

ICT 기술을 융합한 자동차 실러도포 공정 모니터링 시스템*

김호연** · 박종섭** · 박요한** · 조재수***

Car Sealer Monitoring System Using ICT Technology*

Ho Yeon Kim** · Jong Seop Park** · Yo Han Park** · Jae-Soo Cho***

■ Abstract ■

In this paper, we propose a car sealing monitoring system combined with ICT Technology. The automobile sealer is an adhesive used to bond inner and outer panels of doors, hoods and trunks of an automobile body. The proposed car sealer monitoring system is a system that can accurately and automatically inspect the condition of the automobile sealer coating process in the general often factory production line where the lighting change is very severe. The sealer inspection module checks the state of the applied sealer using an area scan camera. The vision inspection algorithm is adaptive to various lighting environments to determine whether the sealer is defective or not. The captured images and test results are configured to send the task results to the task manager in real-time as a smartphone app. Vision inspection algorithms in the plant outdoors are very vulnerable to time-varying external light sources and by configuring a monitoring system based on smart mobile equipment, it is possible to perform production monitoring regardless of time and place. The applicability of this method was verified by applying it to an actual automotive sealer application process.

Keyword : Car Sealing, Monitoring System, Vision Inspection, Smartphone App


1. 서 론

최근 10년 동안 산업 자동화와 더불어 공산품의 품질에 대한 인식이 날로 증가하면서 품질 향상에 도움이 되는 비전 검사 장비에 대한 수요가 급격하게 증대되고 있다. 일반적인 비전 불량 검사는 외부의 다양한 조명영향을 차단하는 실딩 구조 내에서 일정한 조명환경을 유지한 후 시료의 불량을 검사하는 것에 반해, 국내 대부분의 생산 제조현장에서는 일정한 조명환경을 구축하는 것에 대한 높은 비용과 시간 투자를 못하고 있다.

본 논문에서는 위의 문제점들을 해결하기 위해 다양한 가변적인 외부 조명환경에서도 응용 가능한 학습 기반 비전 검사 알고리즘과 실시간 모니터링 기능을 할 수 있는 ICT 기술을 이용하여 기존의 생산성을 유지하면서 제품의 품질을 높일 수 있는 방법을 제안하고자 한다.

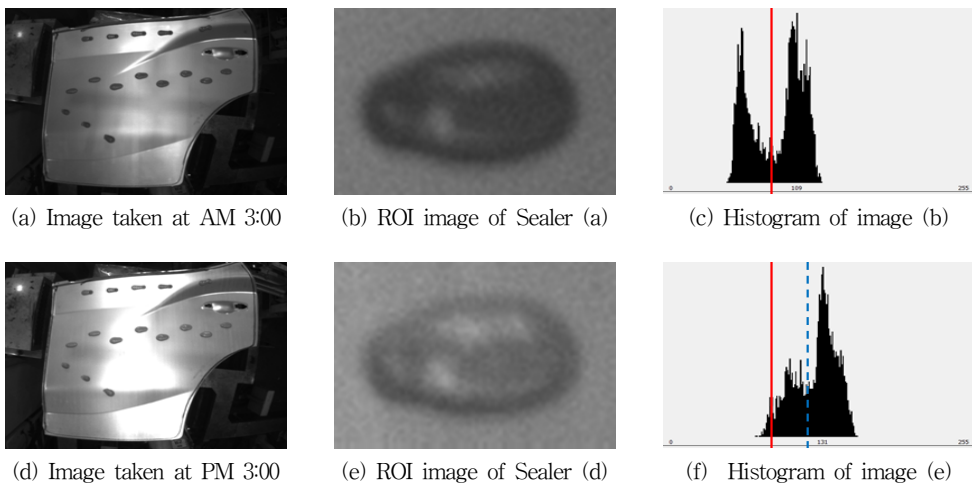
<Figure 1>과 <Figure 2>는 실제 자동차 도어프레임 실러도포 공정에서 시간에 따라 매우 가변적인 조명환경을 잘 보여주고 있다.

