

한국 프로바둑기사 포석 인식을 위한 선형판별분석과 주성분분석 비교

이병두

세한대학교 체육학부 바둑학과

blee026@korea.com

Comparison of LDA and PCA for Korean Pro Go Player's Opening Recognition

Byung-Doo Lee

Dept. of Baduk Studies, Division of Sports Science, Sehan University

요 약

적어도 2,500년 전에 기원된 바둑은 세상에서 가장 오래된 보드 게임 중의 하나이다. 아직까지 포석 바둑에 대한 이론적 연구는 여전히 미흡하다. 본 연구는 특정 프로기사의 포석을 갖고 훈련용 포석으로부터 얻어낸 클래스로의 인식을 위해 전통적인 선형판별분석 알고리즘을 적용하였다. 상위 10위권 한국 프로기사의 포석을 갖고 클래스-독립 선형판별분석과 클래스-종속 선형판별분석을 수행하였다. 실험 결과 클래스-독립 LDA는 평균 14%의 인식률을, 클래스-종속 LDA는 평균 12%의 인식률을 각각 보였다. 또한 연구 결과 일반적인 상식과 달리 PCA가 LDA보다 더 우월하고, 유클리디언 거리 측정 방식이 결코 LDA보다 뒤지지 않는다는 새로운 사실이 밝혀졌다.

ABSTRACT

The game of Go, which is originated at least more than 2,500 years ago, is one of the oldest board games in the world. So far the theoretical studies concerning to the Go openings are still insufficient. We applied traditional LDA algorithm to recognize a pro player's opening to a class obtained from the training openings. Both class-independent LDA and class-dependent LDA methods are conducted with the Go game records of the Korean top 10 professional Go players. Experimental result shows that the average recognition rate of class-independent LDA is 14% and class-dependent LDA 12%, respectively. Our research result also shows that in contrary to our common sense the algorithm based on PCA outperforms the algorithm based on LDA and reveals the new fact that the Euclidean distance metric method rarely does not inferior to LDA.

Keywords : Go openings(바둑포석), Linear Discriminant Analysis(선형판별분석), Principal Component Analysis(주성분분석), Euclidean distance metric(유클리디언 거리 측정)

Received: Jul. 12, 2013 Accepted: Jul. 31, 2013
Corresponding Author: Byung-Doo Lee(Sehan University)
E-mail: blee026@korea.com


© The Korea Game Society. All rights reserved. This is an open-access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>), which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

ISSN: 1598-4540 / eISSN: 2287-8211


1. 서 론

바둑은 인류 역사의 태동과 함께 대략 2,500년 전 중국에서 기원된 보드(board) 게임으로 추정되고 있으며, 서구에서는 2인-제로섬-완전정보게임인 바둑을 흥미로운 신 연구영역으로 삼아 1990년대부터 본격적으로 연구를 진행하고 있다[1].


바둑 게임은 3단계, 즉 초반전, 중반전, 후반전으로 진행이 되며, [Fig. 1]의 (a)와 같은 초반전은 바둑의 골격을 만들어 가는 포석단계이며, (b)와 같은 중반전은 적군의 돌을 공격하거나 아군의 돌을 수비하는 전투단계가 되며, 끝내기로 불리는 (c)와 같은 후반전은 쌍방의 영역을 최종 정리하는 단계가 되며, (d)는 흑이 이긴 상태로 게임이 종료된 최종 모습이다[1,2].




(a) An opening game record (1-17)



(b) An middle game record (44-73)



(c) An end game record (201-260)



(d) A finished game with black's winning

[Fig. 1] Exemplary game stages of a Go game[1]

1990년대부터 전 세계적으로 본격적으로 개발된 컴퓨터 바둑에 있어, 중반전인 끝내기는 컴퓨터 바둑의 수준이 프로기사와 대등하게 되었으며[3], 중반전은 상당한 아마 기력 수준까지 이르고 있으나, 초반전인 포석에 대한 연구는 미진한 편이다[2,4].

본 연구의 기본 아이디어는 수작업이나 컴퓨터로 생성된 임의의 프로기사 전체 기보(棋譜)를 갖고 게임 중 발생된 게임 패턴(포석)을 판별 분석하여 어느 기사가 두었는가를 기존의 컴퓨터 기술(예: LDA, PCA 등)로 어느 정도 정확히 식별해낼 수 있는가를 알아보는 것이다[5].

