

화상분석을 이용한 소프트 센서의 설계와 산업응용사례 2. 인조대리석의 품질 자동 분류

류준형* · 유 준†

부경대학교 화학공학과
608-739 부산광역시 남구 용당동 산 100
*동국대학교 에너지환경시스템학부
780-714 경북 경주시 석장동 707
(2010년 3월 27일 접수, 2010년 4월 19일 채택)

Soft Sensor Design Using Image Analysis and its Industrial Applications Part 2. Automatic Quality Classification of Engineered Stone Countertops

Jun-Hyung Ryu* and J. Jay Liu†

Department of Chemical Engineering, Pukyong National University, San 100, Yongdang-dong, Nam-gu, Busan 608-739, Korea
*Department of Energy & Environmental Systems, Dongguk University, 707 Seokjang-dong, Gyeonju-si, Gyeongbuk 780-714, Korea
(Received 27 March 2010; accepted 19 April 2010)

요 약

본 연구에서는 화상분석(image analysis)에 기반한 소프트 센서를 설계하고, 이를 색상-질감 특성을 가진 제품의 외관품질 자동분류에 적용하였다. 색상과 질감(texture)을 동시에 가진 화상을 분석하기 위해 다중해상도 다변량 화상분석(Multiresolutional Multivariate Image Analysis, MR-MIA) 기법을 이용하였으며, 자동 분류를 위한 감독 학습법(supervised learning)으로는 Fisher의 판별분석(Fisher's discriminant analysis)을 사용하였다. 잠재변수법의 하나인 Fisher의 판별분석을 사용하였기 때문에, 제품의 외관을 서로 다른 불연속적인 부류로 분류할 수 있을 뿐 아니라, 연속적인 외관 변화를 일관적이고 정량적으로 추정할 수 있는 물론, 외관의 특성 해석 또한 가능하였다. 이 방법은 인조대리석 제조 공정에서 중간 및 최종 제품의 외관 품질을 자동으로 분류하는 데에 성공적으로 적용되었다.

Abstract – An image analysis-based soft sensor is designed and applied to automatic quality classification of product appearance with color-textural characteristics. In this work, multiresolutional multivariate image analysis (MR-MIA) is used in order to analyze product images with color as well as texture. Fisher's discriminant analysis (FDA) is also used as a supervised learning method for automatic classification. The use of FDA, one of latent variable methods, enables us not only to classify products appearance into distinct classes, but also to numerically and consistently estimate product appearance with continuous variations and to analyze characteristics of appearance. This approach is successfully applied to automatic quality classification of intermediate and final products in industrial manufacturing of engineered stone countertops.

Key words: Fisher Discriminant Analysis, Quality Inspection, Visual Appearance, Multiresolutional Multivariate Image Analysis, Color-texture Analysis

1. 서 론

제품 표면의 시각적 모습, 즉 외관(外觀)은 그 제품이 전사용 또는 다른 제품의 외장(外裝)용으로 사용될 경우엔 매우 중요한 품질 요소 중 하나이다. 그 대표적인 예로 TV 또는 모니터에 사용되는 박막 액정표시장치인 TFT-LCD 패널, 그 부품인 편광판과 TFT-LCD 유리판 등을 들 수가 있다. 이러한 경우엔 그 제품의 물리, 기계적 성질뿐 아니라 외관, 즉 시각적 품질 또한 제어되거나 유지되어야 한

다. 부유선별공정의 경우에는 기계시각을 이용한 제어 및 모니터링 자동화 사례가 비교적 많으나[1,2], 그 외의 공정에는 시각적 품질의 제어 또는 모니터링의 자동화 사례가 극히 드물고, 전적으로 숙련된 작업자의 판단에 의지한다. 그마저도 대부분의 경우엔 최종 제품의 양품, 불량품을 수동으로 판별하는데 그치는 수준이다. 이러한 방법은 많은 시간과 인적자원을 필요로 하고, 유지를 위한 지속적인 교육 등도 필요하다. 그 뿐 아니라, 가장 심각한 사람 판단의 불일치성이 아직도 미해결 문제로 남아있다[3].

이러한 응용에서 가장 어려운 점은 문제에 관한 사전 지식 또는 정보가 극히 제한적이라는 것이다. 1부[3]의 예와 같이 양품, 불량품의 판정이 완전하지 않거나, 외관의 중요한 요소에 대한 정보가 거

†To whom correspondence should be addressed.

E-mail: jayliu@pknu.ac.kr

*이 논문은 부경대학교 천재기 교수님의 정년을 기념하여 투고되었습니다.

의 없는 경우가 대부분이다. 이는 전적으로 사람의 판단에 의존하기 때문이며, 문제의 특성상 명확한 판단 근거나 기준을 갖기가 어렵다는데 원인이 있다. 1부에서 언급한 바와 같이 공정산업의 경우 화상이 담고 있는 장면이 확률론적이기 때문에, 그에 대한 어떤 특정한 가정이 성립되지 않는 것이 가장 근본적인 이유이다.

