

새로운 커널 기반 정상 상태 복구 기법과 응용

New Kernel-Based Normality Recovery Method and Applications

강대성, 박주영

Daesung Kang and Jooyoung Park

고려대학교 제어계측공학과

요 약

SVDD(support vector data description)는 가장 중요한 one-class 서포트 벡터 학습 방법론 중 하나로 비정상 물체에서 정상 데이터를 구분하기 위해서 특정 공간에서 정의된 구를 이용하는 전략을 쓰는 방법론이다. 본 논문에서는 SVDD를 이용해서 노이즈가 섞인 비정상 데이터를 노이즈가 제거된 정상 데이터로 복원하는 방법에 대해서 논한다. 그리고 고해상도의 학습 데이터를 이용하여 저해상도로 주어진 시험 데이터 이미지를 고해상도의 이미지로 복원하는 문제에 적용함으로써 본 논문의 방법론이 어떻게 실용적으로 적용될 수 있는지에 대해서 다룬다.

키워드 : SVDD(support vector data description), 노이즈 제거, 서포트 벡터 학습

Abstract

The SVDD(support vector data description) is one of the most important one-class support vector learning methods, which depends on the strategy of utilizing the balls defined on the feature space to discriminate the normal data from all other possible abnormal objects. This paper addresses on the extension of the SVDD method toward the problem of recovering the normal contents from the data contaminated with noises. The validity of the proposed de-noising method is shown via application to recovering the high-resolution images from the low-resolution images based on the high-resolution training data.

Key words : SVDD (support vector data description), De-noising, Support vector learning

1. 서 론

최근 들어, 서포트 벡터 학습 방법은 그에 관련된 이론이 정립되고 각종 응용 사례가 보고되면서, 지능시스템 분야에서 매우 중요한 도구 중 하나로 자리를 잡아가고 있다[1, 2]. 서포트 벡터 학습의 주요 응용 대상으로 최근에 주목받고 있는 분야 중 하나로는 비정상상태 탐지 문제(abnormality detection problem)를 들 수 있다. 비정상상태 탐지문제에서는 일반적으로 학습과정에서 정상 클래스(normal class) 위주의 데이터만을 다루게 되고, 학습결과로 얻어진 결정함수(decision function)는 주어진 시험 데이터가 정상상태 범주를 벗어나는 비정상 클래스(abnormal class)에 속하는지를 판단하게 된다. 이러한 문제는 단일 클래스 분류 문제(one-class classification problems)[3-10]로 불리기도 하며, 운행 중인 기계의 고장진단이나 컴퓨터 보안과 관련한 침입 탐지 시스템(intrusion detection system)과 같은 부류의 문제에 효과적으로 사용될 수 있다. 비정상상태 탐지 문제에 대한 고전적인 접근 방법으로는, 학습 데이터를 이용하여 확률밀도함수(probability density function)를 추정한 후, 시험용 개체(test objects)에 대한 밀도 값(density value)이 정해진 문턱 값(threshold value) 미만인 경우 비정상 클

래스로 판정하는 전략이 있다. 그러나 이러한 전략은 확률밀도함수의 정확한 추정에 기반을 두고 있으므로, 일반적으로 다량의 학습 데이터를 필요로 한다. 따라서 제한된 개수의 학습 데이터만이 주어진 경우에는, 확률밀도함수의 추정을 이용하여 정상 클래스의 데이터가 존재하는 영역을 간접적으로 구하는 것보다는 정상 클래스가 존재하는 영역을 직접적으로 구하고자 하는 전략이 오히려 유리할 수 있다. 이러한 전략을 활용하는 방법들 중 가장 대표적인 예로 SVDD(support vector data description)을 들 수 있다[9, 10]. 본 논문에서는 SVDD 기법을 활용하여 정상상태를 복구하는 기법을 제안하고, 제안된 기법을 저해상도 얼굴영상의 복원에 응용하는 문제를 다룬다. 얼굴 인식에 대한 연구는 오랫동안 활발히 진행되어 왔고, 이에 관한 좋은 결과도 많이 나오고 있다. 하지만 보안 시스템에 많이 사용하는 CCTV나 카메라에 잡힌 영상을 선명하고 자세하게 보기에는 여전히 많은 문제점이 있다. 왜냐하면 캡처된 얼굴 이미지는 노이즈가 섞이거나, 얼굴의 일부가 가려지거나 또는 이미지의 해상도가 떨어지기 쉽기 때문이다. 해상도에 관련된 문제점을 해결하기 위해 본 논문에서는 SVDD를 이용하여 저해상도의 얼굴 이미지를 고해상도의 얼굴 이미지로 복원하는 문제를 다루려 한다[11]. SVDD는 비정상 물체에서 정상 데이터들을 구별하기 위해서 SVDD 구를 이용하는 전략을 사용하는데 구 안에 포함된 데이터들은 정상 데이터들로 인식하고, 구 밖에 있는 데이터들은 비정상 데이터들로 인식한다. 노이즈를 제거하기 위해서는 비정상 데

