디지털산업정보학회 논문지 제16권 제1호-2020년 3월
http://dx.doi.org/10.17662/ksdim.2020.16.1.055

이미지 보간을 위한 의사결정나무 분류 기법의 적용 및 구현*

김 동 형**

Adopting and Implementation of Decision Tree Classification Method for Image Interpolation

Kim, Donghyung

〈Abstract〉

With the development of display hardware, image interpolation techniques have been used in various fields such as image zooming and medical imaging. Traditional image interpolation methods, such as bi-linear interpolation, bi-cubic interpolation and edge direction-based interpolation, perform interpolation in the spatial domain. Recently, interpolation techniques in the discrete cosine transform or wavelet domain are also proposed. Using these various existing interpolation methods and machine learning, we propose decision tree classification-based image interpolation methods. In other words, this paper is about the method of adaptively applying various existing interpolation methods, not the interpolation method itself. To obtain the decision model, we used Weka's J48 library with the C4.5 decision tree algorithm. The proposed method first constructs attribute set and select classes that means interpolation methods for classification model. And after training, interpolation is performed using different interpolation methods according to attributes characteristics. Simulation results show that the proposed method yields reasonable performance.

Key Words : Image Interpolation, Machine Learning, Decision Tree, J48 Algorithm, Attribute Set, Nearest Neighbor Interpolation, Bi-Linear Interpolation, Edge Direction-based Interpolation

Ⅰ. 서론

이미지 보간(interpolation) 기법은 단순히 저해상도 이미지를 고해상도 이미지로 변환하는 것은 물론 특정 부분의 확대(zooming), CT(computed tomography), MRI(magnetic resonance imaging) 등의 의료영상 스캔 등에도 광범위하게 사용되는 영상처리 기술이다.

전통적인 이미지 보간 기법에는 대표적으로 최근접

* 본 논문은 2019년도 1학기 한양여자대학교 교내연구비에 의하여 연구됨
** 한양여자대학교 컴퓨터정보과 부교수

화소보간법(NNI, nearest neighbor interpolation), 양선형보간법(BLI, bi-linear interpolation), 양입방보간법(BCI, bi-cubic interpolation)등을 들 수 있다. 이들 방법은 공간영역(spatial domain)에서 주변화소 값과 보간 커널(interpolation kernel)과의 컨볼루션(convolution)을 통해 보간 위치의 값을 예측한다[1, 2].

최근에는 공간영역이 아닌 웨이블릿 영역[3-5]과 DCT(discrete cosine transform) 영역[6, 7]에서의 이미지보간 방법들도 다양하게 연구되고 있다.

본 논문에서는 머신러닝을 적용하여 이미지보간 과정에 다양한 보간법을 적용하는 방법을 제안한다. 해당 보간 화소 위치에서 어떤 보간기법을 사용할 것인가의 결정에는 의사결정나무(decision tree) 분류법을 사용하였으며, 의사결정나무 분류법은 데이터 집합을 분석하여 데이터들 사이에 존재하는 패턴을 예측 가능한 규칙들의 조합으로 나타내는 방식을 말한다[8-10].

제안하는 알고리즘은 먼저 정의할 속성집합(attribute set)을 구성하고 속성집합과 클래스(적용되는 이미지보간법)의 쌍을 이루는 데이터 집합을 생성한다. 이후 생성된 데이터의 66%를 학습에 사용하고 나머지 34%를 검증과정에 사용함으로써 의사결정나무 분류 알고리즘의 모델을 추정한다. 마지막으로 생성된 모델을 이용하여 보간 위치의 속성들에 대한 통계적 특성에 따라 서로 다른 방법을 적용하여 이미지 보간을 수행한다. 즉, 본 논문에서 제안한 알고리즘은 이미지보간 방법 자체에 대한 제안이 아닌 학습한 분류모델에 따라 기존 다수의 이미지 보간 방법을 적응적으로 적용할 수 있는 방법에 대한 것이다.

논문의 구성은 2장에서 전통적인 이미지 보간 기법들 중 의사결정나무분류 모델 생성과정에 사용한 최근접화소보간법, 양선형보간법, 에지방향기반보간법과 함께 양입방보간법과 의사결정나무 분류법에 대한 기반 기술을 기술한다. 3장에서는 제안하는 알고리즘을 3단계로 나누어 기술하며 4장에서는 다양한 크기의 이미지에 대한 정량적, 정성적 결과 분석을 기술하고 마지막 절에서 결론을 맺는다.

Ⅱ. 관련 이론

이미지 보간을 위해 사용되는 대표적은 방식은 고정된 보간예측함수(IPF, interpolation prediction function)를 적용하여 보간을 수행하는 고정 예측보간방법과 보간 대상 화소 주변의 에지의 크기 및 방향성 등에 따라 서로 다른 보간예측함수를 적용하는 가변 예측보간방법으로 나뉠 수 있다.

고정 예측보간방법은 사용하는 보간예측함수의 차원에 따라 대표적으로 최근접화소보간법, 양선형보간법, 양입방보간법으로 나뉘고 각각 0차, 1차, 3차원의 보간예측함수를 사용하여 보간을 수행한다. 반면 가변 예측보간방법은 에지의 크기와 방향을 예측하는 방법, 사용하는 윈도우의 크기 등에 따라 다양한 방법이 존재하는데 이들의 공통적인 특징은 주변 화소들의 통계적 특성에 따라 서로 다른 참조화소의 값을 이용하여 보간을 수행한다는 점이다.