<Figure 1>은 시간대별로 촬영한 자동차 실러 이미지이며 <Figure 2>는 14시간 동안 총 129개의 자동차 실러도포 이미지의 밝기 값 표준편차를 그림으로 나타낸 것이다. 이러한 가변적인 조명 상황에서 정적인 비전 처리 알고리즘으로는 실러도포 상태

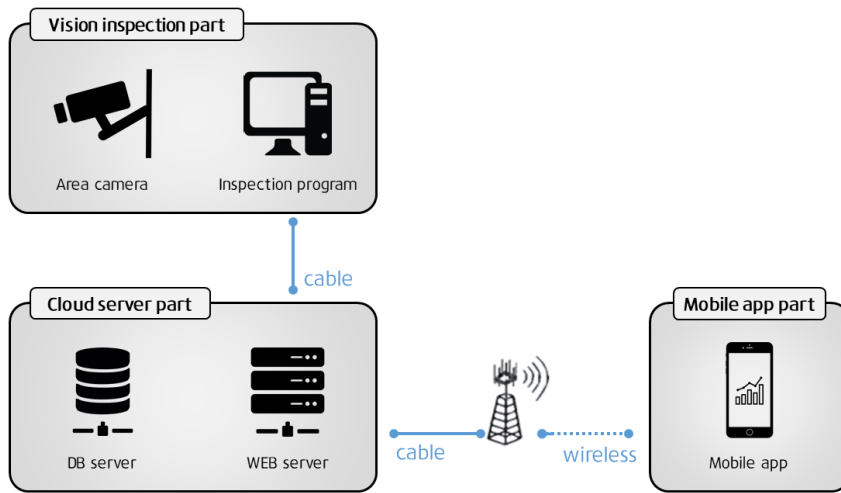


<Figure 2> Standard Deviation of Brightness Value of Car Sealer

를 정확하게 판단할 수 없기 때문에 실제 생산현장에 비전검사 장치를 설치할 수 없는 문제점이 있다. 본 논문에서는 실러도포의 불량 판단 상태를 OK와 NG 그리고 사람의 판단이 필요한 ING 상태로 구분하여 판단한다. OK 상태는 비전알고리즘으로 정확하게 70% 이상의 확신을 가진 양품상태를 의미하고, NG 상태는 확실한(약 70% 이상) 불량 상태를 의미한다. 본 논문에서 추가적으로 제안하는 ING 상태는 비전알고리즘으로는 정확하게 판단할 수 없는 상태를 의미하고, 사람이 직접 눈으로 판단하여야 하는 상태를 의미한다. 24시간 In-Line으로 생산되는 공장에서 제안하는 ING 상태는 비전검사 장비의 효율성을 높이면서 제품의 품질을 높일 수 있는 새로운 방법이라고 판단된다.



<Figure 1> Sealer Images Taken by Time and Histograms of Sealer Images



<Figure 3> Proposed Vision Inspection System for Car Sealing Application

또한 본 논문에서는 비전 알고리즘 뿐 아니라, 클라우드 서버와 모바일 앱을 활용한 원격 모니터링 시스템도 함께 제안한다. 비전 검사 결과인 OK 상태를 제외한 NG와 ING는 빈번히 발생하지 않으므로, 작업자는 원격에서 모바일을 통해 모니터링을 하면서 작업자의 개입이 필요할 때에 Push 알림을 보내 실시간 불량 상황을 모니터링 할 수 있다.

2. 제안하는 실러 도포 비전검사 시스템


본 논문에서 제안하는 전체적인 실러 도포 비전 검사 시스템은 <Figure 3>과 같다. 비전 검사부에서 새로운 검사 시료가 들어와 검사 시작 트리거 신호를 받게 되면 자동차 실러의 도포상태를 통해 불량 유무를 검사한다. 검사가 완료되면 <Figure 3>과 같은 시스템 구성도에 따라 클라우드 웹서버로 검사 결과 데이터를 전송한 뒤, 불량률의 유/무에 따라 스마트폰 앱으로 PUSH 알림을 보낸다.

2.1 비전검사부

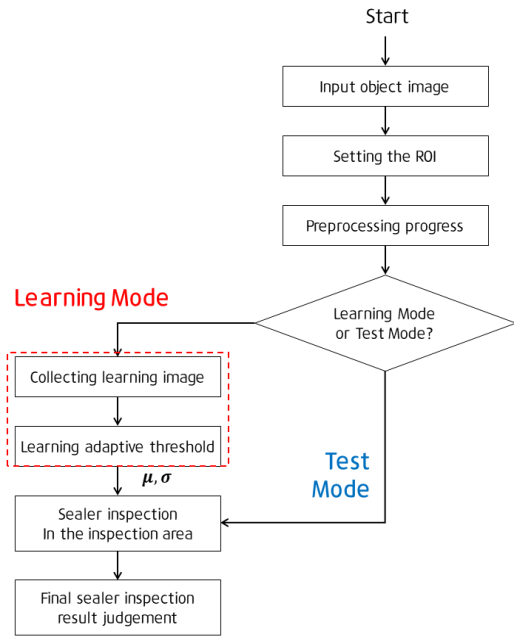
비전 검사부에선 영역스캔 CCD 센서를 통해 획득된 영상을 통해 <Figure 4>의 ROI에 실러가 도포되어 있는 실러 불량 유무를 판별한다. <Figure