접수일자 : 2006년 4월 13일

완료일자 : 2006년 5월 29일

이터들을 정상 데이터 영역의 구의 경계면으로 사영시켜서 비정상 데이터들의 노이즈를 제거하는 전략을 사용한다. 본 논문의 구성은 다음과 같다. 2장에서는 SVDD에 대해서 간단히 기술한 후, SVDD를 이용해서 얼굴 이미지를 복원하는 방법에 대해서 다룬다. 3장에서는 시뮬레이션에 사용한 얼굴 영상과 시뮬레이션 절차에 대해서 논한 후, 4장에서는 결과와 고찰에 대해서 다룬다.

2. SVDD: 비정상 상태 탐지 문제를 위한 서포트 벡터 학습 방법

2.1 SVDD 기본 이론

정상 클래스에 속하는 개체의 존재 영역을 볼을 이용하여 근사하는 SVDD 기법은 다음과 같은 절차를 통하여 유도된다[9, 10]: d -차원 입력공간에 존재하는 개체 $x_i \in R^d$, $i = 1, \dots, N$ 로 구성되는 학습 데이터의 집합 $D = \{x_i | i = 1, \dots, N\}$ 와, R^d 위에 정의되는 중심이 a 이고 반경이 R 인 볼 B 를 고려하자. 볼 B 를 가지고 정상 클래스의 존재 영역을 표현하고자 할 때¹⁾에는, 될 수 있는 대로 각 학습 데이터 x_i 와 중심 a 사이의 거리는 R 이하가 되도록 잡아주고 이 거리가 부득이 R 을 초과하는 경우에는 적절한 벌점(penalty)을 부과하는 전략을 사용하면 된다. SVDD 기법은 이러한 전략을 최적화 문제로 옮긴 결과라고 볼 수 있는데, 그 기본 아이디어는 주어진 학습 데이터 중 상당수를 포함할 수 있으면서 체적을 작게²⁾ 유지할 수 있는 볼을 다음과 같은 최적화 문제를 통하여 구하는 것이다:

$$\begin{aligned} \min L_o(R^2, a, \xi) &= R^2 + C \sum_{i=1}^N \xi_i \\ \text{s.t. } \|x_i - a\|^2 &\leq R^2 + \xi_i, \xi_i \geq 0, \forall i. \end{aligned} \quad (1)$$

여기에서, ξ_i 는 i -번째 학습 데이터 x_i 가 볼에서 벗어나는 정도를 정량적으로 나타내는 항이다. 위의 최적화 문제의 목적함수는, 우리가 최소화시켜야하는 두 가지 상충적인 대상, 즉, 볼의 체적 관련 항 R^2 과 학습 데이터가 볼을 벗어

난 경우에 부과되는 총 벌점 관련 항 $\sum_{i=1}^N \xi_i$ 의 가중 합(weighted sum)으로 이루어져 있다. 그리고 C 는 위의 두 가지 항의 상대적 중요성을 조정하는 상수(trade-off constant)이다. 위의 문제에 대응하는 쌍대 문제(dual problem)는, 다음의 과정을 통하여 유도할 수 있다: 우선, 각 제약조건에 하나씩의 라그랑제 승수(Lagrange multiplier), 즉, 쌍대 변수(dual variable)를 도입하여 라그랑제 함수(Lagrange

function) L 를 구하면 다음과 같은 결과가 얻어진다:

$$\begin{aligned} L &= R^2 + C \sum_{i=1}^N \xi_i \\ &+ \sum_{i=1}^N \alpha_i [(x_i - a)^T(x_i - a) - R^2 - \xi_i] \\ &- \sum_{i=1}^N \eta_i \xi_i \end{aligned} \quad (2)$$

단, $\alpha_i \geq 0, \eta_i \geq 0, \forall i$.

