조화시켜 사용할 수 있다[10].



(그림 7) CoHOG 특징벡터

라. Local Binary Pattern

Local Binary Pattern(LBP)은 패턴 인식에 많이 사용되어온 방식으로 패턴과 같은 텍스처 정보를 분류하는데 탁월한 성능을 발휘한다. LBP는 현재 픽셀과 주변 픽셀과의 관계를 이용해 코드화하는 방법으로 (그림 8)에서와 같이 주변 픽셀에 현재 픽셀보다 작으면 0, 크면 1을 할당한 후 이들을 모아 하나의 코드를 생성한다. 현재 픽셀과 주변 픽셀의 거리, 주변 픽셀의 수 등을 파라미터로 성능을 조절할 수 있으며, 영역별 특징인식을 위하여 윈도우를 셀 단위로 나누어 각각의 셀에서의 코드 값을 히스토그램화 한다. 여기서 0과 1의 교차가 많은 코드의 경우 잡음에 민감한 특성을 나타내기 때문에 코드 내에서 0과 1의 교차 수를 한정시켜 코드를 선별하여 사용하기도 한다. HOG 특징벡터가 경계를 구별하는데 강인한 특징을 나타내고 LBP는 텍스처를 구별하는 데 강인한 특징을 가지고 있어 상호 보완이 가능하여 최근에는 HOG와 LBP를 연접한 특징벡터가 많이 사용되고 있다[11]. 또한, LBP는 redundant한 부분이 많이 존재하여 이를 없애기 위한 많은 알고리즘들이 제안되기도 하였다[12],[13].



(그림 8) LBP 특징벡터


4. 영상 특징벡터 분류

특징벡터 추출기는 모든 윈도우에 대하여 동일한 크기의 벡터를 생산해 낸다. 추출기의 출력은 특징벡터 분류기로 입력되어 입력된 벡터가 검색대상인지의 여부를 판별한다. 분류기는 참과 거짓을 대표하는 벡터들을 이용한 훈련을 통해 미지의 벡터를 분류하

기 위한 내부 계수들을 결정하게 되고, 결정된 계수들을 이용하여 입력 벡터 테스트를 수행한다. 본 절에서는 벡터에 대한 훈련 및 테스트를 수행하기 위한 특징벡터 분류기들에 대하여 알아본다.

가. Adaboost

Adaboost는 실시간 얼굴인식 등에 많이 사용되어온 알고리즘으로 고속의 분류테스트가 가능한 장점을 가지고 있다. 이 방법은 여러 개의 약분류기를 모아 강분류기를 만드는 것으로, 훈련과정에서 N개의 약분류기를 골라 각각의 약분류기에 가중치를 적용하여 나오는 에너지를 합산하여 임계값보다 크고 작음에 따라 참과 거짓을 분류한다. 예를 들어 (그림 9)에서와 같이 회색 클래스와 진회색 클래스를 분류하려 할 때, 각각의 훈련대상벡터에 동일한 가중치를 부여하고 이들을 분류하였을 때 오류가 발생하는 대상벡터의 가중치 합이 가장 작도록 해주는 약분류기 하나를 선택한다. 선택된 약분류기로 훈련대상벡터를 분류하였을 때 오류가 발생하는 벡터들에 대하여 가중치를 증가시키고 다시 오류가 발생하는 벡터의 가중치 합이 최소가 되는 두 번째 약분류기를 선택한다. 오류가 발생하는 벡터에 대하여 가중치를 증가시키면 이후의 약분류기에서 또다시 그 훈련 벡터에 대하여 분류 오류가 발생할 확률을 줄일 수가 있다. 이와 같은 과정을 반복하여 약분류기들을 모아 강분류기를 구성하면 우



(그림 9) Adaboost 개념

수한 성능의 분류기를 만들어 낼 수 있다. 분류 테스트 시에는 약분류기의 분류 결과가 참일 경우 해당 약분류기에 할당된 가중치를 누적하고, 누적된 총 에너지가 모든 약분류기가 참으로 판정했을 때 발생하는 최대 에너지의 반을 넘게 되면 분류 결과를 참으로 판정한다[8].

