

# A Study on Jaundice Computer-aided Diagnosis Algorithm using Scleral Color based Machine Learning

Jin-Gyo Jeong\*, Myung-Suk Lee\*\*

## Abstract

This paper proposes a computer-aided diagnostic algorithm in a non-invasive way. Currently, clinical diagnosis of jaundice is performed through blood sampling. Unlike the old methods, the non-invasive method will enable parents to measure newborns' jaundice by only using their mobile phones. The proposed algorithm enables high accuracy and quick diagnosis through machine learning. In here, we used the SVM model of machine learning that learned the feature extracted through image preprocessing and we used the international jaundice research data as the test data set. As a result of applying our developed algorithm, it took about 5 seconds to diagnose jaundice and it showed a 93.4% prediction accuracy. The software is real-time diagnosed and it minimizes the infant's pain by non-invasive method and parents can easily and temporarily diagnose newborns' jaundice. In the future, we aim to use the jaundice photograph of the newborn babies' data as our test data set for more accurate results.

▶ Keyword: Machine Learning, Jaundice, Computer-aided Diagnosis, Non-invasive

## I. Introduction

신생아에서 주로 발생하는 황달은 소아과 외래에서 흔히 보는 증상 중의 하나이다. 황달은 피부나 공막에 담즙색소(빌리루빈)이 필요 이상으로 몸에 과다하게 쌓여 눈 흰자위, 점막, 피부, 등에 노랗게 착색되는 것을 말한다. 이는 만삭아의 60%, 미숙아의 80% 정도 발견 된다[1]. 신생아에서 황달은 혈액색소의 70%를 차지하는 주성분인 Hb F의 수명이 상대적으로 짧은 이유와 신생아 간이 빌리루빈을 제거하는 능력이 저하되는 원인으로 보고 있다[2]. 핵 황달은 황달의 합병증 중 하나로 전 세계 신생아의 13%가 앓고 있고, 사망률은 75%로 매우 높다. 또한 생존 시에도 뇌신경 손상으로 인한 후유증이 24%를 차지한다. 핵 황달로 인한 병원비는 2016년 통계청 자료에 의하면 연간 106억 정도가 사용되고 있다[3].

황달의 1차적 진단은 피부, 공막, 소변 등의 색 변화를 통해 육안으로 한다. 하지만 피부색으로 황달을 진단하는 데에는 한계가 존재한다[4]. 피부색은 멜라닌 색소량에 따라서 사람마다 피부의 색이 다르게 나타나며 베타카로틴이 풍부한 음식을 과다 섭취할

경우 황달과 비슷하게 피부색이 노란빛을 띤다. 특히 피부색을 결정하는 멜라닌의 영향은 황달을 진단하는데 있어서 인종간의 차이를 나타낸다. 피부의 색으로 정확한 황달을 판단하기는 어렵다 [5,6].

하지만 공막 색은 인종에 관계없이 흰색을 띄고 있으며 멜라닌 색소나 음식 등의 인체내부, 외부 혼란인자의 영향을 받지 않아 빌리루빈이 침착되어 노랗게 변화되었을 시 가장 정확하게 황달을 진단 할 수 있다. 또, 공막 색을 기반으로 황달을 진단하는 방법은 비침습적이고, 비접촉성을 가져 진단 시 발생하는 고통을 최소화하며 감염의 위험도 현저히 낮출 수 있으며, 공막색은 인체의 내·외부의 혼란인자의 영향을 최소화할 수 있다[7].

이에 본 연구는 공막 색을 통하여 신생아 황달의 진단을 위한 시스템을 개발하기 위해 영상의 전처리 과정에서 공막 추출 알고리즘을 개발하고 이미지를 이용하여 기계학습 기반의 병변 진단 알고리즘을 연구하였다.