원래의 문제와 쌍대문제의 최적해로 이루어지는 벡터는 라그랑제 함수가 정의되는 확장된 공간(augmented space)에서 안장점(saddle point)이 되어야 하므로[1, 2], 최적해는 다음의 조건을 만족해야 한다.

$$\begin{aligned} \frac{\partial L}{\partial (R^2)} &= 0: \sum_{i=1}^N \alpha_i = 1. \\ \frac{\partial L}{\partial \xi_i} &= 0: C - \alpha_i - \eta_i = 0 \therefore \alpha_i \in [0, C], \forall i. \\ \frac{\partial L}{\partial a} &= 0: a = (\sum_i \alpha_i x_i) / \sum_i \alpha_i = \sum_{i=1}^N \alpha_i x_i \end{aligned} \quad (3)$$

여기에서, 원래의 변수(primal variables) R^2, a, ξ 를 소거하기 위하여 위의 조건을 다시 라그랑제 함수 L 에 대입 해주면, L 은 다음과 같이 쌍대 변수 α_i 의 함수로 표현될 수 있다:

$$L = \sum_{i=1}^N \alpha_i \langle x_i, x_i \rangle - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j \langle x_i, x_j \rangle \quad (4)$$

단, $\sum_{i=1}^N \alpha_i = 1, \alpha_i \in [0, C], \forall i$.

따라서 위의 최소화 문제 (1)의 쌍대 문제는 다음과 같은 QP(quadratic programming) 문제로 정리 된다:

$$\begin{aligned} \max_a & \sum_{i=1}^N \alpha_i \langle x_i, x_i \rangle - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j \langle x_i, x_j \rangle \\ \text{s.t. } & \sum_{i=1}^N \alpha_i = 1, \alpha_i \in [0, C], \forall i. \end{aligned} \quad (5)$$

그리고 위의 최대화 문제 (5)는 다음과 같은 최소화 형태의 QP 문제와 동치가 됨은 자명하다:

$$\begin{aligned} \min_a & \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j \langle x_i, x_j \rangle - \sum_{i=1}^N \alpha_i \langle x_i, x_i \rangle \\ \text{s.t. } & \sum_{i=1}^N \alpha_i = 1, \alpha_i \in [0, C], \forall i. \end{aligned} \quad (6)$$

여기에서 유의할 점은 Kuhn-Tucker 조건에 의하여

$$\alpha_i (\|x_i - a\|^2 - R^2 - \xi_i) = 0, \forall i \quad (7)$$

가 성립하므로, $\|x_i - a\|^2 < R^2$ 이면(즉, 학습 데이터 x_i 가 볼의 내부에 속하게 되면), $\|x_i - a\|^2 - R^2 - \xi_i < 0$ 이 성립하므로 $\alpha_i = 0$ 이 된다는 점이다. 그리고 α_i 가 $(0, C)$ 범위에 속하게 되면 x_i 가 볼의 경계에 속하게 되고, $\alpha_i = C$ 이면 x_i 가 볼의 외부에 속하는 됨도 역시 Kuhn-Tucker 조건으로부터 유도할 수 있다. 일반적으로 우리는, 볼의 경계에 위치한 학습 데이터들을 서포트 벡터로, 그리고 볼의 외부에 속한 학습 데이터들은 에러 벡터(error vector)로 부른다. 최소화 문제 (6)을 풀어서 최적의 α_i 값들을 얻게 되면, 최적의 중심 a 는 식 (3)을 통하여 결정할 수 있게 되고, 반경의 자승 R^2 는 서포트 벡터에 관한 Kuhn-Tucker 조건 (7)을 이

1) 입력 공간 위의 영역을 표현하기 위한 도구로 볼을 택하는 것은 단순한 경계만을 다룰 수 있기에 매우 불리한 선택이 됨에 틀림없다. 하지만, SVDD 기법은 소위 커널 트릭(kernel trick)을 이용하여 궁극적으로 커널 특징 공간(kernel feature space) 위에서 정의되는 볼을 사용하는 방향으로 확장되므로, 훨씬 다양한 경계를 실현할 수 있다. 여기에서는 내용 전개에 편의상 우선 입력 공간 위에서 정의되는 볼을 이용하여 설명을 시작하기로 한다.