얼굴인식(face recognition)은 비디오나 디지털 이미지로부터 자동적으로 특정인물을 구별해내는 컴퓨터 응용기술로 주로 보안 분야에서 활용되고 있으며, 지문이나 홍채인식을 통한 생체인식기술과 더불어 여러 분야에서 널리 사용되고 있다[5]. 얼굴인식을 위해 주로 사용되는 분석법으로는 주성분분석(PCA: Principal Component Analysis), 독립성분분석(ICA: Independent Component Analysis), 선형판별분석(LDA: Linear Discriminant Analysis) 등이 있다[6,7,8,9].

저자는 [5]에서 PCA 방식에 의한 특정 기사의 포석 인식을 시도하였으나 평균 인식률이 22%로 매우 저조하여 실제 현실 적용을 할 수 없음을 발견하였다. 이에 본 연구에서는 LDA 방식을 채택하여 포석 인식을 재 실시하였으며, 그 결과를 PCA 방식과 비교하였다.

2. 본 론

2.1 실험 환경 및 데이터 수집

2013년 현재 한국기원 소속 프로기사 280명 중 상위 10위 명단은 [Table 1]과 같다. 바둑 대국은 흑대국자에 의해 포석이 확연히 달라질 수가 있기 때문에 연구용 포석으로 2012년 국내외 공식 기전에서 치룬 대국 중에서 흑선으로 대국을 치룬 377 대국을 원시데이터로 선정하였다.

[Table 1] Number of openings for 10-fold cross validation[5]

Rank	Player's name	Number of openings		
		training	test	total
1	L. Sedol	45	5	50
2	P. Junghwan	51	6	57
3	C. Chulhwan	44	5	49
4	K. Jisuk	34	4	38
5	W. Sungjin	22	3	25
6	J. Hanseung	20	2	22
7	K. Dongyoon	40	4	44
8	B. Hongsook	36	4	40
9	P. Yeonghoon	30	3	33
10	K. Seungjae	17	2	19
	total	339	38	377

2.2 PCA 분석과 LDA 분석

2.2.1 PCA 분석

주성분분석은 통계학적 선형변환으로 고차원의 데이터를 가능한 한 데이터의 정보를 손실시키지 않으면서 저차원으로 압축시키는 기법이다[3,10]. PCA는 고유벡터(eigenvector)를 이용하여 고차원의 원시데이터(또는 원시이미지)를 저차원의 특징 공간(feature space)로 사상(projection)하는 것이다.

n 차원으로 된 M 개의 훈련용 데이터는 (eq. 1)과 같은 벡터 X 로 표현이 된다.

$$X = [X^1, X^2, \dots, X^M] \quad (\text{eq. 1})$$

여기서 X^i 는 i 번째 훈련용 포석으로 행벡터인 $X^i = [X_1^i, X_2^i, \dots, X_n^i]$ 가 된다.

벡터 X 에 대한 공분산행렬(covariance matrix) C 는 (eq. 2)와 같다.

$$C = \frac{1}{M} \sum_{i=1}^M (X^i - \mu)(X^i - \mu)^T \quad (\text{eq. 2})$$

여기서 $\mu = \frac{1}{M} \sum_{i=1}^M X^i$ 로 훈련용 전체 데이터의 평균이 되며, $(X^i - \mu)^T$ 는 행렬 $(X^i - \mu)$ 의 전치행렬이 된다.

다음으로 고유값 λ_n 과 고유벡터 E_n 은 (eq. 3)과 같이 계산된다.

$$CE_n = \lambda_n E_n \quad (\text{eq. 3})$$

고유값 λ_n 을 내림차순으로 정돈하였을 때 생성된 첫 번째 k 개의 주성분(PC)들은 (eq. 4)와 같이 λ_n 가 큰 순서로 된 공분산행렬 C 의 고유벡터 V 가 된다.

$$V = [V_1, V_2, \dots, V_k] \quad (\text{eq. 4})$$

이후 고유벡터 V 를 $\|V_j\| = 1$ 로 정규화 한다. 이때 벡터 V_j 는 원시데이터의 차원과 같기 때문에 고유포석(eigenopening)¹⁾으로 불린다.


원시데이터 X^i 에 대해 PCA에 의한 최종 선형 변환된 데이터는 (eq. 5)와 같이 계산된다.

$$Y^i = V^T \times X^i \quad (\text{eq. 5})$$

여기서 $X^i \in R^n$, $Y^i \in R^k$, $V \in R^{n \times k}$ 이며 $k < n$ 이 된다.