나. Support Vector Machine

Adaboost 분류기는 고속의 연산이 가능한 장점이 있는 반면에 분류 성능은 떨어지는 단점이 있어 보다 우수한 성능의 분류기가 요구되었고 이에 대한 결과물로 제안된 알고리즘이 support vector machine (SVM)이었다[14]. SVM은 (그림 10)에서 보이는 바와 같이 단순히 현재의 훈련벡터를 잘 분류할 수 있도록 훈련되지 않고 분류할 클래스들 사이의 분류 경계선을 최대의 마진을 가지는 선으로 최적화하여 테스트 시 오류 확률을 낮추어 줄 수 있도록 훈련된다. SVM 분류를 위한 결정식은 식 (3)과 같다. 여기서, x_k 는 서포트벡터, $K(a,b)$ 는 커널 함수, b 는 오프셋을 각각 의미한다.

$$d(x) = \sum_{x_k \in T} \alpha_k K(x_k, x) + b \quad (3)$$

SVM은 단순한 선형 커널뿐만 아니라 식 (4)에서와 같은 폴리노미얼, radial basis function(RBF) 커

널, 하이퍼볼릭 탄젠트 커널 등을 사용하여 분류 성능을 향상시킬 수 있다. 그러나, RBF 커널 등과 같은 비선형 커널을 사용할 경우 모든 support vector를 저장해야 하고 각각의 벡터에 대하여 모두 연산을 수행하여야만 하여 매우 큰 복잡도가 요구되어 간단한 구조에 비하여 우수한 성능을 나타내는 선형 커널 SVM이 주로 사용되고 있다.

$$K(x, y) = x \cdot y$$

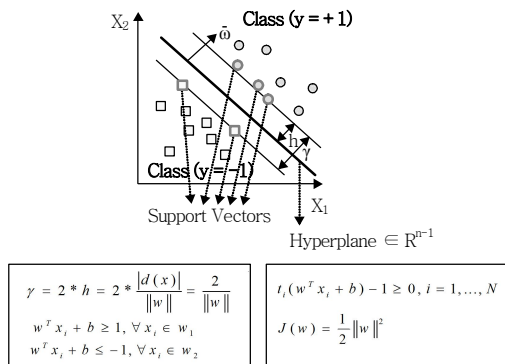
$$K(x, y) = (x \cdot y + 1)^p \quad (4)$$

$$K(x, y) = e^{-\|x-y\|^2 / 2\sigma^2}$$

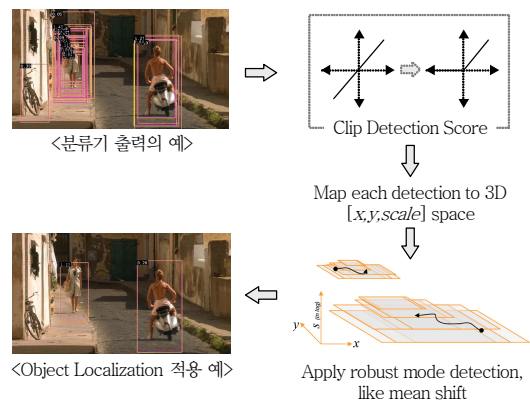
$$K(x, y) = \tanh(\alpha x \cdot y + \beta)$$

5. Object Localization

분류기를 통해 참 윈도우로 판단된 윈도우들은 일반적으로 (그림 11)에서 보이는 바와 같이 대상물체 하나에 대해 단 하나가 존재하는 것이 아니라 여러 개의 무리를 지어 존재할 수 있다. 따라서 참으로 판단된 윈도우들을 참조하여 대상물체 윈도우를 (그림 11)에서와 같이 하나로 한정 지어주기 위한 단계가 필요하다. 이와 같은 과정을 Object Localization(OL)이라고 하며, (그림 11)에서와 같이 검출 점수 클리핑, 3D 매핑, mean shift 등을 이용한 윈도우 결정 등의 단계로 구성된다. OL은 위의 과정뿐만 아니라 개



(그림 10) SVM 개념



(그림 11) Object Localization 개념

발자마다 다른 알고리즘이 적용되기도 하며, 추적 (tracking)과 연계되기도 한다.