2) 여기에서 체적을 작게 유지하는 것은, 적용 시에 비정상 클래스의 개체를 정상으로 판정하는 위험을 줄이는 효과를 얻기 위해서임은 물론이다.

용하여 구할 수 있게 된다. 학습이 끝난 후 적용 과정에서, 시험 입력(test input) $x \in R^d$ 가 볼 안에 있으면, 즉

$$\begin{aligned} f(x) &= R^2 - \|x - a\|^2 \\ &= R^2 - (\langle x, x \rangle - 2 \sum_{i=1}^N a_i \langle x_i, x \rangle \\ &\quad + \sum_{i=1}^N \sum_{j=1}^N a_i a_j \langle x_i, x_j \rangle) \\ &\geq 0 \end{aligned} \quad (8)$$

이 만족되면, x 는 정상 클래스에 속하는 것으로 판정된다. 도입부 중 각주에서 이미 언급한 바와 같이, 입력 공간 위에서 정의되는 볼은 매우 간단한 형태의 영역만을 나타낼 수 있으므로, 상당히 빈약한 표현력을 가진다. 이러한 한계를 극복하기 위하여 SVDD는, Mercer 커널³⁾ k 를 통하여 정의되는 고차원⁴⁾의 커널 특징 공간 F 위에서 정의되는 볼을 사용하는 방향으로 확장될 수 있다. 이제, 위에서 소개한 SVDD 기법의 유도 과정을 입력 공간 R^d 위에서 적용하는 대신, 커널 특징 공간 F 위에서 적용하는 상황을 고려해 보자. 이 같은 상황에서는, $x \in R^d$ 대신 $\phi(x) \in F$ 를 고려해야 하므로, 학습 데이터의 집합 $D = \{x_i | i = 1, \dots, N\} \subset R^d$ 를 최대한 포함하는 최소 체적의 볼 $B \subset R^d$ 를 찾는 과정은 집합 $D_F = \{\phi(x_i) | i = 1, \dots, N\} \subset F$ 를 최대한 포함하는 최소 체적의 볼 $B_F \subset F$ 를 찾는 과정으로 바뀌게 된다. 이러한 고려를 바탕으로 SVDD 기법의 논리 전개를 따라 가면 최종적으로 다음의 최적화 문제를 얻어 진다:

$$\begin{aligned} \min_a \quad & \sum_{i=1}^N \sum_{j=1}^N a_i a_j k(x_i, x_j) - \sum_{i=1}^N a_i k(x_i, x_i) \\ \text{s.t.} \quad & \sum_{i=1}^N a_i = 1, \quad a_i \in [0, C], \quad \forall i. \end{aligned} \quad (9)$$

여기에서, 이론의 전개는 비록 커널 특징 공간 F 위에서 진행되었지만 커널 트릭의 효과적인 적용으로 말미암아 최종 결과로 얻어진 최소화 문제 (9)에는 커널 특징함수 ϕ 가 직접적으로 등장하지는 않게 됨을 관찰할 수 있다. 이에 따라, (9)의 풀이는 커널 특징공간을 직접적으로 고려할 필요가 없이 입력 공간 위에서 곧바로 수행할 수 있게 된다. 그리고 유도과정에서 얻게 되는 커널 특징 공간 F 위에서 정의되는

3) 함수 $k: R^d \times R^d \rightarrow R$ 가, 특정한 함수 $\phi: R^d \rightarrow F$ 를 이용하여 모든 입력 벡터 쌍 $x, y \in R^d$ 위에서의 값을 내적 형태인 $\langle \phi(x), \phi(y) \rangle$ 로 표현할 수 있을 때(즉, 커널 트릭

$$k(x, y) = \langle \phi(x), \phi(y) \rangle, \quad \forall x, y \in R^d$$

이 성립할 때), 우리는 함수 k 를 Mercer 커널(kernel), 혹은 간단하게 커널이라고 부른다. 서포트 벡터 학습 분야에서, 함수 ϕ 는 일반적으로 커널 특징함수(kernel feature map) 혹은 특징함수로 불리고, ϕ 의 공역(co-domain) F 는 커널 특징 공간(kernel feature space) 혹은 특징공간으로 불려진다. 본 논문에서 주로 사용하게 될 가우시안 커널 $k(x, y) = \exp(-\|x - y\|^2 / \sigma^2)$ 는 서포트 벡터 학습 분야에서 가장 널리 사용되는 Mercer 커널 중 하나이다.