---

• First Author: Jin-Gyo Jeong, Corresponding Author: Myung-Suk Lee  
\*Jin-Gyo Jeong (wlsry4008@gmail.com), Undergraduate, Department of Biomedical Engineering, Keimyung University  
\*\*Myung-Suk Lee (mslee@kmu.ac.kr), Tabula Rasa College, Keimyung University  
• Received: 2018. 09. 20, Revised: 2018. 10. 30, Accepted: 2018. 11. 12.

## II. Related works

### 1. Percutaneous Bilirubin System

황달의 원인으로 알려진 빌리루빈 수치를 비침습적인 방법으로 예측하기 위해 해외에서 여러 연구가 진행되고 있다. BiliCheck 이라는 연구는 경피적 빌리루빈 측정 기기를 개발하여 빌리루빈 수치를 예측하였는데 이는 피부에 특정 주파수 대역의 광선을 쏘아 돌아오는 파장을 이용하여 예측한 빌리루빈 수치가 총 혈청 빌리루빈 수치와 90%이상 일치하는 것으로 결과가 나왔다[8]. 하지만 경피적 빌리루빈계는 고가의 장비이다 보니 일반인들이 사용하기에는 어려움이 있다.

### 2. Smartphone-based Sensors and Cameras

'BiliCheck' 연구를 통하여 피를 채취하지 않아도 빌리루빈 수치를 알 수 있다는 연구 결과를 통하여 워싱턴 대학에서 휴대용 카메라를 이용한 빌리루빈 수치를 예측하는 애플리케이션 'Bilicam'이 개발되었다[9]. Bilicam은 아기의 배 위에 색 보정 카드를 올려놓고 사진을 찍음으로 빌리루빈 수치를 측정하는데 백인을 제외한 나머지 인종들의 빌리루빈 수치 예측 정확도가 20%를 넘지 못하여 백인들에게만 사용하기 적합하다는 단점이 존재한다.

## III. Background

### 1. Classification Algorithm

분류 알고리즘은 구분되지 않은 전체 데이터를 학습과정을 통해 비슷한 속성을 지니고 있는 데이터들로 나누는 방법을 익힌 후, 새로 받아들이는 데이터를 학습한 기준에 따라 분류하는 것을 의미한다. 본 논문에서는 분류 알고리즘 중 가장 대표적이면서도 널리 이용되는 kNN(k-nearest neighbor) 알고리즘과 SVM(support vector machine)을 사용하였다.

kNN알고리즘은 새로 받아들인 데이터를 판단해야 할 경우, 기준에 학습한 데이터와 비교하여 거리상 가까운 거리의 데이터의 분류값으로 받아들인다. 데이터들의 거리를 구할 때 다음과 같은 유클리디안 거리(식1)를 사용한다[10].

$$dist(p,q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} \quad (1)$$

SVM은 이질적인 서로 다른 집단간의 상대적인 거리를 최대화 할 수 있는 기준면을 통해 분류한다. 두 속성은 데이터 중에서 서로 가장 바깥쪽에 위치하고 있는 경계점을 서포트 벡터라고 하고 이들 간의 거리를 최대화할 수 있는 경계선을 서포트 벡터 머신 이라고 한다.

데이터를 한 직선으로 구분하기 힘들 때 고차원 공간으로 데

이터의 위치를 이동하여 분류하기도 하는데 이 경우 커널 함수를 사용한다. 커널 함수 중에 가장 대표적으로 사용되는 RBF(Radial Basic Function kernel)이며 수식은 다음과 같다.

$$k(x^{(i)}, x^{(j)}) = e^{-r \sum (x^{(i)}, x^{(j)})^2} \quad (2)$$

SVM은 명백한 이론적 근거에 기반을 두므로 결과 해석이 용이하고 적은 학습 데이터만으로도 효과가 있으며, 인공 신경망 수준의 성능을 보인다는 장점이 있다.

### 2. Machine Learning

기계학습은 표본 데이터와 같은 과거의 경험을 바탕으로 컴퓨터가 최적의 성능을 갖도록 계획하는 일로 정의된다.[9] 기계 학습의 기법은 지도학습, 비 지도학습, 강화학습 으로 나누어진다.