참고로 [Fig. 2]는 3개의 클래스([Table 1]내의 조한승, 박영훈, 김승재)를 갖고 $n = 361$ 차원의 원시데이터를 $k = 2$ 차원으로 선형 변환한 모습이다.

1) 이미지 처리에서는 이를 고유얼굴(eigenface)라고 하나, 바둑에서는 이에 대한 용어가 없어 저자가 만든 신조어이다.



[Fig. 2] The two largest PCs and the major projection W_1 generated by class-independent LDA

[5]에서 PCA 방식에 의한 포석의 인식을 비교 결과 1) 흑만으로 된 포석의 인식률(22%)이 2) 흑백으로 된 포석의 인식률(16%)보다 높음을 보였으며, [Table 2]에서 보듯이 10-묶음 교차 검증²⁾ 결과 흑만으로 된 포석의 인식률(22%)이 저조하여 실제 현실 적용을 할 수 없음을 보였다.

[Table 2] Recognition accuracy by each round and the number of PCs[5]

	Number of PCs		
	2 PCs	w/o 2 PCs	all PCs
r=1	8%	16%	10%
r=2	11%	21%	21%
r=3	13%	24%	24%
r=4	34%	11%	21%
r=5	26%	18%	29%
r=6	13%	18%	18%
r=7	18%	13%	16%
r=8	18%	11%	24%
r=9	13%	5%	21%
r=10	26%	11%	32%
Mean	18%	15%	22%

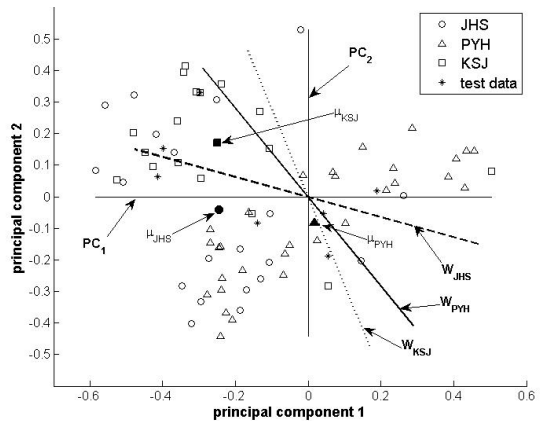
또한 [Table 2]에서 보듯이 2개의 주성분으로는 평균 18%의 정확한 인식을, 2개의 주성분을 제외한 나머지 성분(359개 주성분)으로는 15%의 인식을, 전체의 주성분(361개 주성분)으로는 22%의 인

식을 보임을 알 수 있다.

2.2.2 LDA 분석

선형판별분석은 주어진 데이터 집합의 클래스내 분산(within-class variance)에 대한 클래스간 분산(between-class variance)의 비를 최대화하여, 주어진 클래스들에 대한 분류를 최적화하는 것이다 [10]. LDA와 PCA의 근원적인 차이는 LDA는 데이터의 최적 분류(optimized classification)를 위해 데이터 차원을 줄이는 반면에, PCA는 데이터의 최적 표현(optimized representation)을 위해 데이터 차원을 줄이는 것이다.

원시데이터 집합은 LDA변환으로 다른 주축으로 변환되어 축소되며, [Fig. 2]와 같은 클래스-독립 변환 또는 [Fig. 3]과 같은 클래스-종속 변환 방법에 의해 분류코자하는 데이터는 특정 클래스에 분류가 된다.

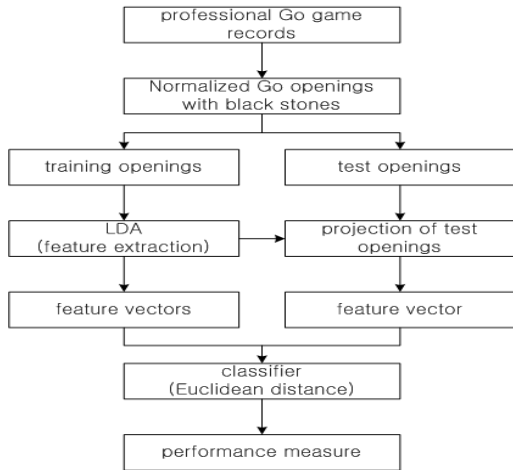


[Fig. 3] The three projections for classifying 3-class data by class-dependent LDA

어떠한 LDA 유형을 선택하느냐는 주어진 원시 데이터와 분류 문제의 목표에 따라 정해진다. 만약 일반화(generalization)가 중요하다면 클래스-독립

2) 10-묶음 교차검증법(10-fold cross-validation)을 위해 입력 포석의 90%를 훈련용 데이터(training data), 10%를 시험용 데이터(test data)로 사용하였다.