4) 우리가 실용적인 문제에 주로 사용하는 커널의 경우에는, 거의 예외 없이 $\dim F \gg d$ 이 성립하고, $\dim F = \infty$ 인 경우도 많다.

볼 B_F 의 중심 $a \in F$ 는 조건 (3)에 대응해서 $a = \sum_{i=1}^N a_i \phi(x_i)$ 이 됨도 기억해 두자. 앞에서 나온 각주에서 잠깐 언급한 바와 같이 가우시안 커널은 서포트 벡터 관련 연구에서 가장 널리 쓰이는 커널 중 하나인데, 이러한 경향은 단일 클래스 서포트 벡터 학습 분야에서도 예외가 아니다. 특히, 가우시안 커널의 경우에는 모든 $x \in R^d$ 에 대하여 $k(x, x) = 1$ 이 성립하므로, 최소화 문제 (9)는 다음과 같이 보다 더 간단한 형태로 단순화 될 수 있다:

$$\begin{aligned} \min_a \quad & \sum_{i=1}^N \sum_{j=1}^N a_i a_j k(x_i, x_j) \\ \text{s.t.} \quad & \sum_{i=1}^N a_i = 1, \quad a_i \in [0, C], \quad \forall i. \end{aligned} \quad (10)$$

그리고 이 경우에는 학습이 종료된 후 주어진 시험 입력 $x \in R^d$ 의 정상클래스 소속 여부는, 결정 함수 f 가 다음 조건

$$\begin{aligned} f(x) &= R^2 - \|\phi(x) - a\|^2 \\ &= R^2 - (1 - 2 \sum_{i=1}^N a_i k(x_i, x) \\ &\quad + \sum_{i=1}^N \sum_{j=1}^N a_i a_j k(x_i, x_j)) \\ &\geq 0 \end{aligned} \quad (11)$$

을 만족하는 지를 관찰하여 판정할 수 있다.

2.2 SVDD를 이용한 노이즈 제거

본 논문의 목적은 특징 공간 내에서 노이즈로 왜곡된 테스트 입력을 구 모양의 서포트를 이용해서 정상 데이터로 바꾸는 것이다. 바꾸는 방법은 특징 공간상에서 비정상 데이터를 직접 정상 데이터 영역에 해당하는 SVDD 구의 경계면으로 옮기면 된다. 정상 데이터를 이용해서 학습을 하면 그림 1에 있는 것과 같은 작은 구가 만들어지는데 이 구가 바로 SVDD 구이다.

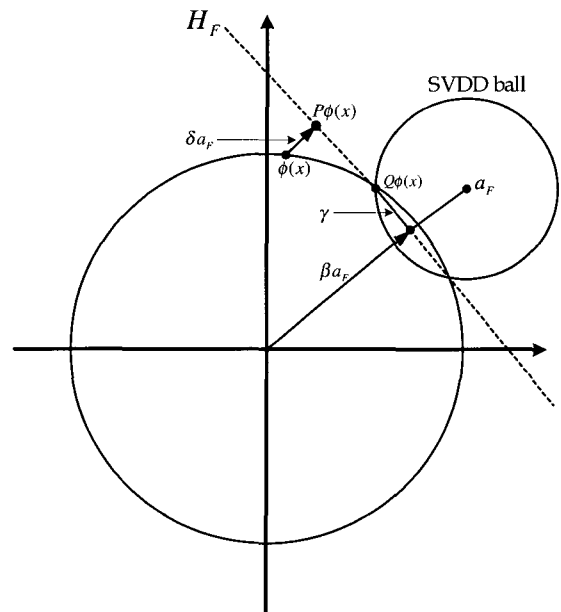


그림 1. 본 논문에서 제안하는 노이즈 제거 방법.
Fig. 1. Proposed de-noising method.