지도학습은 정답(라벨이 있는 경우)을 알려주며 학습시키는 것이다. 지도학습에는 크게 분류와 회귀가 있다. 분류에는 이진 분류와 다중 분류가 있는데 이진 분류는 어떤 데이터에 대해 두 가지 중 하나로 분류할 수 있는 것을 말하고 다중 분류는 어떤 데이터에 대해 여러 값 중 하나로 분류할 수 있는 것을 말한다. 마지막으로 회귀는 어떤 데이터들의 특징을 토대로 값을 예측하는 것이다.

비 지도학습은 정답을 따로 알려주지 않고(라벨이 없는 경우), 데이터를 간의 값을 비교하여 비슷한 데이터들을 군집화하는 것이다.

강화학습은 에이전트가 주어진 환경에 대해 어떤 행동을 취하고 이로부터 어떤 보상을 얻으면서 학습을 진행한다. 이때, 에이전트는 보상을 최대화하도록 학습이 진행된다. 즉, 강화학습은 일종의 동적인 상태에서 데이터를 수집하는 과정까지 포함되어 있는 알고리즘이다. 대표적인 강화학습의 예로는 알파고에 있는데 바둑이라는 주어진 환경에서 바둑알을 어디에 두었을 때 이길 가능성이 가장 높은 쪽으로 학습하는 하는 방식을 의미한다.

## IV. System Algorithm

### 1. Machine Learning Procedures

기계학습은 학습 및 데이터 셋을 Fig. 1과 같은 절차를 거쳐 수행한다.

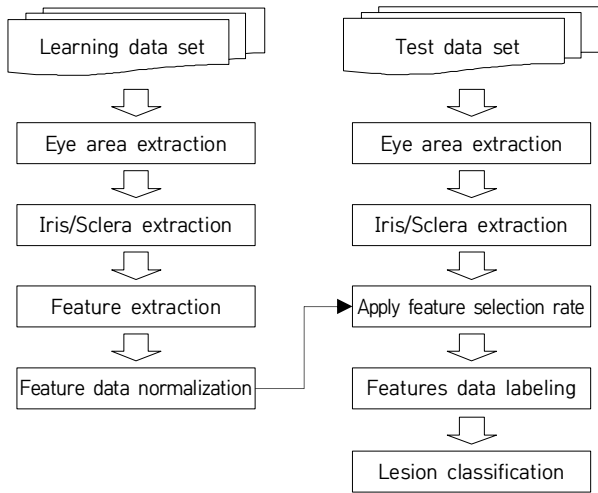


Fig. 1. Machine Learning Procedures

## 2. Eye Extraction

눈 영역을 추출하기 위한 알고리즘은 Fig. 2와 같다. 얼굴 사진으로 입력데이터가 들어오면 HSV 채널로 변환, 샤프닝, 이진화, 모폴로지 연산의 과정을 거쳐 눈을 추출한다.

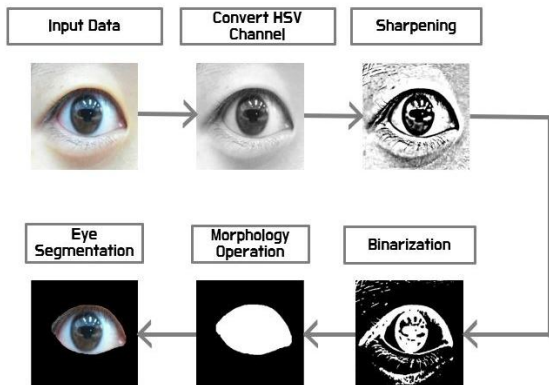


Fig. 2. Eye Segmentation Algorithm

### 2.1 Eye Area Estimation

눈 영역 추정에서는 눈 영역을 ‘피부가 아닌’ 영역이라는 사실에 근거하여 이미지의 영역을 ‘skin피부’ 또는 ‘피부가 아닌’으로 분류할 수 있다. 그런 다음 이미지에서 눈에 해당하는 영역을 피부가 아닌 영역으로 가정해서 조명이 있는 상태와 없는 상태 각각 색상 거리 맵을 사용하여 눈 영역을 계산한다. 조명이 있는 상태에서는 식(5)와 같이 계산한다.