III. 영상인식 SoC 기술동향

1. 개요

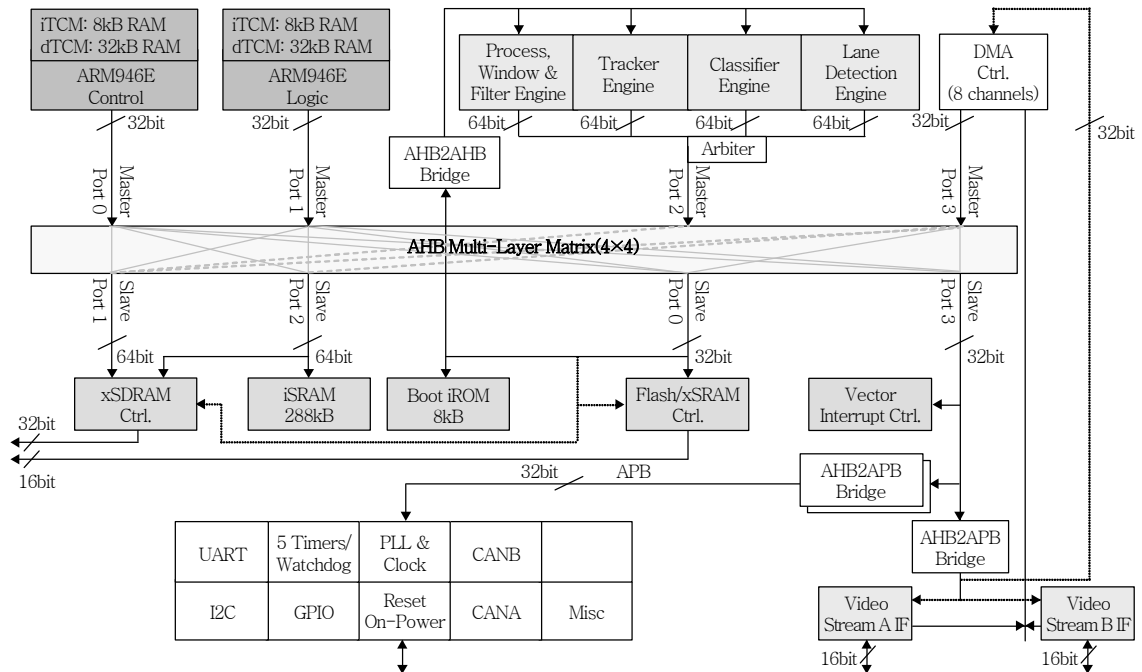
본 절에서는 현재 시판되고 있는 자동차용 영상인식 SoC들을 알아보고 향후의 개발 방향을 전망해 보도록 한다. 자동차용 영상인식 SoC는 Mobileye사의 EyeQ 시리즈를 선두로 NEC와 합병한 Renesas사의 IMAPCAR 시리즈가 추격하고 있는 상황이다. EyeQ 시리즈는 시리즈 1, 2가 이미 차선 검출 등의 안전 시스템에 사용되어 시판되고 있으며, 시리즈 3는 보행자 검출 시스템의 자동차 장착을 위한 테스트 및 제품 생산을 2014년까지 마무리할 계획으로 개발 중에 있다[15]. IMAPCAR 시리즈는 시리즈 1의 경우 차선 검출 시스템의 자동차 장착 및 시판이 이루어졌으며, 용도 및 필요 성능에 따라 칩을 선택할 수 있는 시리즈 2의 경우에는 아직 차량에 장착되어 시판된 예는 없으나 많은 업체에서 본 시리즈를 이용한 제품을 개발하고 있는 것으로 알려져 있다. 국내에서는 한국전자통신연구원과 전자부품연구원에서 공동으로 자동차용 영상 SoC를 개발하고 있다.