1부에서는 이러한 문제들을 해결하기 위한 일반적인 방법론으로 화상분석에 기반한 소프트 센서 설계가 소개되었는데, 이 방법론은 매우 유연하여 자유로운 확장이 가능하며 다른 목적으로 응용이 쉽다는 것이 장점이다[4,5]. 본 연구에서도 같은 방법론이 사용되었는데 1부와는 달리 인조대리석 외관의 색상과 질감 정보의 분석을 위해 다중해상도 다변량 화상분석(Multiresolutional Multivariate Image Analysis, MR-MIA)[6]이, 외관의 자동분류를 위해 Fisher 판별분석(Fisher's Discriminant Analysis, FDA)[7]이 각각 사용되었다. MR-MIA는 Liu와 MacGregor가 다변량 화상분석(Multivariate Image Analysis, MIA) [8]과 웨이블릿 질감분석을 결합하여, 화상의 분광정보만 분석할 수 있었던 MIA의 단점을 극복한 방법이다. 비감독 학습(unsupervised learning) 법인 주성분분석과는 달리, FDA는 분류하려는 대상에 대한 정보를 미리 알고서 모델을 학습시켜 어떤 대상이 어느 부류(class)에 속하는지를 예측하는 감독 학습(supervised learning) 법이다.

본 논문에서는 1부에서 제시한 방법론을 따라 응용목적에 맞게 소프트 센서를 설계하고 인조대리석의 외관을 추정, 이를 인조대리석 품질의 자동분류 문제에 적용하는 산업응용사례를 소개하고자 한다. 이 사례연구를 통해 1부에서 제시한 방법론의 우수성 - 확장가능성과 유연성을 증명할 수 있을 것이다. 이 연구에서 외관이란 제품의 색상-질감적(color-textured) 외관을 의미한다. 이 논문의 구성은 다음과 같다. 2절에서는 색상과 질감을 동시에 분석하기 위한 MR-MIA와 FDA 등의 방법을 융합한 새로운 질감분석법이 소개된다. 이 방법은 3절에서 컬러 인조대리석 제조 공정에서 중간 및 최종 제품의 외관품질 자동분류에 적용되었고, 본 논문의 요약과 결론은 4절에 있다.

2. 색상-질감 화상의 분석

2-1. 다중해상도 다변량 화상분석(Multiresolutional Multivariate Image Analysis, MR-MIA)

1부에서 언급한 바와 같이 제품의 외관은 제품 표면의 색상과 질감에 단독으로 또는 조합으로 의존하는데, 이 논문에서 다루는 인조대리석의 외관은 Fig. 1에서 보듯이 질감과 색상 모두와 관련이 있다. 그러므로 1부에서와는 달리, 이 논문에서는 질감과 색상 정보 모두의 추출에 중점을 둔다. 이와 같은 이유로 색상 정보와 질감정보를 동시에 분석하는 MR-MIA[6]를 사용하였다. MR-MIA는 웨이블릿과 밀접한 관계가 있는 다중해상도 분석(Multiresolution Analysis, MRA)[9]과 MIA를 결합하여, 기존에 grayscale 화상에만 적용할 수 있었던 웨이블릿 질감분석을, RGB 화상은 물론 나아가서 다중분광 화상의 질감분석도 가능하게 하는 방법이다. 본 논문에서는 이에 대해 간단 설명하고자 하며, 자세한 설명은 참고문헌을 참고하기 바란다.

Fig. 2에 나타난 것과 같이, 다변량 화상은 서로 합동(congruent)인 화상을 쌓은 것으로[8], 2차원의 기하학적 좌표계와 1차원의 분광 좌




Fig. 1. Four sample images of countertop slabs with labels. Meanings of alphabet letters in image labels are: 'S' - after surface polishing, 'U' - before polishing, 'Q' - questionable quality, and 'G' - good quality (following expert graders' evaluations). Two digit numbers denote slab numbers. In sections 3-2 and 3-3, original images are subdivided two smaller images as shown in slab S-01-Q.




Fig. 2. A multivariate image can be considered as a stack of congruent images measured from different variables (for example, 512×512 congruent images from 4 different wavelength bands, $\lambda_1 \sim \lambda_4$). Then, it is same as a three-way data array and each pixel can be represented by a multivariate vector as shown above.