$$CDM_1 = \begin{cases} R > 95, G > 40, B > 20, \\ 1, \max(R, G, B) - \min(R, G, B) > 15, \\ |R - G| > 15, R > G, R > B \\ 0, \text{ else} \end{cases} \quad (5)$$

조명이 있는 상태에서 두 번째 색상 거리 맵은 식 (6)을 사용하여 계산한다.

$$CDM_2 = \begin{cases} R > 220, G > 210, B > 170, \\ \max(R, G, B) - \min(R, G, B) > 15, \\ |R - G| \leq 15, R > B, B > G \\ 0, \text{ else} \end{cases} \quad (6)$$

위 두 가지의 색상 거리 맵을 사용하여 식(7)을 사용하여 눈 영역을 계산한다.

$$S_1(x, y) = \begin{cases} 1, & CDM_1(x, y) \text{ or } CDM_2(x, y) = 0 \\ 0, & \text{else} \end{cases} \quad (7)$$

위 식을 이용하여 눈 영역을 판단한 결과는 Fig. 3과 같다.




Fig. 3 Eye estimation result

### 2.2 Noise Remove

Fig. 3은 색상 거리 맵을 사용하여 계산된 눈 영역인데, 눈 영역 이외에 다른 노이즈가 많아 다른 후처리 과정이 필요하였다. 그래서 매트랩이라는 프로그램을 이용하여 모폴로지 연산을 통해 노이즈를 제거한 결과 Fig. 4와 같다.



Fig. 4. (a) imfill function (b) bwareaopen function (c) imopen function

## 3. Iris/Sclera Extraction

홍채 추출과 공막 추출을 위한 전체 알고리즘은 Fig. 5와 같다. 홍채는 눈에서 가장 원형에 가까운 부분이다.

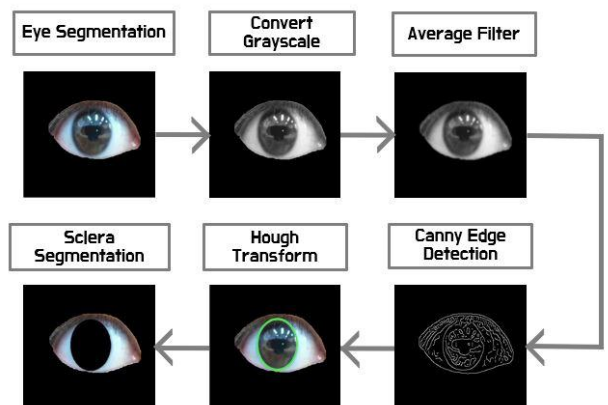


Fig. 5. Iris segmentation & Sclera segmentation algorithm

원에 가까운 것을 찾는 알고리즘 중 하프변환 기법을 사용하기 위해 우선 추출된 눈 영역 이미지를 그레이 스케일로 변환 후 노이즈 제거를 위해 가우시안 스무딩 필터를 사용하는데 가우시안 스무딩 필터는 식 (8)과 같이 계산한다[11].

$$G_{\sigma}(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} * \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{y^2}{2\sigma^2}} \quad (8)$$

가우시안 스무딩 필터로 나온 결과 이미지는 경계선을 찾기 위해 캐니 엣지 검출 기법을 사용한다. 이미지에서 경계는 데이터 값이 급격하게 변화하는 부분으로 보며, 캐니 엣지 검출 기법은 컨볼루션 마스크를 사용하여 계산된 그라디언트 강도와 방향 값을 이용하여 값의 변화가 큰 부분을 경계선으로 감지하게 된다. 이는 식(9), (10)과 같이 계산한다[11].