변환이 주효하며, 양질의 판별(discriminant)을 원한다면 클래스-종속 변환이 주효하다. 본 연구에서는 클래스-독립 변환과 클래스-종속 변환 모두를 적용/비교하였다. 참고로 LDA를 활용하여 포석인식을 하는 절차는 [Fig. 4]와 같다.



[Fig. 4] Flowchart for Go opening recognition by LDA

LDA는 PCA의 부분공간(subspace)을 활용한다. 즉, (eq. 4)에 있는 고유벡터 V 를 활용한다.

우선 훈련용 데이터를 갖고 클래스내 분산행렬 S_w 와 클래스간 분산행렬 S_B 를 구한다. 클래스의 전체 개수가 C 이고 각 클래스 C_i 에 대해 포석의 개수가 N_i 인 경우, 클래스내 분산행렬 S_w 는 (eq. 6)과 같다.

$$S_w = \sum_{i=1}^C p_i \sum_{X \in X^i} (X - \mu_i)(X - \mu_i)^T \quad (\text{eq. 6})$$

여기서 $p_i = \frac{N_i}{C} = \frac{N_i}{N}$ 는 각 클래스 C_i 에 대한 사전확률(a priori probability)이 되며,

$\mu_i = \frac{1}{N_i} \sum_{j=1}^{N_i} X^j$ 는 클래스 C_i 의 평균포석이 된다.

또한 클래스간 분산행렬 S_B 는 (eq. 7)과 같다.

$$S_B = \sum_{i=1}^C (\mu_i - \mu)(\mu_i - \mu)^T \quad (\text{eq. 7})$$

여기서 $\mu = \frac{1}{N} \sum_{i=1}^C \sum_{j=1, X^j \in X^i}^{N_i} X^j$ 는 훈련용 전체 데이터에 대한 평균이 된다.

그러면 고유벡터 E_k 는 (eq. 8)을 만족한다.

$$S_B E_k = \lambda S_w E_k \quad (\text{eq. 8})$$

여기서 λ 는 고유값, $k=1, 2, \dots, m$ 이 되고, m 은 고유벡터의 수가 된다

2.2.3 원시데이터 작성

상위 10명의 프로기사에 대한 전체기보를 갖고 [Fig. 1]의 (a)와 같은 형태의 377개의 포석으로 가공처리를 한 후, 좌표값 입력을 통해 다음과 같이 선형판별분석을 위한 i 번째 입력용 포석 X^i 로 변형을 했다.

$$X^i = [X_{1,1}^i, X_{1,2}^i, \dots, X_{1,19}^i, X_{2,1}^i, \dots, X_{19,19}^i] \\ = [X_1^i, X_2^i, \dots, X_{19}^i, X_{20}^i, \dots, X_{361}^i]$$


여기서 바둑판 내 특정좌표 (j, k) 에 흑돌이 있는 경우에는 $X_{j,k}^i$ 의 값을 +1, 백돌이 있는 경우에는 -1, 돌이 없는 경우에는 0으로 처리하였다.

361차원으로 된 339개의 훈련용 데이터는 (eq. 9)와 같은 벡터 X 로 표현이 된다.

$$X = [X^1, X^2, \dots, X^{339}] \quad (\text{eq. 9})$$

여기서 X^i 는 i 번째 훈련용 포석인 행벡터이다. [Table 1]에서 보듯이 10명의 포석 클래스를 C_1, C_2, \dots, C_{10} 이라고 하면 각 클래스 C_i 는 n 개의


포석인 X_j 로 구성되어 있으며 $j=1, 2, \dots, n$ 이 된다. 참고로 [Fig. 5]는 339개의 훈련용 전체 포석을 갖고 PCA의 2개의 주성분(PC1, PC2)를 통해 2차원 평면상에 그려진 10개 클래스 내의 포석들이다.




[Fig. 5] The 339 openings in 10 classes projected along the two largest PCs, PC1 and PC2

LDA 알고리즘을 구현하기 위하여 원시 데이터를 훈련용 데이터와 10-목을 교차 검증을 위한 시험용 데이터로 구분하였다. 즉, [Table 1]에서 보듯이 10명의 프로기사에 대한 377개의 전체 포석 중 훈련용으로 339개의 포석을, 시험용으로 38개의 포석을 활용하였다.