표계를 가진 3차원 행렬로 간주할 수 있다. 다변량 화상($N \times K \times Q$) \mathbf{X} 는 Q 개의 ($N \times K$) 화상을 쌓은 것으로 주성분분석에 의해 다음과 같이 분해될 수 있다.

$$\mathbf{X} = \sum_{a=1}^A \mathbf{T}_a \otimes \mathbf{p}_a + \mathbf{E} \quad (1)$$

여기서 밑줄 ‘_’은 3차원 행렬, $\mathbf{T}_a (N \times K)$ 는 스코어 행렬, $\mathbf{p}_a (Q \times 1)$ 는 부하(loading)벡터, \otimes 는 Kronecker 곱, $\mathbf{E} (N \times K \times Q)$ 는 잔차 행렬을 각각 나타낸다. 주성분분석을 이용한 MIA는 색상 또는 분광정보를 추출하는데 아주 우수하여, 많은 적용사례가 보고되었으나[10-12], 질감과 관계 있는 공간정보를 추출하는 데는 한계가 있다. MIA 자체가 분광정보를 추출하기 위해 고안되었기 때문에, 주성분분석을 수행할 때 공간정보의 손실이 생기는 것이 그 이유이다[13]. 이러한 문제점을 극복하기 위해 몇 가지 방법이 제안되었으나, 모두 특정한 문제에 국한한 경우이며 다른 문제에 적용할 때는 제한이 따른다[14,15].

다중해상도 분석은 화상의 공간적 특성 확인을 위한 아주 간편한 계층적 체계를 제공한다. 높은 분해능에서 화상의 세부 정보는 화상이 담고 있는 장면의 물리적 구조의 차이를 묘사하며, 낮은 분해능에서 이러한 세부 정보는 화상 전체의 내용을 제공하는 보다 큰 구조에 해당한다[9]. 다중해상도 분석의 기본 개념은 연쇄적 근사(successive approximation)에 기초한 신호 분해이며, 따라서 웨이블릿 분해를 통해 구현이 가능하다.

다중해상도 분석의 공리적 정의(참고문헌[16]의 식 (4.2.1)-(4.2.3))를 살펴보면, grayscale 화상의 MRA 결과인 부화상(sub-image)이 서로 합동이 되고 새로운 다변량 화상을 이루는 것을 알 수 있다. 따라서 단변량 화상, 예를 들어 grayscale 화상이라 할지라도 다중해상도 분석을 통해 형성된 다변량 화상에 MIA를 적용할 수 있다. 이 경우엔 웨이블릿 부화상이 다변량 화상의 분광 좌표계를 이루게 된다. 이론적인 고찰을 통해 grayscale 화상에 MR-MIA를 적용하는 것과 1부에서 사용한 웨이블릿 질감분석이 동일하다는 사실이 증명되었다[6]. 또한 다변량 화상의 경우 MRA 후 각 분해능의 부화상이 새로운 다변량 화상을 형성하게 되므로, J단계 이산 웨이블릿 변환을 사용했을 때 모두 $3J+1$ 개의 새로운 다변량 화상이 생성된다. 이 새로운 다변량 화상을 MIA를 통해 분석하면 각 분해능에서 분광정보를 분석할 수 있게 된다. 이러한 점은 이산 웨이블릿 변환 또는 웨이블릿 packet 등 MRA 종류에 관계없이 모두 적용된다. 이렇게 MRA와 MIA를 결합한 방법을 MR-MIA라 부르며 MR-MIA는 분광정보와 질감정보를 하나의 체계 안에서 분석이 가능하게 한다. MR-MIA 방법론에 대한 이론적 고찰, 예시 및 적용 등 자세한 내용은 참고문헌 [6]을 참조하기 바란다.

2-2. Fisher 판별분석(Fisher's Discriminant Analysis, FDA)

인간의 시각 시스템은 화상이 가지고 있는 특징의 선택적 추출은 물론 추출된 정보의 압축과 해석을 손쉽게 할 수 있다[3]. 본 논문에서 화상분석의 최종 목적은 인조대리석의 자동분류이므로 화상으로 부터 추출된 질감 및 색상 정보를 잠재 변수 공간에 투영할 때 감독 학습법의 하나인 Fisher 판별분석(Fisher's Discriminant Analysis, FDA)을 사용하였다.

앞에서 이미 언급한 바와 같이 감독 학습은 분류하려는 대상에 대한 정보, 즉 부류표시(class label) y 와 그 대상을 설명하는 특징 벡터 \mathbf{x} 가 쌍을 이룬 데이터가 필요하다. FDA에서는, 일반적으로 c 개의 부류가 있을 때 d 차원의 입력공간을 ($c-1$) 차원의 공간으로 투영한다($d \leq c$)[7]. 고차원의 데이터를 저차원으로 투영할 때 주성분분석이 데이터의 표현에 효과적인 잠재변수공간을 찾는 반면, FDA는 데이터의 분류에 효과적인 잠재변수공간을 찾기 때문에 이러한 이유로 FDA를 본 연구에 사용하였다.