$$|G| = \sqrt{G_x^2 + G_y^2} \quad (9)$$

$$\angle G = \arctan\left(\frac{G_y}{G_x}\right) \quad (10)$$

필터링 된 이미지는 캐니 엣지 검출 기법을 이용하여 경계선을 찾은 후 하프 변환 수식을 통하여 원에 가까운 부분을 찾는데, 이는 식 (11)과 같이 계산한다[12].

$$(x - x_{center})^2 + (y - y_{center})^2 = r^2 \quad (11)$$

하프 변환을 사용하여 나온 결과 이미지는 Fig. 6(a)과 같으며, 추출된 눈 영역 이미지에서 추출된 홍채 영역을 제거함으로써 Fig. 6(b)과 같이 공막 영역을 추출하게 된다.




Fig. 6. (a) Hough transform result (b) Sclera segmentation result

#### 4. Feature Extraction

황달은 노란색 변색이 특징이므로 공막 분할의 결과 이미지에서 추출한 특징은 공막에 속한 픽셀의 색상에 대한 값이다. 종종 공막에는 혈관과 같은 다른 구성 요소에 의해 오차가 발생하게 된다. 이러한 경우 색 채널을 독립적으로 집계하면 공막에 존재하지 않는 색이 나타날 수 있다. 예를 들어, 깨끗한 공막이 많은 혈관을 포함하는 경우 색 채널의 평균을 개별적으로 취하면 공막의 색이 분홍색으로 나타난다. 중간 벡터는 빨간색보다 흰색 영역이 더 많을 때 흰색으로 표현 한다. 중간 벡터는

공막 분할이 공막 외부의 불필요한 픽셀을 포함하는 경우에도 유용하다. 대부분의 픽셀이 공막에 속한다고 가정하면, 그 픽셀은 최종 공막 색에 영향을 미치지 않는다.

Table 1. Variations for feature extraction[13]

Pixel Selection Methods	
All pixels	All pixels
No glare	L≤220 in HSL space
No glare or vessels	L≤220 and H≥15 in HSL space
No glare or eyelashes	5≤L≤ 220 in HSL space
No glare, vessels, eyelashes	5≤L≤220 and H≥15 in HSL space
Color space	
RGB, HSL, HSV, L*a*b*, YCrCb	

특징 추출을 위해 고려해야 할 두 가지 고려 사항이 있다. 첫 번째는 픽셀이 계산에서 고려되는 것이다. 앞서 언급했듯이, 공막의 경계 내의 모든 픽셀이 실제로 공막의 색을 나타내는 것은 아니다. 혈관과 속눈썹은 데이터에 원치 않는 문제를 일으킬 수 있다. 중간 벡터는 효과를 줄이기 위한 것이지만 우리는 Table 1에 설명된 5가지 픽셀 선택 방법을 사용한다. 다양한 방법에 대한 임계값은 눈부심, 혈관 및 눈에 띄는 경우가 있는 이미지를 선별하여 사용했다.

특징 추출을 위한 두 번째 고려 사항은 어떤 색 공간을 사용하는 것이다. 이미지는 RGB 색상 공간에 저장된다. 이미지를 다른 색상 공간으로 변환하는 것은 3가지 채널을 통해 계산하는 것이다. 이 방법은 숫자를 다양한 방식으로 표현하며 다양한 기계 학습 모델과 기능 변형 기술을 통해 스스로 배울 수 있다. 그럼에도 불구하고 명시 적으로 색상 변환을 수행하면 더 적은 기능을 필요로 하는 방식으로 색상 데이터를 재 정렬 할 수 있다. 우리는 Table 1에서 나열된 5가지 색상 공간에 대한 기능을 계산한다.

본 연구에서는 픽셀 선택 방법과 색상 공간의 모든 조합을 사용하여 공막의 색상 표현을 계산할 것이다. 각 색상은 3개의 채널을 가지므로 5개의 픽셀 선택 방법 × (색상 공간 당 5개의 색상 공간 × 3개의 채널 + 6개의 RGB 비율) = 공막 이미지 한 장은 105개의 특징을 가져올 수 있다.