어졌으며, 용도 및 필요 성능에 따라 칩을 선택할 수 있는 시리즈 2의 경우에는 아직 차량에 장착되어 시판된 예는 없으나 많은 업체에서 본 시리즈를 이용한 제품을 개발하고 있는 것으로 알려져 있다. 국내에서는 한국전자통신연구원과 전자부품연구원에서 공동으로 자동차용 영상 SoC를 개발하고 있다.

2. Mobileye

가. EyeQ

EyeQ 시스템의 특징은 4개의 영상처리전용 엔진과 시스템의 제어와 응용 프로그램 수행을 위한 듀얼 프로세서를 탑재하고 있다는 것이다. 또한, EyeQ는 (그림 12)에서 보이는 바와 같이 Process, Window & Filter Engine, Tracker Engine, Classifier Engine, Lane Detection Engine을 통해 영상 데이터를 고속으로 처리하고 데이터 전송에 따른 대역폭 확보와 고속 전송을 위하여 AHB Multi-Layer Ma-



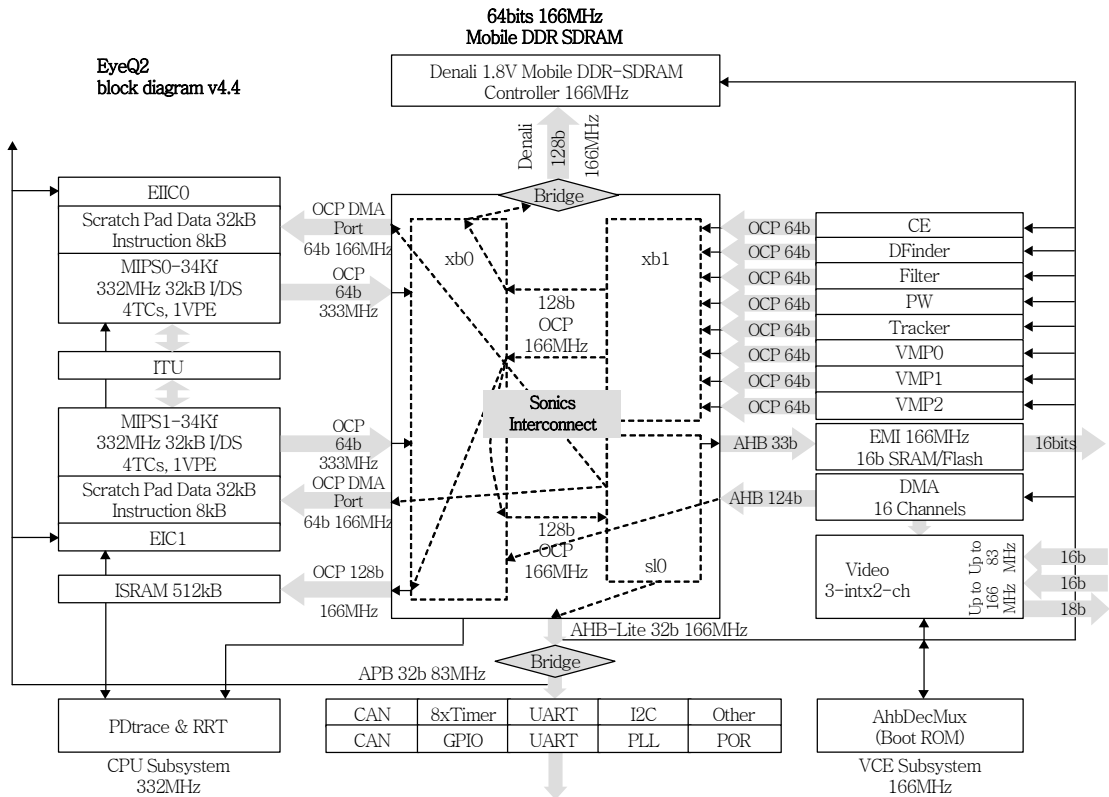
(그림 12) EyeQ의 구조

trix(4×4) 버스와 다채널 DMAC를 적용하고 있다. 스테레오 이미지를 이용한 거리측정 등을 위하여 두 개의 비디오 입력 포트를 제공하며, 차선 검출, 교통 신호 분석, 자동차 검출 등에 응용되었다[16]. 주요 적용 사례를 보면 BMW 6, 7 시리즈의 LDW 시스템, BMW 7 시리즈의 Speed Limit Information, Headlight control 시스템, Volvo S80, V70, XC60, XC70 차량의 Collision Warning with Auto brake, Driver Alert Control, LDW 시스템 등이 있다. 주로 영상을 이용한 차선 및 신호 검출에 사용되고 있으며, 영상과 레이저/라이다를 결합하여 자동차 검출에 사용되기도 하였다. SoC는 0.18 μ m 공정을 사용하여 120MHz에서 동작하도록 설계되었다. 그러나 보행자 인식 및 처리 영상의 크기가 증가하고 보다 빠른 영상처리가 요구되면서 전용엔진의 추가, 알고리즘

적용에 따른 유연성 제공, 데이터 전송 성능의 향상을 도모한 EyeQ2 제품이 개발되었다.