[Fig. 6]은 클래스-독립 LDA 변환을 위해 훈련용 데이터로 생성된 두 개의 주축 W_1, W_2 와 판별하고자 하는 시험용 데이터의 분포를 보여주고 있다. 또한 [Fig. 7]은 클래스-종속 LDA 변환을 위해 훈련용 데이터로 생성된 10개의 클래스에 대한 10개의 주축을 보여주고 있다.



[Fig. 6] The two major projections for class-independent LDA



[Fig. 7] The 10 major projections for class-dependent LDA

2.2.4 클래스 분류

클래스 분류는 훈련용 평균포석의 사영벡터들과 시험용 포석의 사영벡터간의 유클리드 거리 (Euclidean distance)를 비교하면 된다. 즉, (eq. 10)과 같은 유클리드 거리 식을 이용하여 최소 거리를 갖는 포석 클래스 C_k 를 찾는 것이다.

$$\epsilon_k = \|\Omega - \Omega_k\| \quad (\text{eq. 10})$$

여기서 Ω 는 분류하고자 하는 시험용 포석의 사영벡터가 되며, Ω_k 는 k 번째 포석 클래스 C_k 를 대표하는 평균포석의 사영벡터가 된다.


[Table 2]에서 보듯이 클래스-독립 LDA 변환을 10회 시행하게 되면 평균 14%의 인식률을, 클래스-종속 LDA 변환인 경우는 12%의 인식률을 보이고 있어, 클래스-독립 LDA 변환이 클래스-종속 LDA 변환보다 다소 우월하다는 것을 알 수 있다. 그러나 이 결과는 PCA 방식(22%)보다 훨씬 떨어짐을 알 수 있다.

한편 클래스내 평균포석과 시험용 포석간의 단순 거리를 비교하는 유클리디언 거리 측정에서 평균인식률이 16%로 나왔으며, 이 결과는 결코 단순 유클리디언 거리 측정이 LDA 방식보다 뒤지지 않는다는 사실이 돌출되었다.

결론적으로 PCA의 평균 인식률은 22%, 클래스-독립 LDA는 14%, 클래스-종속 LDA는 12%, 유클리디언 방식은 16%를 각각 보이고 있다. 결국 인식의 정확성을 비교해 보면 우리가 알고 있는 "LDA 방식이 PCA 방식보다 우월하다"는 일반적인 상식과는 달리 'PCA가 LDA보다 우월하다'라는 새로운 사실이 밝혀졌다. 또한 유클리디언 방식과의 성능 비교에서 '유클리디언 방식이 PCA보다 우월하지는 않지만 LDA보다 결코 뒤지지 않는다'라는 새로운 사실도 밝혀졌다.

즉, 바둑 포석과 같이 비선형 멀티모달(multimodal) 형태를 따르는 분포에서는 PCA 및 LDA의 평균 인식률이 22%이하가 되어 실제 현실 적용을 할 수 없으며, 현실 적용을 위해서는 PCA(22%) 방식보다 더 우월한 알고리즘의 개발

이 요구됨을 알 수 있다. 참고로 [Fig. 8]은 클래스-종속 LDA 방식을 통해 얻어낸 클래스에 따른 사영벡터들의 확률분포도이다.



[Fig. 8] Probability density function along with the projection vector

3. 결론 및 제언

본 논문에서는 컴퓨터 바둑이나 프로기사에 의해 생성된 임의의 포석을 갖고 어느 바둑기사가 이 포석을 두었는가를 기존의 컴퓨터 기술로 식별해내고자 했다. [5]에서 특정 기사의 포석 인식을 위해 저자는 PCA 방식을 시도하였으나, 평균 인식률이 22%로 저조하여 실제 현실 적용을 할 수 없어 또 다른 인식 방식인 LDA, ICA, ANN(인공신경망) 등을 제안하였다.

LDA활용한 포석 인식을 위해 실험 대상으로 2012년 국내 상위 10위까지의 프로기사로 한정하

[Table 3] Recognition accuracy by each round and the number of PCs[5]

Method		r=1	r=2	r=3	r=4	r=5	r=6	r=7	r=8	r=9	r=10	Mean
PCA	2 PCs	8%	11%	13%	34%	26%	13%	18%	18%	13%	26%	18%
	w/o 2 PCs	16%	21%	24%	11%	18%	18%	13%	11%	5%	11%	15%
	all PCs	10%	21%	24%	21%	29%	18%	16%	24%	21%	32%	22%
LDA	independent	16%	8%	16%	11%	8%	21%	24%	16%	8%	11%	14%
	dependent	16%	5%	16%	5%	8%	16%	11%	16%	18%	6%	12%
Euclidean distance		18%	18%	16%	11%	11%	24%	13%	18%	18%	8%	16%

였으며, 그들의 흑번(黑番) 포석에 대해 LDA, PCA, 유클리디언 거리 측정 등 세 가지 방식을 비교/검토하였다.