#### V. Results

본 연구에서는 영상처리 통하여 공막 추출을 하였고, 추출한 이미지에서 특징들을 뽑아낸 후 SVM을 사용하여 황달을 진단 하였다. 사용한 데이터는 미국 워싱턴 대학에서 진행한 테스트 데이터 셋을 이용하였다. 학습 데이터 셋은 정상인 데이터 170 장, 황달 환자의 데이터 160장이다.

Fig. 7은 SVM을 사용하여 황달을 진단한 결과이다. 파란색

으로 표시된 점들이 일반인들의 데이터이고, 빨간색으로 표시된 점들이 환자들의 데이터이다. x축이 의미하는 것은 환자들의 라벨링이고, y축이 의미하는 것은 환자들의 데이터 값이다. 초록색 선은 SVM을 사용하여 황달인 사람과 황달이 아닌 정상인들을 분류한 최적의 함수이며, SVM을 사용하여 나온 결과의 정확도는 93.4%이다. 정확도가 높은 이유는 흰색과 노란색의 데이터 값들이 특정 채널에서 확연한 차이를 보이기 때문이다.




Fig. 7. SVM classification result of jaundice diagnosis

Fig. 8은 입력 이미지에 대한 SVM 분류 모델의 예측결과를 나타내는 GUI이다. ‘Diagnosis Result’ 메뉴에 정상인과 환자의 예측 결과를 나타내었으며, ‘Color Data’ 메뉴에 핵심 색상 채널의 값을 나타냄으로 사용자가 사용하기 편리하고, 현 눈에 알아볼 수 있도록 구성하였다.

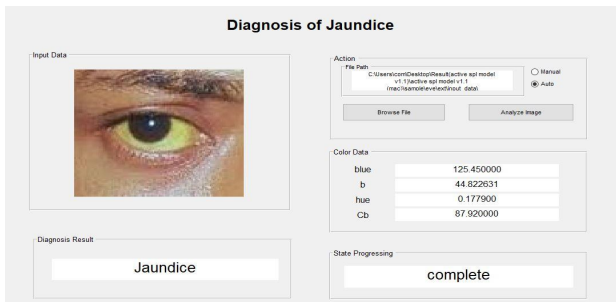


Fig. 8. Diagnosis of jaundice system GUI

## VI. Conclusions

본 연구에서는 머신러닝 기법 중 하나인 SVM을 사용하여 황달의 병변을 진단하는 알고리즘을 제안하였고 제안된 방법의 정확도를 평가하였다. 기계학습의 결과로 나온 예측 정확도는 93.4%이다. 이와 같이 얻어진 결과는 예측된 모든 오류 값 중 86%가 정상인과 황달 환자들의 빌리루빈 수치가 0.24mg/dL

에서 0.3mg/dL 범위에 포함된 결과이며, 정상인과 환자의 구분이 힘든 것을 감안할 경우 예측된 결과는 대부분 분류되었다고 판단할 수 있다. 그러나 예측된 오류 값 중 3% 정도가 환자를 정상인으로 예측한 결과가 나왔으며, 이러한 결과는 허용오차범위 5%내의 값이므로 황달을 진단하는데 큰 무리가 없다. 이와 같은 오류가 발생한 원인은 이미지 전처리 방법을 통해 추출된 공막이 완벽하게 추출되지 않았거나 쌍꺼풀까지 같이 추출된 영상에서 발생한 것으로 판단되었다.