1(b)>, <Figure 1(d)>와 같이 같은 모델의 실러이지만 시간 별 외부 조명의 영향이 다르기 때문에, 영상의 밝기 분포가 전혀 다른 양상을 보인다. 한 예로 <Figure 1(c)>의 영상에 대한 실러를 배경으로부터 분리할 수 있는 Otsu 기법의 임계값은 82에 반해, <Figure 1(f)>의 Otsu 기법의 임계값은 108이다.

위 예를 통해 하나의 비전처리 임계값으로 모든 검사환경에서 사용하기 어렵다는 것을 알 수 있다. 따라서 본 논문은 위의 문제점을 해결하기 위해 학습기반 비전 검사 알고리즘을 제안한다.



<Figure 4> Car sealer ROI(Region Of Interest)



〈Figure 5〉 Proposed Vision Processing Algorithm Flow Chart

비전 검사를 하기 위해선 기준(레퍼런스) 영상들이 학습이 되어 있어야한다. 레퍼런스 영상이란 실러도포에 문제없는 양품의 영상을 시간대 별 학습시킬 이미지이며, 〈Figure 5〉의 학습 모드와 같은 처리 순서도를 따른다.

실러도포 ROI 영역의 밝기값 상태를 학습하기 전 영상에서 노이즈를 제거하고 ROI 영역내 밝기값을 표준화 하여 실러와 배경을 확실하게 분리해내기 위한 영상 전처리 과정을 진행한다. 전처리 필터로 가우시안 필터를 사용하여 저주파 영상을 생성하였고, 원본 영상에서 저주파영상을 뺀 뒤 저주파영상의 평균값을 구하였다. 가우시안 필터로 구한 영상 식 (1) $G_{x,y}$ 와 전처리 영상 식 (2) $C_{x,y}$ 는 다음과 같다.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (1)$$

$$C(x, y) = I(x, y) - G(x, y) + \frac{\sum_1^{r*c} G(x, y)}{r*c} \quad (2)$$

전처리가 완료된 영상에서 이진화를 하여 실러와 배경을 구분한다. Otsu 기법은 분산을 통해 두 클래스를 구분하는데 최적의 임계값을 계산하기 때문에 본 논문은 Otsu 기법을 사용하여 이진화 영상 $O_{x,y}$ 를 생성하였다. Otsu 기법은 식 (3)과 같이 두 클래스간 분산 σ_b^2 이 최대가 되는 임계값을 찾아 해당 값을 기준으로 이진화를 진행한다(cf. 〈Figure 1(c)〉 참조).

$$\sigma_b^2 = \text{argmax}(\omega_1(\mu_1 - \mu_T)^2 + \omega_2(\mu_2 - \mu_T)^2) \quad (3)$$

매우 다양한 가변적인 조명환경에서 하나의 임계값으로 모든 테스트 영상을 만족할 수 없다. 따라서 본 논문은 양품인 다양한 조명의 학습영상에 대한 밝기 값 히스토그램 분포를 이용하여 실러도포에 대한 밝기 임계값의 범위를 적응적 최적 계층화(adaptive optimal layering)로 결정하게 된다.


적응적 최적 계층화란 학습된 여러 영상들의 최적 임계값을 기반으로 한 새로운 영상 이진화 방법이다. 기존 임계값으로 이진 영상을 생성하지 않고, 식 (7)과 같이 일정 범위 내를 기준으로 이진화를 진행한다. 〈Figure 6〉는 다양한 조명의 학습영상에 대한 밝기 값 히스토그램을 보여주고 있다. 〈Figure 6〉에서 2σ 는 임계값의 범위를 나타내며, 이 안에 들어오는 밝기 값은 실러로 인식한다.