RBF 커널을 사용하면 모든 데이터들이 그림1에 있는 것과 같이 크기가 1인 단위 구의 표면에 있게 된다. 정상 데이터의 경우에는 단위 구와 SVDD 구가 만나는 곳에 존재하지만 노이즈를 가지고 있는 비정상 데이터의 경우에는 SVDD 구에는 포함되지 않는다. 그래서 본 논문에서는 노이즈를 제거하기 위해서 단위 구에 있는 $\phi(x)$ 를 SVDD 구와 만나는 교점인 $Q \phi(x)$ 로 옮기는 전략을 사용한다. 즉, $\phi(x)$ 를 $Q \phi(x)$ 로 옮기는 것이 본 논문의 목적이며 비정상 데이터의 노이즈를 제거하여 정상 데이터로 만드는 과정인 것이다. $Q \phi(x)$ 가 $\phi(x)$ 의 de-noised pattern이 될 수 있는 이유는 참고 문헌 [18]을 통해서 알 수 있다. 노이즈를 제거하기 위해서는 다음과 같은 간단한 절차를 밟으면 된다. 그림 1처럼 비정상 데이터 $\phi(x)$ 를 분리 초평면(separating hyperplane) H_F 로 사영시키면 $P\phi(x)$ 가 되는데 이를 정상 데이터 영역인 $Q \phi(x)$ 로 옮겨주는 과정을 밟으면, $Q \phi(x)$ 가 다음과 같은 형태로 표현될 수 있음을 쉽게 보일 수 있다.

$$Q \phi(x) = \lambda_1 \phi(x) + \lambda_2 a_F \quad (12)$$

$$\text{단, } \lambda_1 = \frac{\gamma}{\sqrt{1+2(\delta-\beta)k_x \alpha + (\delta-\beta)^2 \alpha^T K \alpha}}$$

$$\lambda_2 = \frac{\gamma(\delta-\beta)}{\sqrt{1+2(\delta-\beta)k_x \alpha + (\delta-\beta)^2 \alpha^T K \alpha}}$$

이상의 과정을 밟아 구한 denoised pattern $Q \phi(x)$ 는 특정 공간에 존재하기 때문에 이를 다시 입력 공간으로 매핑(mapping)시켜야 한다[12, 13]. 만약 역함수 $\phi^{-1}: F \rightarrow R^d$ 이 존재한다면 pre-image를 구하는 것은 아주 간단한 일이다. 하지만 일반적으로 모든 데이터에 대한 정확한 pre-image는 존재하지 않는다. 그래서 각 데이터에 대한 근사해를 찾아야 한다[13, 14, 15]. 이를 위해서 한 데이터와 그 주변의 데이터 사이의 입력 공간에서의 거리 정보와 특정 공간에서의 거리 정보 사이에 간단한 관계가 있다는 것을 이용하여 입력 공간에서의 $Q \phi(x)$ 의 근사해 \hat{x} 를 구할 수 있다[13].

3. 모의 실험

3.1 얼굴 영상 데이터

이번 실험에 사용한 얼굴 영상⁵⁾은 모두 200개의 2차원 벡터인 얼굴 이미지를 사용하였는데 이 이미지는 레이저 스캐너(CyberwareTM)로 기록되어진 3차원 얼굴 모델의 데이터베이스에서 얻어진 것이다. 원래 이 이미지들은 256×256 픽셀 크기의 칼라 이미지를 8비트 흑백이미지로 변환하고 얼굴의 머리카락을 얼굴에서 완전히 제거한 이미지이다. 시뮬레이션에 사용한 이미지는 모두 200개인데 임의로 100개의 데이터는 학습 데이터로 사용하고, 나머지 100개의 데이터는 테스트 데이터로 사용하였다. 실험에 앞서 각 이미지를 backward warping[16]을 이용해서 원본 이미지를 shape와 texture로 각각 분리해서 따로 실험을 하였다. 만약 이미지를 shape과 texture로 나누지 않고 원본 이미지를 그대로 실험에 사용하면 학습을 할 때, 픽셀 단위로 학습하기 때문에 결과 이미지가 얼굴이 겹쳐서 나오는 것과 같이 흐리게 보인다. 결과가 흐리게 나오는 이유는 사람마다 얼굴, 눈, 코, 입,

귀 등의 크기와 각각의 위치가 조금씩 다르기 때문에 그런 현상이 생긴다. 이미지를 shape과 texture로 분리한 후, 본 논문에서 제안한 방법론을 이용해서 shape과 texture에 각각 있는 노이즈를 제거한 후 forward warping[16]을 이용해서 노이즈가 제거된 shape과 texture를 합성하면 본 논문에서 제안한 결과 이미지가 나온다.