S_B 를 군간(between-class) 공분산(covariance) 행렬, S_W 를 군내(within-class) 공분산 행렬이라 하면 각각 다음과 같이 정의된다.

$$S_W = \sum_{i=1}^c S_i \quad (2)$$

$$S_i = \sum_{\mathbf{x} \in D_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^T \quad (3)$$

$$S_B = \sum_{i=1}^c n_i (\mathbf{m}_i - \mathbf{m})(\mathbf{m}_i - \mathbf{m})^T \quad (4)$$

이 때 \mathbf{m}_i 는 i 번째 부류의 평균벡터, D_i 는 i 번째 부류의 특징벡터 \mathbf{x} 의 집합, n_i 는 D_i 내 특징벡터의 개수를 각각 나타낸다. 매핑 행렬 W 는 다음을 최대화한다.

$$J = \frac{|\mathbf{W}^T S_B \mathbf{W}|}{|\mathbf{W}^T S_W \mathbf{W}|} \quad (5)$$

다시 말해, W 는 투영되었을 때 같은 부류내의 거리는 최소화하고, 동시에 다른 부류와의 거리는 최대화하여 판별을 용이하게 한다. J

는 Fisher의 기준이라고 불리며 투영된 벡터 $\mathbf{z}(=\mathbf{W}\mathbf{x})$ 는 판별 변수라 불린다. Fisher의 기준은 때로 판별의 성능을 나타내는 기준으로 쓰이기도 한다.

매핑 행렬 W 를 찾는 것은 고유치(eigenvalue) 문제와 밀접한 관련이 있다. 일반적으로 W 의 열 \mathbf{w}_i 는 다음 식에서 가장 큰 고유치에 해당하는 일반화된 고유벡터이다.

$$S_B \mathbf{w}_i = \lambda_i S_W \mathbf{w}_i \quad (6)$$

위 식에서 S_B 가 정칙(nonsingular)이면 전형적인 고유치 문제가 되지만, S_B 는 계수가 $c-1$ 인 행렬이므로 0이 아닌 고유치가 $c-1$ 개 존재하며 따라서 고유벡터도 $c-1$ 개만 존재한다[17]. 하지만 식 (2)는 $\mathbf{W}^T S_W \mathbf{W}$ 의 역행렬이 존재할 때만 계산이 가능하기 때문에 다음과 같이 행렬식 대신 대각합(trace)을 사용하여 수치적 문제를 해결하였다[18].

$$J = \text{tr} \left(\frac{\mathbf{W}^T S_B \mathbf{W}}{\mathbf{W}^T S_W \mathbf{W}} \right) \quad (7)$$

3. 인조대리석 외관품질의 자동 분류

3-1. 문제 정의

본 연구에 사용된 인조대리석 시료의 크기는 약 $20.4 \text{ cm} \times 12.9 \text{ cm} \times 1.3 \text{ cm}$ ($L \times W \times H$)이며, 1부에서 설명한 공정과 동일한 과정을 통해 제조된 인조대리석이다. Fig. 1의 화상을 포함하여 본 연구에 사용된 모든 인조대리석의 화상은 컬러 스캐너를 이용하여 수집하였다. 이 때 조건은 300DPI, 8 bit 이며, 화상 파일 포맷은 압축을 사용하지 않는 비트맵 형식으로 저장하였다. 이 원본 화상의 외곽 부분 등을 잘라내어 최종적으로 $2,300 \times 1,400$ 의 화상을 분석에 사용하였다. Appendix Table A1에 전체 인조대리석 화상의 리스트를 나타내었다.

Fig. 3에 표면연마(surface polishing) 전후의 인조대리석 외관의 변화를 공정도의 일부와 함께 나타내었다. Fig. 1과 3에서 표면연마 전과 후 인조대리석의 외관 차이는 쉽게 알 수 있지만, 연마 후 또는 연마 전 인조대리석의 양품과 불량품의 외관의 차이는 숙련가가 아니면 구분하기 매우 어려움을 알 수 있다. 연마 후 인조대리석의 경우 연마 전보다 명암 대비가 더 크고 색상 또한 선명하다. 따라서 육안으로 외관품질의 차이를 판별하는데 있어 연마 전 대리석보다 연마 후 대리석이 더 용이하며, 현재 해당 공정에서도 숙련된 판별가들이 연마가 끝난 최종 제품을 양불 판정을 하고 있다. 연마 전 제품의 양불 판정이 가능하다면 불량품의 연마에 사용되는 물 및 연마제 등의 불필요한 사용을 줄일 수 있다는 이점이 있다. 하지만 연마 전 인조대리석의 외관 품질판정은 Fig. 1과 3에 나타난 특성상 불가능하여, 공정의 숙련자들도 만족할 만한 판별 결과를 얻지 못하는 실정이다. 본 연구에 사용된 모든 인조대리석의 외관품질에 대한 숙련된 판별




Fig. 3. A part of countertops manufacturing. Color and textural properties of countertops change after surface polishing.

가들의 판정을 Appendix의 Table A1에 나타내었다. 연마 전 인조대리석 12개는 연마 후 인조대리석과 동일한 인조대리석의 부분으로, 이를 나타내기 위해 화상의 레이블에 숫자를 동일하게 사용하였다. Table A1에 연마 전 인조대리석의 판정이 있는 이유도 이 때문이다.