Otsu 기법으로 이진화 된 영상 $O_{x,y}$ 에서 실러가 차지하는 면적의 밝기 합의 평균은 histMean이라 하며 제곱 합의 평균을 histSqMean으로 하여 이진화된 영역의 원본 밝기 합을 구한다.

$$\text{histMean} = \frac{\sum_{\text{histCount}} C_{x,y}}{\text{histCount}}, O_{x,y} = 0 \quad (4)$$

$$\text{histSqMean} = \frac{\sum_{\text{histCount}} (C_{x,y})^2}{\text{histCount}}, O_{x,y} = 0$$

실러 학습은 여러 장을 기준으로 하므로 정규화 과정이 필요하다. 각 영상들의 histMean과 histSqMean의 평균을 식 (5)와 같이 구하여 최종 실러영역의 밝기 값 표준편차 σ 를 구한다.



〈Figure 6〉 Adaptive Threshold Range Using Histogram Distribution

$$\text{hist.SumMean} = \frac{\sum_{\text{image Count}} \text{histMean}_i}{\text{image Count}} \quad (5)$$

$$\text{hist.SqSumMean} = \frac{\sum_{\text{image Count}} \text{histSqMean}_i}{\text{image Count}}$$

$$\sigma = \sqrt{\text{hist.SqSumMean} - (\text{hist.SumMean})^2} \quad (6)$$


실제 입력영상에 대한 실러도포의 비전 검사 또한 기준영상 학습과 동일한 전처리 절차를 가지며 〈Figure 5〉의 검사 모드와 같은 처리 순서도를 따른다. 학습을 통해 계산된 밝기 값의 평균 μ 와 표준편차 σ 를 사용하여 검사 영상에서 실러의 양을 계산하고 다음과 같이 최종 검사 파라미터를 계산한다. 식 (8)에서 R_0 는 검사하고자 하는 ROI 면적에서 학습과정에서 양품으로 결정된 실러면적을 나타내고, R_1 은 실제 검사영상에서 ROI 면적대비 검사 실러 면적을 계산하는 식이다. 이러한 두 실러면적 대비 식 (9)를 이용하여 최종적인 OK, ING, NG 상태를 판단하게 된다.

$$B_i = \begin{cases} 1, & \mu - \sigma \leq I_{x,y} \leq \mu + \sigma \\ 0, & \text{otherwise} \end{cases} \quad (7)$$

$$\frac{(\text{학습실러면적})}{(\text{ROI면적})} = R_0, \quad (8)$$

$$\frac{(\text{검사실러면적})}{(\text{ROI면적})} = R_1$$

$$\frac{R_1}{R_0} = R = \begin{cases} \text{OK}, & R > th_{ok} \\ \text{ING}, & th_{ok} > R > th_{ing} \\ \text{NG}, & \text{otherwise} \end{cases} \quad (9)$$



〈Figure 7〉 3-Level Vision Test Results

검사 결과 파라미터는 OK, ING, NG로 총 3단계로 판단하며, 3단계를 나누는 기준은 〈Figure 7〉과 같다. 해당 그림에서 신뢰도는 기존 학습 실러 면적 대비 검사 실러 면적 R 이며, 사용자의 판단과 검사 환경에 따라 신뢰도 비율을 수정할 수 있다.

OK는 학습 데이터 대비 검사 데이터의 신뢰도가 70% 이상으로 정상적으로 도포된 상태를 의미하며, ING 상태는 신뢰도가 50~70%로 사람의 확인이 필요한 상황이다. 이 경우 작업공정을 멈추지 않고, 원본영상/결과영상을 관리자의 스마트폰으로 전송하여, 양품/불량을 직접 판단한다. NG 상태는 불량일 가능성이 70% 이상으로 도포된 상태를 뜻하며 작업공정을 즉시 중단한다. 그리고 ING 상태와 마찬가지로 검사영상/결과영상을 관리자의 스마트폰으로 전송한다.

2.2 클라우드 서버부

비전 검사부로부터 검사 데이터를 수신 받는 서버부는 WEB서버와 DB서버로 구성되어 있다. WEB서버는 외부 단말과 인터페이스를 위한 서버이며 DB서버는 데이터를 취합 및 관리하기 위한 서버이다. 본 논문에서 제안하는 시스템에서 사용된 서버는 Spring framework를 기반으로 한 Java Web



(a) Error checking

(b) State by time

(c) State by date

(d) Live streaming

〈Figure 8〉 Smartphone Monitoring Application

Server이며, DBMS는 MariaDB를 사용하였다. 모바일 어플리케이션에서 데이터를 요청할 경우 WEB 서버는 DB서버에 데이터를 검색하여 전송한다. 클라우드 서버부의 추가적인 역할은 추 후 과제로 남겨놓았다.