3.2 시뮬레이션 절차

본 논문에서 제안한 방법론을 통해서 저해상도의 얼굴 영상을 고해상도의 얼굴 영상으로 복원하는 절차는 다음과 같다. 다음의 절차는 참고문헌 [17]에서 본 논문의 저자 등에 의해 제안된 순서를 따르고 있다:

- ① 학습 데이터로 선택된 N개의 얼굴 이미지를 backward warping을 통해서 N개의 texture 벡터 T_1, T_2, \dots, T_N 와 x, y방향을 가진 shape 벡터 $S_{1x}, S_{2x}, \dots, S_{Nx}, S_{1y}, S_{2y}, \dots, S_{Ny}$ 2N개를 나누고, 각각 학습을 한다.
- ② 테스트 데이터에 해당하는 저해상도의 이미지를 절차 ①처럼 각각 shape와 texture로 나누고, bicubic 보간법을 이용해서 고해상도로 각각 변환시킨다.
- ③ 고해상도로 변환된 shape와 texture로, 본 논문에서 제안한 노이즈 제거 방법론을 이용해서 각각 $Q \phi(x)$ 를 구한다.
- ④ 특정 공간상에 있는 $Q \phi(x)$ 를 입력공간으로 옮기기 위해서 pre-image[13]를 이용한다.
- ⑤ 입력 공간으로 옮겨진 shape와 texture를 forward warping을 통해서 이미지로 합성한다.

4. 결과 고찰

이번 시뮬레이션에서 사용한 저해상도 이미지는 32 × 32 픽셀의 이미지이다. 이 이미지를 고해상도의 이미지 256 × 256 픽셀의 이미지로 변환하면 그림2와 같이 알아보기 힘든 이미지로 변환된다. 그림 3은 저해상도의 이미지를 shape과 texture로 나누어서 Bicubic 보간법을 사용해서 고해상도로 복원한 후, forward warping을 이용해서 shape과 texture를 합성했을 때의 이미지이다. 그림 2보다는 얼굴 영상을 알아보기 쉽지만 여전히 흐릿하고 불명확하게 보인다. 그림 4는 본 논문에서 제안한 방법론을 이용해서 저해상도의 얼굴 영상을 고해상도의 얼굴 영상으로 복원한 결과이다. 그림 3과 비교했을 때 눈, 코, 입 등이 명확하게 보일 뿐 아니라, 원본 얼굴 영상인 그림 5와 비교했을 때 각 얼굴이 매우 비슷하다는 것을 알 수 있다. 비록 시뮬레이션의 결과가 좋게 나왔지만 여전히 문제점이 있다. 가장 큰 문제점은 저해상도의 얼굴 영상의 shape과 texture를 각각 구하는 것이다. 본 논문에서는 저해상도 이미지에서 직접적으로 shape과 texture를 구하진 못했다. 대신 고해상도 이미지를 각각 shape과 texture를 나누고, 각각 nearest neighborhood 보간법을 이용해서 32 × 32로 바꾸어서 사용하는 트릭을 사용했다. 물론 처음 사용한 고해상도의 shape과 texture의 값과 트릭으로 바꾼 저해상도에서 고해상도로 변환된 shape과 texture의 값은 확연히 차이가 있지만 저해상도의 shape과 texture를 구하는 문제점은 여전히 남아있고, 향후에 개선해야 할 문제점이다.

5) 본 논문에서 사용한 얼굴영상은 Max Plank Institute for Biological Cybernetics로부터 제공받은 것임.



그림 2. 학습에 사용된 얼굴 영상.
Fig. 2. Facial images used in training.



그림 3. Bicubic 보간법을 이용했을 때 복원된 얼굴 영상.
Fig. 3. Reconstruction facial images when used bicubic interpolation.



그림 4. 제안한 방법론을 이용했을 때 복원된 얼굴 영상.
Fig. 4. Reconstruction facial images when used proposed method.



그림 5. 원본 얼굴 영상.
Fig. 5. Original facial images.

참 고 문 헌

[1] N. Cristianini and J. Shawe-Taylor, "An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods," Cambridge, U.K.: Cambridge University Press, 2000.

[2] B. Schölkopf, and A. J. Smola, "Learning with Kernels," Cambridge, MA: MIT Press, 2002.