본 연구에서 첫 번째 목적은 인조대리석의 외관품질을 분석하고 연마 후 인조대리석의 품질을 자동분류 하는데 있으며, 궁극적인 목적은 경제적인 가치가 높은 연마 전 인조대리석의 품질 자동분류에 있다.

3-2. 인조대리석 외관품질의 분석

1부에서 설명한 질감분석 방법은 grayscale 화상에 대한 것인 반면, 2절에서 언급한 바와 같이 본 연구에서 다루는 인조대리석의 외관품질은 질감과 색상에 관련이 있다. 따라서 grayscale 질감분석 방법을 color로 확장하는 것이 필요한데, 본 연구에서는 MR-MIA법 중, 첫 번째 방법을 사용하였다[6]. 이 방법은 grayscale 질감분석을 color 영역으로 확장시킨 것으로, 궁극적으로는 correlation signature[19]와 동일하다고 분석된다 있다[6]. 이에 대한 자세한 설명은 참고문헌을 참조하기 바란다. 일반적으로 MR-MIA에서 Q channel 화상의 경우 화상으로부터 추출한 색상-질감 특징벡터의 크기는 (근사 계수를 포함했을 때) $Q(3J+1)$ 이다. 여기서 J는 이산 웨이블릿 분해단계 수, Q는 color channel 수이다.

본 연구를 위해 획득한 인조대리석 사진은 총 29개(연마 후 17개, 연마 전 12개)로 각기 다른 조업조건에서 제조된 인조대리석을 스캔한 것이다 (12개의 동일 인조대리석 쌍 제외). 우선 MR-MIA법이 색상-질감을 가진 인조대리석의 분석에 적합한가 알아보기 위해, 육안으로도 외관의 차이를 쉽게 구분할 수 있는 연마 전/후 대리석의 외관분석을 실시하였다. 1부에서와 마찬가지로, 먼저 \mathbf{X} 의 관측수를 증가시키기 위해 원래의 화상을 겹치지 않는 2개의 작은 (1,150×1,400) 화상으로 나누었다. 그리고 1차 Coiflet 필터를 사용하여 R, G, B 각 채널 단변량 화상의 2차원 이산 웨이블릿 변환을 수행하였다. 이 때 5단계 분해 단계를 사용했으므로 전체 부화상, 즉 2차원 웨이블릿 계수의 개수는 $3(3 \times 5 + 1) = 48$ 개이다(a_5 와 d_{0j}^k ; $k \in \{h, v, d\}$, $j \in \{1, 2, 3, 4, 5\}$). 그리고 각각 부화상으로부터 에너지 서명을 계산하여 최종적으로 1개의 인조대리석 화상을 (48×1)의 MR-MIA 특징벡터로 나타내었다.




Fig. 4. t_1 - t_2 score plot from PCA of MR-MIA features of all countertops(sanded and unsanded).




Fig. 5. p_1 and p_2 loadings of the PCA model.

Table 1. Cumulative R^2 and Q^2 of the PCA model of MR-MIA features of all countertops (sanded and unsanded)

Dimension of Latent Space	$R^2(\%)$	$Q^2(\%)$
1	97.5	97.4
2	98.8	98.5
3	99.3	99.1

이 특징벡터로 이루어진 데이터 $\mathbf{X}(48 \times 58)$ 를 주성분 분석을 이용하여 분석하고 그 결과를 Fig. 4, 5 그리고 Table 1에 각각 나타내었다.

우선 Table 1로부터 48개의 MR-MIA 특징들로 이루어진 인조대리석 특징벡터의 변화량의 거의 대부분이 3개의 주성분을 가지는 주성분 모델로 설명과 예측이 가능하다는 사실을 알 수 있다. Fig. 4에서 보는 바와 같이, 연마 전과 연마 후의 인조대리석의 외관이 MR-MIA 특징의 주성분분석을 통해서도 쉽게 구분된다는 사실을 보여준다. 비감독 학습법인 주성분분석을 통해서도 쉽게 구분이 가는 것은, 육안으로도 쉽게 구분이 가는 외관의 특징을 MR-MIA가 화상으로부터 효과적으로 추출하기 때문이라 할 수 있다. 또한 Fig. 5의 부하벡터 plot은 주성분 t_1 과 t_2 에 대한 RGB 각 channel 웨이블릿 부화상의 기여도를 나타낸다. 2차원 웨이블릿 계수의 에너지가 갖는 물리적 의미는 각 부화상의 grayscale intensity를 나타내고[6] 근사 부화상은 화상의 배경 등 화상 전체의 내용을, 상세 부화상은 화상 내 구조물의 차이 등을 각각 제공한다[9]. 이를 근거로 인조대리석의 외관을 Fig. 4와 5를 이용하여 설명하면, 연마 전 인조대리석은 전체적인 밝기가 연마 후 대리석보다 밝는데 이는 연마전 대리석이 양의 t_1 값을 갖고(Fig. 4) 각 channel의 근사 부화상의 에너지의 기여도가 양의 부호를 갖는 것(Fig. 4)으로 설명될 수 있다. 그리고 연마 전 인조대리석이 연마 후보다 흐릿하게 보이는 이유는 t_1 에 대한 상세 부화상의 에너지의 기여도가 음의 부호를 갖기 때문(Fig. 5)인데, 이는 연마 전에는 석영 입자와 resin과의 경계면이 뚜렷하지 않기 때문인 것으로 설명할 수 있다. Fig. 5에서 p_1 과 p_2 의 값을 보면 R, G, B 세 channel의 값이 서로 다름을 알 수 있으며, 특히 p_2 의 경우 각 channel의 차이는 두드러진다. 만약 인조대리석의 외관이 색상과는 상관없이 질감에만 관계가 있다면 R, G, B 세 channel 모두 각 부화상의 에너지 기여도가 동일해야 할 것이다. 따라서 본 연구에서 다루는 인조대리석의 외관은 색상-질감 특성을 가지고 있으며, 위의 사실을 종합했을 때 색상-질감 분석이 가능한 MR-MIA의 사용은 적절함을 알 수 있다.