나. EyeQ2

EyeQ2는 (그림 13)와 같이 기존 EyeQ에 비하여 늘어난 영상처리전용 엔진과 고속벡터연산처리를 위한 병렬 프로세서 그리고, 영상인식 응용 시스템의 원활한 제어와 애플리케이션 수행을 위해 멀티-스레딩을 지원하는 듀얼 프로세서를 포함하고 있다. 영상처리전용 엔진으로는 Classifier Engine, Tracker Engine, Pre-Process, Window Engine, Filter Engine, 그리고 Disparity Finder Engine이 있으며, 구형의 유연성을 올리기 위한 병렬 프로세서로 3개의 Vector Micro Processor를 장착하였다[15]. 또한, CPU로는 두 개의 MIPS34K RISC 프로세서가 사용



(그림 13) EyeQ2의 구조

되었으며, 고속 데이터 전송을 지원하기 위하여 Sonics사의 네트워크 인터커넥션을 적용하고 있다. 대표적 적용 사례를 보면 Volvo S60 차량의 LDW, Vehicle Detection, Pedestrian Detection 시스템에 적용되었다. SoC는 90nm 공정을 사용하여 332MHz에서 동작할 수 있도록 설계되었다.

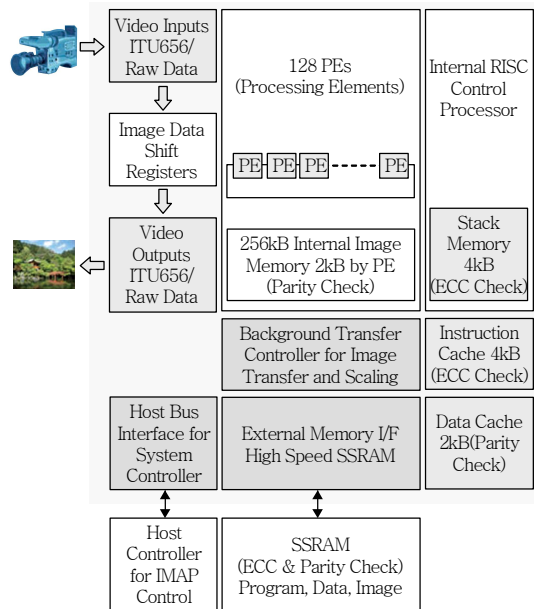
다. EyeQ3

EyeQ 시리즈의 3세대 버전인 EyeQ3이 최근에 개발되고 있다. 이 EyeQ3는 전 시리즈에 비하여 6배 빠른 성능을 보일 것으로 예상된다. 현재 설계가 진행 중이며, 자동차용 반도체 신뢰성 시험 규격인 AEC-Q100에 따라서 2013년에 실차 테스트가 계획되어 있다. EyeQ3는 서라운드 뷰 시스템을 위한 다중 카메라 입력을 지원하고, 4개의 멀티스레드 32비트 프로세서와 더욱 향상된 4개의 VMP를 채택할 것으로 알려졌다. 이러한 시스템을 바탕으로 전방 카메라와 서라운드 카메라 기반의 많은 애플리케이션들을 동시에 지원할 수 있을 것으로 예상된다. 이와 함께 Mobileye사는 EyeQ3-Lite를 개발하여 EyeQ3의 제한된 성능을 지원함으로써 제한된 애플리케이션 수행이 가능한 제품 생산도 계획하고 있다[16].