2.3 모바일 어플리케이션부

모니터링 관리자는 모바일 어플리케이션을 통해 시간과 공간에 제약받지 않으며 데이터들을 열람할 수 있으며, 현 공정진행상황을 모니터링 할 수 있다.


〈Figure 8〉은 모바일 어플리케이션의 캡처 화면이다. 〈Figure 8(a)〉와 같이 하루 동안의 알람을 받아 볼 수 있다. 검사 결과가 NG나 ING인 알람들은 관리자의 어플리케이션 조작을 통해 피드백 및 에러 확인을 할 수 있다. 〈Figure 8(b)〉는 특정 날짜의 하루 공정 데이터 그래프이다. 각 장비별 개별 그래프로 나타낼 수 있어 특정 시간대의 에러들을 나타내며 이러한 지표들은 학습이 잘 되었는지 관리자에게 확인시켜준다. 〈Figure 8(c)〉는 날짜별 에러율을 확인 할 수 있는 달력 UI이며, 〈Figure 8(d)〉는 현 가동 중인 장비들의 실시간 스트리밍 환경을 제공하여 준다.

3. 실험 결과


제안하는 자동차 실러 도포 검사 알고리즘의 성능 평가는 〈Figure 9〉와 같이 실제 (주)네오텍 공장 생산라인에 설치된 비전 검사 장비에서 실험하였다. 생산라인에 설치된 자동차 실러 도포 검사 비전 검사 장비의 구성은 산업용 카메라세트와 PC 기반의 비전 검사 응용 프로그램으로 구성되어 있다. 〈Figure 10〉은 비전 검사 응용 프로그램으로 실험 한 결과 영상이며 총 80개의 ROI가 설정되어 있다.



〈Figure 9〉 Sealer Vision Inspection Equipment Installed on NEOTEC Factory Production Line



(a) Image of 'ING' result



(b) Image of 'NG' result

<Figure 10> Images of Vision Test Result

<Table 1> Vision Test Result of 129 Sealer Applications

	OK	NG	ING	Accuracy	Time
Ground Truth	127	1	1	-	-
Thresholding($\tau = 80$)	78	5	46	62%	57ms
Proposed	127	1	1	100%	274ms

실험은 오전 3시부터 오후 5시까지 총 14시간동안 생산된 총 129개의 자동차 도어 프레임의 실리도포 검사 결과를 나타내었으며, 실험 방법은 본 논문에서 제안하는 이진화 알고리즘과 식 (9)와 같이 특정 임계값($\tau=80$)을 통한 이진화 방법을 비교하여 검증한다.

$$I(x,y) = \begin{cases} 255, & I(x,y) > \tau \\ 0, & I(x,y) \leq \tau \end{cases} \quad (9)$$

<Table 1>에서 제안하는 알고리즘의 검사 소요시간(TACT Time)은 평균 274ms이다. 자동차 도어 프레임은 1pc/min의 속도로 생산되기에 전체 공정에서 비전 검사의 소요시간은 영향을 주지 않는다.

<Table 1>에 대한 성능 평가는 대표적인 공정상 불량률을 계산하는 지표로 FPR(False Positive Rate)과 FNR(False Negative Rate)을 통해 정확도를 도출하였다. FPR이란 불량으로 판정된 전체 불량률의 수에서 실제 양품인 비율 즉, 가상불량이라 한다. FNR이란 실제 불량품을 양품으로 잘못 판정하는 비율이다. 식 (10)과 식 (11)은 FPR과 FNR에 대한 정의이다.

$$FPR = \frac{FP}{FP+TN} \quad (10)$$

$$= \frac{\text{불량으로 판정된 제품중 양품개수}}{\text{불량으로 판정된 전체 불량개수}}$$

여기서 FP : 불량으로 잘못 판정된 양품 수

TN : 실제 불량률 불량으로 정확하게 판정한 양품 수

$$FNR = \frac{FN}{FN+TP} \quad (11)$$

$$= \frac{\text{양품으로 판정된 제품중 불량개수}}{\text{양품으로 판정한 전체 양품개수}}$$

여기서 FN : 양품을 불량으로 판정한 양품 수

TP : 실제 양품을 양품으로 정확하게 판정한 양품 수

본 논문에서 실험된 FPR과 FNR의 계산 결과는 <Table 2>에 정리하였다.