Fig. 6. First three score plots of PCA of sanded countertops.

3.3. 인조대리석 외관품질의 자동분류

연마 후 인조대리석 외관품질의 자동분류를 위해, 우선 3.2절과 마찬가지로 주성분분석을 연마 후 MR-MIA 특징벡터로 이루어진 (48×34) 데이터 행렬에 적용하여 그 결과를 Fig. 6과 Table 2에 나타내었다. Fig. 6에서 각각의 인조대리석 내의 부분적 변화가 서로 다른 인조대리석 간의 변화보다 작음을 알 수 있어, MR-MIA 특징벡터의 주성분이 연마 후 인조대리석의 외관을 어느 정도 표현함을 알

Table 2. Cumulative R^2 and Q^2 of the PCA model of MR-MIA features of sanded countertops

Dimension of Latent Space	$R^2(\%)$	$Q^2(\%)$
1	66.1	63.7
2	80.8	77.5
3	88.0	83.9
4	92.1	88.3
5	94.2	89.9
6	95.7	91.4




Fig. 7. z_1 - z_2 FDA score plot of sanded countertops.

수 있다. 하지만, 종전보다 2배가 넘는 잠재변수를 사용하고도 R^2 값과 Q^2 값이 각각 95.6%와 91.1%로 상대적으로 작을 뿐 아니라, 양품 (Fig. 6에 ▲로 표시)과 불량품 (Fig. 6에 △로 표시)을 효과적으로 구분하지 못하고 있다. 따라서 비감독 학습 잠재변수법인 주성분분석은 육안으로도 아주 쉽게 구분이 가능한 연마 전과 연마 후 인조대리석은 구분할 수 있어도, 육안으로 구분이 어려운 미묘한 차이의 외관은 구분이 불가능함을 알 수 있다. 이에, 감독 학습 잠재변수법 중 하나인 FDA를 연마 후 인조대리석의 자동분류에 적용하여 그 결과 중 하나인 판별변수 plot을 Fig. 7에 나타내었다. 이 때 사용한 부류 표시 y는 속련된 판별가들의 판단을 기준으로 한 것으로, 연마 후 인조대리석 17개 중 10개는 불량품, 나머지 7개는 양품이다.

Fig. 7에서 FDA는 주성분분석과는 달리 연마 후 인조대리석의 양품과 불량품을 완벽하게 구분하고 있다. FDA의 첫 번째 잠재변수, 즉 첫 번째 판별변수는 주로 양품과 불량품의 외관 차이를 설명하며, 두 번째 판별변수는 양품과 불량품 인조대리석 각각 외관의 보다 세밀한 차이를 설명하는 것으로 판단된다. Fig. 8에 첫 번째 판별변수 값이 가장 큰 차이를 보이는 11-S-G_B와 02-S-Q_B 두 인조대리석의 화상을 각각 나타내었다. Fig. 8로부터 두 인조대리석의 외관이 서로 다름을 알 수 있으나, 명확히 어떤 차이가 있는지 속련된 판별가가 아닌 사람이 상세히 묘사하기란 매우 어렵다. 하지만, 3.2절에서와 마찬가지로 잠재변수법의 부하벡터를 해석하면 양품과 불량품 인조대리석의 외관의 차이를 쉽게 해석할 수 있다. Fig. 9에 인조대리석의 양품과 불량품의 차이를 잘 설명하는 첫 번째 판별변수에 해당하는 부하벡터를 나타내었다. 주성분분석과 마찬가지로 FDA의 판별변수 또한 인조대리석 화상에서 추출한 MR-MIA 특징벡터의 선




Fig. 8. Two sanded countertops with extreme quality in Fig. 7.




Fig. 9. FDA first loading w_1 plot of sanded countertops.