[3] C. Campbell and K. P. Bennett, "A linear programming approach to novelty detection," *Advances in Neural Information Processing Systems*, vol. 13, pp. 395-401, Cambridge, MA: MIT Press, 2001.

[4] K. Crammer and G. Chechik, "A needle in a haystack: Local one-class optimization," In *Proceedings of the Twentieth-First International Conference on Machine Learning*, Banff, Alberta, Canada, 2004.

[5] G. R. G. Lanckriet, L. El Ghaoui, and M. I. Jordan, "Robust novelty detection with single-class MPM," *Advances in Neural Information Processing Systems*, vol. 15, pp. 905-912, Cambridge, MA: MIT Press, 2003.

[6] G. Rätsch, S. Mika, B. Schölkopf, and K. -R.

Müller, "Constructing boosting algorithms from SVMs: An application to one-class classification," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, pp. 1-15, 2002.

[7] B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson, "Estimating the support of a high-dimensional distribution," *Neural Computation*, vol. 13, pp. 1443-1471, 2001.

[8] B. Schölkopf, J. C. Platt, and A. J. Smola, "Kernel Method for Percentile Feature Extraction," Technical Report MSR-TR-2000-22, Microsoft Research, 2000.

[9] D. Tax, "One-Class Classification," Ph.D. Thesis, Delft University of Technology, 2001.

[10] D. Tax and R. Duin, "Support Vector Domain Description," *Pattern Recognition Letters*, vol. 20, pp. 1191-1199, 1999.

[11] S.-W. Lee, J.-S. Park, and S.-W. Hwang, "How can we reconstruct facial image from partially occluded or low-resolution one?," *Lecture Notes in Computer Science*, vol. 3338, pp. 386-399, 2004.

[12] S. Mika, B. Schölkopf, A. Smola, K. R. Müller, M. Scholz, and G. Rätsch, "Kernel PCA and de-noising in feature space," *Advances in Neural Information Processing Systems*, vol. 11, pp. 536-542, Cambridge, MA: MIT Press, 1999.

[13] J. T. Kwok and I. W. Tsang, "The pre-image problem in kernel methods," *IEEE Transactions on Neural Networks*, vol. 15, pp. 1517-1525, 2004.

[14] T. F. Cox and M. A. A. Cox, "Multidimensional Scaling," *Monographs on Statistics and Applied Probability*, vol. 88, 2nd Ed., London, U.K.: Chapman and Hall, 2001.

[15] C. K. I. Williams, "On a connection between kernel PCA and metric multidimensional scaling," *Machine Learning*, vol. 46, pp. 11-19, 2002.

[16] T. Vetter and N.E. Troje, "Separation of texture and shape in images of faces for image coding and synthesis," *Journal of the Optical Society of America A*, vol. 14, pp. 2152-2161, 1997.

[17] J. Park, D. Kang, J. T. Kwok, S.-W. Lee, B.-W. Hwang, and S.-W. Lee, "Facial image reconstruction by SVDD-based pattern de-noising," *Lecture Notes in Computer Science*, vol. 3832, pp. 129-135, 2005.

[18] A. Ben-Hur, D. Horn, H. T. Siegelmann, and V. Vapnik, "Support vector clustering," *Journal of Machine Learning Research*, vol. 2, pp. 125-137, 2001.

저 자 소 개



강대성(Daesung Kang)

2004년 : 고려대학교 제어계측공학과 졸업
(학사)

2005년 ~ 현재 : 고려대학교 대학원
제어계측공학과 석사과정

관심분야 : SVM, 강화학습

phone : 019-506-2086, 922-0863

E-mail : mpkds@korea.ac.kr



박주영(Jooyoung Park)

1983년 : 서울대학교 전기공학과 졸업 (학사)

1985년 : 한국과학기술원 졸업(석사)

1985년 3월~1988년7월 : 한국전력공사
월성원자력발전소 근무

1992년 : University of Texas at Austin
전기 및 컴퓨터공학과 졸업(박사)

1992년8월~1993년2월 : 한국전력공사
전력경제연구실 선임전문원

1993년3월~현재 : 고려대학교 과학기술대학 제어계측공학과
교수

관심분야 : 신경망이론, 학습이론, 제어이론

E-mail : parkj@korea.ac.kr