향후 연구 방향의 중점은 짙은 쌍꺼풀이 있는 눈 데이터에서 쌍꺼풀이 추출되는 부분에 대해서 보완하기 위해 쌍꺼풀을 제거할 수 있는 전처리 과정을 추가해야 한다. 쌍꺼풀까지 추출을 하게 되면 특정 채널의 값들에 노이즈가 생기는데 이는 분류 알고리즘에서 잘못된 값의 영향으로 인하여 정상인을 환자로 또는 환자를 정상인으로 분류할 수 있기 때문이다. 만약 데이터가 더 많이 확보된다면 딥러닝 알고리즘 중 CNN을 사용하여 공막 추출에 대한 정확도를 높이고 정상인과 환자들 사이의 애매한 데이터들을 분류할 수 있는 모델을 사용하여 분류 알고리즘의 정확도를 높여보고자 한다.

## REFERENCES

- [1] Stoll BJ, Kliegman RM. Jaundice and hyperbilirubinemia in the newborn. In : Behrman RE, Kliegman RM, Jenson HB, editors. Nelson Textbook of Pediatrics. 17th ed. Philadelphia : WB Saunders Co, p.592-599, 2004.
- [2] American Academy of Pediatrics. Subcommittee on Hyperbilirubinemia Management of hyperbilirubinemia in the newborn infant 35 or more weeks of gestation. Pediatrics, p.297-316, 2004.
- [3] Slllee. Neonatal Jaundice, Korean Journal of Pediatrics, 49(1), 2006.
- [4] Hsahn. Textbook of pediatrics. 8th ed. Seoul : Daehan Printing & Publishing Co, p.343, 2004.
- [5] Maisels MJ. Neonatal jaundice. In : Avery GB, editor. Neonatology. 2nd ed. Philadelphia : JB Lippincott, p.484, 1981.
- [6] Horiguchi T, Bauer C. Ethnic differences in neonatal jaundice; comparison of Japanese and Caucasian newborn infants. Am J Obstet Gynecol p.71-74, 1975.
- [7] Maisels MJ. Jaundice. In : MacDonald MG, Mullett MD, Seshia MMK, editors. Avery's Neonatology; pathophysiology & management of the newborn. 6th ed. Philadelphia : Lippincott Williams & Wilkins, p.768-846, 2005.
- [8] Charalambos N., Alkistis A., Stefanos L., et al. A comparison between transcutaneous and total serum

- bilirubin in healthy-term greek neonates with clinical jaundice. *Prague Med Rep.* 115(1-2), pp.33-42, 2014.
- [9] Lilian de Greef, Mayank Goel, Min Joon Seo, et al. BiliCam: Using Mobile Phones to Monitor Newborn Jaundice. *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computation*, ACM Press, 2014.
- [10] E. Alpaydin, "Introduction to Machine Learning," MIT Press: Cambridge, MA, 2004.
- [11] G. Kitagawa, "The two-filter formula for smoothing and an implementation of the Gaussian-sum smoother," *Ann. Inst. Stat. Math.*, 46, pp.605-623, 1994.
- [12] Lei Xu, Erkki Oja, Randomized Hough transform (RHT): basic mechanisms, algorithms, and computational complexities, *CVGIP: Image Understanding*, 57(2), p.131-154, 1993.
- [13] Alex Mariakakis, Megan A. Banks, Lauren Phillipi, Lei Yu, James Taylor, Shwetak N. Patel, BiliScreen: Smartphone-Based Scleral Jaundice Monitoring for Liver and Pancreatic Disorders, *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 1(2), p.1-26, 2017.

## Authors



Jins-Gyo Jeong is undergraduate student majoring in biomedical engineering in School of Medicine from Keimyung University, Daegu, Korea. He researched about medical image processing and computer-aided diagnosis. His current research interests include

image processing, deep learning, and machine learning.



Myung-Suk Lee received the B.S., M.S. and Ph.D. degrees in Computer Engineering from Keimyung University, Korea, in 2001, 2003 and 2009, respectively. Dr. Lee joined the faculty of the Tabula Rasa College at Keimyung University, Daegu, Korea, in

2013. She is currently a Professor in the Science and Technology at Tabula Rasa College, Keimyung University. She is interested in Computer Network, Internet Ethics and Computer Education, Artificial Intelligence, etc.