3.1 연구 결과

두 가지 LDA 방식(클래스-독립 LDA와 클래스-종속 LDA)을 적용하였으며, 10-뚝음 교차 검증을 통한 실험 결과 클래스-독립 LDA의 평균 인식률은 14%, 클래스-종속 LDA의 평균 인식률은 12%를 보이고 있어, 클래스-독립 LDA가 클래스-종속 LDA보다 다소 우월하다는 것을 알 수 있다. 그러나 이 두 결과는 [5]에서 실시한 PCA 방식(22%)보다 훨씬 떨어짐을 알 수 있었다.

또한 단순한 유클리디언 거리 측정에서 평균인식률이 16%로 나와, 유클리디언 거리 측정이 LDA 방식보다 결코 뒤지지 않는다는 새로운 사실을 발견하였다. 즉, 바둑 포석과 같이 멀티모달 형태를 따르는 분포에서는 낮은 인식률로 실제 현실 적용을 할 수 없음을 최종 알 수 있었다.

3.2 제언

정보교환이 매우 용이한 현대에서 바둑과 같이 동시대에 두어지는 대국들은 대부분 그 시대의 유행을 따르기 때문에 서로 다른 기사라도 그 포석 형태는 매우 유사하여 멀티모달 형태를 띤다. 이러한 이유로 동시대에 있는 특정 포석만으로 그 대국 기사를 판별해내는 것은 거의 불가능하다는 사실을 알게 되었다. 그러나 정보 교환이 별로 안 되는 지역들 간의 포석이나 또는 시대별 현저한 차이가 있는 포석에 대한 인식은 가능한 것으로 추측이 되며, 향후 이에 대한 연구가 기대된다.

ACKNOWLEDGMENTS

This work was conducted under the research grant of Sehan University in 2013. In

addition, the authors thank Yong-Sung Kim, the third year student in Sehan University, for his helping to create the input Go openings from the professional Go game records.

REFERENCES

- [1] B. D. Lee, "Multi-strategic Learning, Reasoning and Searching in the game of Go", PhD thesis, Auckland University, 2005.
- [2] B. D. Lee and J. W. Park, "Applying Principal Component Analysis to Go Openings", Journal of Korea Game Society, Vol. 13, No. 2, pp. 59-70, 2013.
- [3] B. D. Lee and Y. W. Keum, "Candidate First Moves for Solving Life-and-Death Problems in the Game of Go, using Kohonen Neural Network", Journal of Korea Game Society, Vol. 9, No. 1, pp. 105-114, 2009.
- [4] B. D. Lee, "Applying Neuro-fuzzy Reasoning to Go Opening Games", Journal of Korea Game Society, Vol. 9, No. 6, pp. 117-126, 2009.
- [5] B. D. Lee, "Korean Pro Go Player's Opening Recognition Using PCA", Journal of Korean Society For Computer Game, Vol. 26, No. 2, pp. 73-80, 2013.
- [6] K. Delac and M. Grgic, "Face Recognition", I-Tech Education and Publishing, 2007.
- [7] A. M. Martinez and A. C. Kak, "PCA versus LDA", IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol. 23, No. 2, pp. 228-233, 2001.
- [8] J. Mazanec and et al., "Support Vector Machine, PCA and LDA in Face Recognition", Journal of Electrical Engineering, Vol. 59, No. 4, pp. 203-209, 2008.
- [9] A. Khan and H. Farooq, "Principal Component Analysis - Linear Discriminant Analysis Feature Extractor for Pattern Recognition", IJCSI International Journal of Computer Science Issues, Vol. 8, Issue 6, No. 2, pp. 267-270, 2011.
- [10] H. Y. Han, "Introduction to Pattern Recognition", Hanbit Media, 2011.



이 병 두 (Lee, Byung Doo)

1982 한양대 원자력공학 학사
1991 서강대 정보처리학 석사
2005 Auckland University 컴퓨터공학 박사
2012-현재 세한대 체육학부 바둑학과 조교수

관심분야 : 컴퓨터공학, 인공지능, 컴퓨터바둑