<Table 2> FPR and FNR on Measurement Results

Unit(10^{-1})	Thresholding	Proposed
FPR	9.607	0
FNR	0	0

4. 결론 및 추후과제

본 논문에서는 실제 산업 현장에서 사용되는 비전 검사 시스템을 바탕으로 자동차 실러 도포 공정의 자동화와 ICT 기술을 활용한 실러도포 품질검사 모니터링 시스템을 제안하였다. 본 논문에서 제안된 비전 검사 알고리즘은 다양한 외부 조명의 영향을 학습 기반의 적응적 임계값(adaptive optimal layering)을 통해 충분히 극복할 수 있다는 점에서 의미가 있다고 할 수 있다.

학습 기반의 비전 검사 알고리즘이 정상적으로 수행되기 위해선 충분한 학습 데이터가 필요하다. 따라서, 본 논문에서 연구된 비전 알고리즘은 산업 현장에서 충분한 학습 데이터가 쌓인 후 사용이 가능하다. 향후 과제로 이미지 확대(Image Augmentation)를 이용하여 학습 데이터 확대에 대해 연구할 예정이다.

본 논문에서 제안된 알고리즘은 극적인 조명변화가 아닌, 부분적·점진적 조명변화로, 시간에 따른 영상 밝기 변화가 매우 큰 편이 아니다. 향후 과제로 시간별 학습을 통해 극적인 조명변화에서도 강인한 알고리즘을 개발 할 필요가 있다. 또한 클라우드 서버는 검사 결과를 저장하고, 아무런 가공 없이 데이터를 모바일 어플리케이션으로 전송한다. 향후 과제로 제안된 클라우드 서버의 역할을 보다 확장시켜 검사결과와 데이터를 분석 및 가공의 역할을 하도록 개선해나갈 예정이다.

References

- Kim, G.S., Y.H. Park, J.S. Park, and J.S. Cho, "Auto Parts Visual Inspection in Severe Changes in the Lighting Environment", *Robotics and Systems*, Vol.21, No.12, 2015, 1109-1114.
- Babaud, J., A.P. Witkin, M. Baudin, and R.O. Duda, "Uniqueness of the Gaussian Kernel for Scale-Space Filtering", *IEEE Transactions on Pattern Analysis & Machine Intelligence*, Vol.1, 1986, 26-33.
- Kumar, A., Y. Bar-Shalom, and E. Oron, "Precision Tracking Based on Segmentation with Optimal Layering for Imaging Sensors", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.17, No.2, 1995, 182-188.
- Otsu, N., "A Threshold Selection Method from Gray-Level Histograms", *IEEE Transactions on Systems, Man, and Cybernetics*, Vol.9, No.1, 1979, 62-66.
- Perez, L. and J. Wang, "The Effectiveness of Data Augmentation in Image Classification using Deep Learning", *arXiv preprint arXiv*, 1712.04621, Dec 2017.
- Thames, L. and D. Schaefer, "Cybersecurity for Industry 4.0 : Analysis for Design and Manufacturing", 2017, 255.

◆ About the Authors ◆



Ho Yeon Kim (kimhoyun77@koreatech.ac.kr)

Ho Yeon Kim received the BS degree in Computer Engineering from Koreatech in 2017, and he is currently a master's course in Computer Engineering at Koreatech and His current research interests include Machine Vision, Deep Learning, Patten Recognition.



Jong Seop Park (pjs0329s@koreatech.ac.kr)

Jong Seop Park received the M.S degree in Computer Engineering from Koreatech in 2016, and he is currently doctor's course in Computer Engineering at Koreatech and he His current research interests include Pattern Recognition, Machine Learning, Android Programming.



Yo Han Park (a22120@koreatech.ac.kr)

Yo Han Park received the B.S degree in Computer Engineering from Koreatech in 2017. His current research interests include Software Optimization, Machine Learning.



Jae-Soo Cho (jaesoo27@koreatech.ac.kr)

Professor Jae-Soo Cho received the Ph.D. degree in Signal Processing from Korea Advanced Institute of Science and Technology (KAIST) in 2001. He has been working for Koretech since 2003. His current research interests include Automatic Video Tracking, Visual Surveillance, Pattern Recognition, Machine Learning.