형조합이며 이때 계수는 부하벡터의 각 성분이므로, 부하벡터 각 성분의 부호와 크기는 R, G, B 세 channel의 웨이블릿 부화상의 외관 차이에 대한 기여도를 나타낸다. Fig. 7에서 양품 인조대리석은 음의 z_1 값을, 불량품은 양의 z_1 값을 각각 가지므로, 양품의 외관품질에 영향을 끼치는 부화상은 양의 부하벡터 성분을, 불량품의 외관품질에 영향을 끼치는 부화상은 음의 부하벡터 성분을 가질 것이다. Fig. 9로부터 양품 인조대리석의 외관품질에 R channel의 고주파수 영역인 $d_{(1)}^v$ 와 B channel의 고주파수 영역인 $d_{(1)}^d$ 부화상의 기여도가 크음을 알 수 있다. 불량품은 R channel의 중간 및 고주파수 영역인 $d_{(3)}^d$, $d_{(1)}^h$ 와 $d_{(1)}^d$, G channel의 고주파수 영역인 $d_{(1)}^v$ 와 $d_{(1)}^d$, 그리고 B channel의 중간 주파수 영역인 $d_{(2)}^d$ 부화상이 외관품질에 기여도가 크게 나타났다. 또한 Fig. 9에서 R, G, B 각 channel의 부화상의 부하벡터 값이 서로 다르므로, 본 연구에서 다루는 인조대리석은 색상-질감 특징을 가진다는 것을 다시 한번 확인할 수 있다.

이번에는 연마 전 인조대리석의 품질 자동분류를 같은 방법으로 시도하였다. 3.1절에서도 설명했듯이, 연마 전 인조대리석의 외관은 전체적으로 밝아 명암 대비가 작고 색상 또한 선명하지 못하기 때문에 숙련된 판별가조차 만족할 만한 판별결과를 얻지 못하고 있지만, 판별이 가능할 경우 불량품의 불필요한 연마를 없앨 수 있다는 장점을 가지고 있다. 부류표시는 동일한 인조대리석의 연마 후 판별결과를 사용하였다(Table A1 참조).

FDA의 결과인 판별변수 plot을 Fig. 10에 나타내었다. 연마 후 인조대리석의 자동판별과 마찬가지로 연마 전 인조대리석의 품질을 완벽하게 분류하는 것을 알 수 있다. Fig. 11에 Fig. 1에서 가장 큰 외관품질 차이를 보이는 연마 전 인조대리석 11-S-G_B와 10-U-G_A를 나타내었는데, 연마 전의 경우에는 양품과 불량품의 외관 차이가 차이를 숙련되지 않은 사람은 물론, 숙련된 전문가라 할지라도 육안




Fig. 10. z_1 - z_2 FDA score plot of unsanded countertops.




Fig. 11. Two unsanded countertops with extreme quality in Fig. 10.




Fig. 12. FDA first loading w_1 plot of unsanded countertops.

으로 확인하기란 거의 불가능하지만, MR-MIA는 이러한 아주 미묘한 차이를 매우 효과적으로 추출함을 알 수 있다. 또한 Fig. 12에 첫 번째 판별변수의 부하벡터를 나타내었는데, 연마 전 인조대리석의 경우, 양품의 외관품질엔 B channel의 고주파수 영역인 $d_{(1)}^d$ 부화상이, 불량품 외관품질엔 R channel의 고주파수 영역인 $d_{(1)}^d$ 부화상이 기여도가 크음을 알 수 있다. 이를 Fig. 9의 연마 후 인조대리석의 부하벡터와 비교하면 흥미로운 사실을 알 수 있는데, 연마 전과 후에도 양품과 불량품의 외관품질에 대해 공통적으로 기여도가 높은 부화상들이 존재한다는 사실이다. 양품의 경우 B channel의 $d_{(1)}^d$, 불량품의 경우 R channel의 $d_{(1)}^d$ 부화상이 바로 그것인데, 이러한 공통되

는 기여도 높은 부화상이 존재하기 때문에 연마 후와 마찬가지로 연마 전 인조대리석의 자동분류도 가능했다고 판단된다. 연마 후 인조대리석의 외관품질에 기여하는 웨이블릿 부화상의 개수가 많은 이유는 연마하는 과정에서 연마 전에는 볼 수 없었던 외관특징들이 나타나기 때문이며, 이런 많은 외관특징들로 인해 연마 후 인조대리석의 (숙련된 판별가에 의한) 자동분류가 연마 전 인조대리석보다 용이하지 않았나 판단된다.

4. 맺음말

본 논문에서는 화상분석에 기반한 소프트 센서를 이용하여 확률론적인 색상-질감 외관 특성을 가진 인조대리석 제품의 품질 자동분류에 적용하였다. 색상-질감 특성을 가진 외관의 특징을 추출하기 위해 MR-MIA가 사용되었으며 잠재변수법의 하나인 FDA가 자동분류를 위해 사용되었다. MR-MIA 특징벡터 분석을 통해 인조대리석의 색상-질감 특성을 상세하게 분석할 수 있었고, FDA를 이용한 자동분류 결과 연마 후 인조대리석의 양불 자동판정뿐 아니라 경제적인 이점이 있는 연마 전 인조대리석의 자동 양불판정까지도 가능함을 보였다.