3. Renesas

가. IMAPCAR

IMAPCAR의 구조는 SIMD 구조의 병렬처리 프로세서에 의한 영상처리를 그 특징으로 한다. IMAPCAR에는 SIMD 구조로 되어있는 128개의 8비트 VLIW PE가 장착되어있으며, PE를 제어하기 위한 16비트 RISC 프로세서와 메모리들로 구성되어 있다. 대표적인 적용 사례로는 Lexus LS460의 Pre-crash safety system을 들 수 있으며, 자동차용 영상인



(그림 14) IMAPCAR의 구조도

식에 주로 사용된다. (그림 14)은 IMAPCAR의 구조도를 나타내고 있다[17].

나. IMAPCAR2

IMAPCAR2의 구조에 있어서는 IMAPCAR와 차별되는 구조적 변화는 찾아보기 힘들다. 그러나 기존의 IMAPCAR에 비하여 개별 프로세서의 성능향상에 중점을 두고 개발되었다. SIMD 구조의 비효율성을 극복하기 위하여 제어 프로세서에 의해 SIMD와 MP를 선택할 수 있는 구조를 적용하였으며, (그림 15)와 같이 64개의 16비트 VLIW PE를 장착하였다. 또한 대용량 데이터 전송 및 저장을 위하여 독립적인 3개의 외부 메모리를 사용함으로써 메모리 대역의 확보를 꾀하고 있다. 이와 같이 IMAPCAR2는 개별 블록의 성능 향상을 통해 IMAPCAR에서 수행되기 힘들었던 보행자 인식 시스템 수행이 가능하도록 데이터 전송능력과 제어 프로세서의 명령 처리 성능을 향상시켰다.

보행자를 90% 이상 인식할 수 있으며, 자동차는 99% 이상 인식이 가능하다.

EVE는 ETRI와 KETI가 공동 개발한 영상인식 SoC에 탑재되었으며, (그림 17)은 EVE를 탑재한 영상인식 SoC 테스트 보드와 테스트 영상에 대한 인식 결과를 보여주고 있다.

IV. 결론

본고에서는 현재 사용되고 있는 기본적인 자동차용 영상인식 알고리즘 및 영상인식 SoC에 대하여 살펴 보았다.

자동차의 보급이 확대되고, 운송수단으로써의 자동차가 아닌 편안하고 안전한 자동차를 추구하는 현대 사회에서 영상인식 기술은 자동차의 지능 고도화를 위한 필수 기술로 판단되며, 후방카메라 장착 의무화 등의 정책에 힘입어 수요시기가 앞당겨질 것으로 예측된다. 본고에서 설명한 인식 알고리즘들은 현재 많은 변형을 거치고 있으며, 슬라이딩 윈도우 기반 deformable part 모델[18]을 적용하는 등 전체와 일부를 동시에 검색하는 형태로 성능을 향상시켜나가고 있다. 따라서, 기본적인 알고리즘은 변화하지 않겠으나 이런 알고리즘들의 운용은 개발자 및 시대에 따라서 끊임없이 변화할 것으로 예측되며 이로 인해 영상인식 SoC는 기본적인 인식 엔진에 유연성을 보완할 연산 집중형 프로세서를 장착하는 형태로 발전될

것으로 예측된다.

향후 주요 응용 분야로 예상되는 보행자 검출을 위해서는 아직 알고리즘의 성능 향상과 이를 위한 SoC의 연산 성능 향상이 필요한 상황이며, 이를 위한 연구가 계속될 것으로 예상된다.