참고문헌

- Holtham, P. N. and Nguyen, K. K., "On-line Analysis of Froth Surface in Coal and Mineral Flotation Using JKFrothCam," *Int. J. Miner. Process.*, **64**, 163-180(2002).
- Kaartinen, J., Höttönen, J., Hyötyäniemi, H. and Miettunen, J., "Machine-vision-based Control of Zinc Flotation-A Case Study," *Control Eng. Practice*, **14**, 1455-1466(2006).
- Liu, J., "Soft Sensor Design Using Image Analysis and Its Industrial Applications Part 1. Estimation and Monitoring of Product Appearance," *Korean Chem. Eng. Res.*, **48**(4), 475-782(2010).
- Kim, D., Han, C. and Liu, J. J., "Optimal Wavelet Packets for Characterizing Surface Quality," *Ind. Eng. Chem. Res.*, **48**(5), 2590-2597(2009).
- Liu, J. J. and MacGregor, J. F., "Modeling and Optimization of Product Appearance: Application to Injection-molded Plastic Panels," *Ind. Eng. Chem. Res.*, **44**, 4687-4696(2005).
- Liu, J. J. and MacGregor, J. F., "On the Extraction of Spectral and Spatial Information from Images," *Chemometrics Intell. Lab. Syst.*, **85**(1), 119-130(2007).
- Fisher, R. A., "The Use of Multiple Measurements in Taxonomic Problems," *Annals of Eugenics*, **7**(II), 179-188(1936).
- Geladi, P. and Grahn, H. *Multivariate Image Analysis*, John Wiley & Sons, Chichester, UK(1996).
- Mallat, S. G., "A Theory for Multiresolution Signal Decomposition: The Wavelet Representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **11**, 674-693(1989).
- Bharati, M., MacGregor, J. F. and Champagne, M., "Using Near-infrared Multivariate Image Regression Techniques to Predict Pulp Properties," *TAPPI J.*, **3**, 8-14(2004).
- Yu, H. and MacGregor, J. F., "Monitoring Flames in an Industrial Boiler Using Multivariate Image Analysis," *AIChE J.*, **50**(7), 1474-148(2004).
- Pereira, A. C., Reis, M. S. and Saraiva, P. M., "Quality Control of Food Products using Image Analysis and Multivariate Statistical Tools," *Ind. Eng. Chem. Res.*, **48**(2), 988-998(2009).
- Bharati, M., Liu, J. J. and MacGregor, J. F., "Image Texture Analysis: Methods and Comparisons," *Chemometrics and Intelligent Laboratory Systems*, **72**(1), 57-71(2004).
- Geladi, P., "Some Special Topics in Multivariate Image Analysis," *Chemometrics and Intelligent Laboratory Systems*, **14**, 209-220(1992).
- Lied, T. T., Geladi, P. and Esbensen, K., "Multivariate Image Regression (MIR): Implementation of Image PLSR-first Forays," *J. Chemometrics*, **14**, 585-598(2000).
- Vetterli, M. and Kovacevic, J., *Wavelets and Subband Coding*, Prentice Hall, Englewood Cliffs(1995).
- Duda, R. O., Hart, P. E. and Stork, D. G., *Pattern Classification*, 2nd ed., Wiley-Interscience, New York(2001).
- Demirkol, A., Demir, Z. and Emre, E. A., "New Classification Approach using Discriminant Functions," *Journal of Information Science and Engineering*, **21**, 819-828(2005).
- Van de Wouwer, G. *Wavelets for Multiscale Texture Analysis*, Ph.D Thesis, University of Antwerp, Antwerp, Belgium(1998).

Appendix

본 연구에 사용된 29개의 인조대리석 화상변호와 해당하는 외관 품질에 대한 숙련자의 판단을 Table A1에 나타내었다.

Table A1. List of 29 images and corresponding experts' evaluations

Image Number	Evaluation	Image Number	Evaluation
01-S-Q	Questionable	-	-
02-S-Q	Questionable	-	-
03-S-Q	Questionable	03-U-Q	Questionable
04-S-Q	Questionable	04-U-Q	Questionable
05-S-G	Good	05-U-G	Good
06-S-G	Good	06-U-G	Good
07-S-G	Good	07-U-G	Good
08-S-G	Good	08-U-G	Good
09-S-Q	Questionable	-	-
10-S-G	Good	10-U-G	Good
11-S-G	Good	11-U-G	Good
12-S-G	Good	12-U-G	Good
13-S-Q	Questionable	13-U-Q	Questionable
14-S-G	Good	14-U-G	Good
15-S-G	Good	-	-
16-S-G	Good	16-U-G	Good
17-S-G	Questionable	-	-