약어 정리

ACC	Adaptive Cruise Control
BSD	Blind Spot Detection
CoHOG	Co-occurrence HOG
EPS	Electric Power Steering
ESC	Electronic Stability Control
EVE	ETRI Vision Engine
FCW	Forward Collision Warning
FPPW	False Positive Per Window
HOG	Histogram of Oriented Gradients
LBP	Local Binary Pattern
LDWS	Lane Departure Warning System
LRR	Long Range Radar
MP	Multi-Processor
OL	Object Localization
PE	Processing Element
RBF	radial basis function
RISC	Reduced Instruction Set Computer
ROI	Region of Interest
SIMD	Single Instruction Multiple Data
SRR	Short Range Radar
SVM	Support Vector Machine
VMP	Vector Micro Processor
VLIW	Very Long Instruction Word

참고 문헌

- [1] 자동차부품연구원, 미래형자동차사업단, “미래형 자동차 개발 현황,” 미래형자동차사업단 기획 보고서, 2007.
- [2] 황준연, “스마트자동차를 위한 충돌안전 확보기술,” 제5회 자동차 전자기술 워크숍, 2011, pp. 19-31.
- [3] AsiaNet, “Mobileye’s System-on-Chip EyeQ2 and Computer Vision Algorithms Power the In-

● 용 어 해 설 ●

영상인식추출기: 영상을 이용하여 사물을 인식하기 위하여 영상으로부터 특징을 추출하여 특정 형태의 벡터로 변환해 주기 위한 장치

영상인식분류기: 영상을 이용하여 사물을 인식하기 위하여 추출된 특징 벡터를 입력으로 하여 인식 대상인지의 여부를 검사하기 위한 장치

- novative Forward Collision Warning (FCW) System in the new BMW 1-Series,” Jerusalem, Sept. 28th, 2011.
- [4] 전자신문, “美 안전 규제 강화로 자동차 후방 카메라 시장급성장,” 2011. 1. 6.
- [5] N. Dalal, “Finding People in Images and Videos,” Institut National Polytechnique De Grenoble, France, Thesis, 2006.
- [6] C. Papageorgiou, M. Oren, and T. Poggio, “A General Framework for Object Detection,” *IEEE Int. Conf. Comput. Vision*, 1998.
- [7] P. Dollar, S. Belongie, and P. Perona, “The Fastest Pedestrian Detector in the West,” *Br. Mach. Vision Conf.*, 2010.
- [8] P. Viola and M. Jones, “Robust Real-time Face Detection,” *Int. J. Comput. Vision*, vol. 57, no. 2, May 2004, pp. 137-154.
- [9] N. Dalal and B. Triggs, “Histograms of Oriented Gradients for Human Detection,” *IEEE Conf. Comput. Vision Pattern Recognit.*, 2005.
- [10] H. Ren et al., “Fast Object Detection Using Boosted Co-occurrence Histograms of Oriented Gradients,” *IEEE Int. Conf. Image Process.*, 2010.
- [11] X. Wang, T.X. Han, and S. Yan, “An HOG-LBP Human Detector with Partial Occlusion Handling,” *IEEE Int. Conf. Comput. Vision*, 2009.
- [12] Y. Zheng, C. Shen, and X. Huang, “Pedestrian Detection Using Center-Symmetric Local Binary Patterns,” *IEEE Int. Conf. Image Process.*, 2010.
- [13] D.T. Nguyen et al., “Object Detection Using Non-Redundant Local Binary Patterns,” *IEEE Int. Conf. Image Process.*, 2010.
- [14] C. Cortes and V. Vapnik, “Support-vector Networks,” *Mach. Learning*, 1995, pp. 273-297.
- [15] STMicroelectronics, “STMicroelectronics and Mobileye to Develop Third-Generation System-on-Chip Family for Vision-Based Driver Assistance Systems,” Geneva and Jerusalem, Oct. 4th, 2011.
- [16] Mobileye web site. <http://www.mobileye.com>
- [17] Renesas web site. <http://www.renesas.com>
- [18] P.F. Felzenszwalb et al., “Object Detection with Discriminatively Trained Part Based Models,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 32, no. 9, Sept. 2010, pp. 1627-1645.