2.1 고정 예측함수를 활용한 보간방법

본 논문에서 2차원 이미지 보간을 위해 적용한 모든 방법은 <그림 1>에서 표현된 바와 같이 가로방향의 각 행별로 1차원 보간을 수행한 뒤 다시 세로방향으로 1차원 보간을 수행함으로써 최종적으로 2차원 이미지에 대한 보간을 수행하였다.

2.1.1 최근접화소보간법(NNI)

최근접화소보간법은 보간을 수행하고자 하는 위치

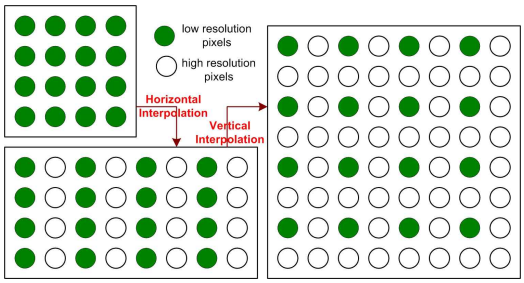

<그림 1> 가로방향으로의 1차원 보간 및 세로방향으로의 1차원 보간을 통한 2차원 보간

에서 가장 가까운 저해상도(low resolution) 화소값으로 보간위치의 화소값을 예측하는 방법을 말하며 이때 사용되는 보간예측함수 $PF_{NNI}(x)$는 식(1)과 같다.

$$PF_{NNI}(x) = \underset{P_{pos}}{argmin}(distance(x - pos))$$
$$\text{여기서, } pos = 0, 1, 2, \ldots, N-1 \quad (1)$$

식 (1)에서 $distance(\cdot)$는 두 위치값 사이의 절대적 거리를 말하며 거리가 최소인 위치의 화소값인 P_{pos}로 최근접화소보간법 예측값($PF_{NNI}(x)$)을 선정한다. 이때 동일한 거리를 가지는 경우 왼쪽 위치의 화소값을 선택한다.

$PF_{NNI}(x)$를 이용하여 <그림 2>의 $I_{0.5}$에서의 화소 값은 다음 식과 같이 계산될 수 있다.

$$I_{0.5} = PF_{NNII}(0.5) = P_0 \quad (2)$$

이후 이상의 방법을 세로 방향으로 확장하여 2차원 이미지를 보간한다.

2.1.2 양선형보간법(BLI)

양선형보간법 역시 1차원 선형보간법(linear)을 가로방향과 세로방향으로 연속하여 적용한 방법이다. 1차원 선형보간방법은 예측보간함수를 1차 함수로 정

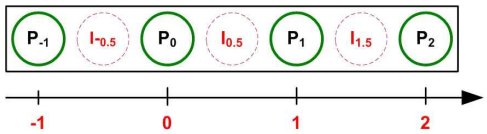

<그림 2> 보간 예측함수(PF, prediction function) 산정을 위한 화소 좌표 (P_i : 저해상도 화소값, I_j : 보간위치의 화소값)

의한 것으로 인접한 좌우 두 화소 값의 크기를 연결한 직선상의 값으로 두 화소 사이의 임의의 위치에서의 화소값을 예측하는 것이다. 식 (3)은 이를 나타낸다.

$$PF_{BLI}(x) = ax + b$$
$$\text{여기서, } a = P_1 - P_0,\ b = P_0 \quad (3)$$

$PF_{BLI}(x)$를 이용하여 <그림 2>의 $I_{0.5}$에서의 화소 값은 다음 식 (4)와 같이 계산될 수 있다.

$$I_{0.5} = PF_{BLI}(0.5) = (P_0 + P_1) \times 0.5 \quad (4)$$

이상의 방법을 세로 방향으로 확장하여 2차원 이미지를 보간한 것이 양선형방법이다.

2.1.3 양입방보간법 (BCI)

앞서 기술한 양선형보간법 방법이 인접한 두 화소를 잇는 1차원 직선상의 값으로 예측을 수행하는 반면 양입방보간법은 인접한 4개의 화소값을 잇는 3차원 곡선상의 값으로 예측을 수행하며 식 (5)는 이러한 양입방보간법의 보간예측함수를 나타낸다.

$$PF_{BCI}(x) = ax^3 + bx^2 + cx + d$$
$$\text{여기서, } a = -0.5P_{-1} + 1.5P_0 - 1.5P_1 + 0.5P_2$$
$$b = P_{-1} - 2.5P_0 + 2P_1 - 0.5P_2$$
$$c = -0.5P_{-1} + 0.5P_1$$
$$d = P_0 \quad (5)$$

역시 $PF_{BCI}(x)$를 이용하여 <그림 2>의 $I_{0.5}$에서의 화소 값은 다음 식과 같이 계산될 수 있다.

$$I_{0.5} = PF_{BCI}(0.5) = a \times 0.5^3 + b \times 0.5^3 + c \times 0.5 + d$$
$$\text{여기서, } a \sim d \text{ are equal to eq.(5)} \quad (6)$$

이상의 방법을 세로 방향으로 확장하여 2차원 이미지를 보간한 것이 양입방보간법이다.

2.2 가변 예측함수를 활용한 보간방법

2.2.1 에지방향기반보간법(EDI)

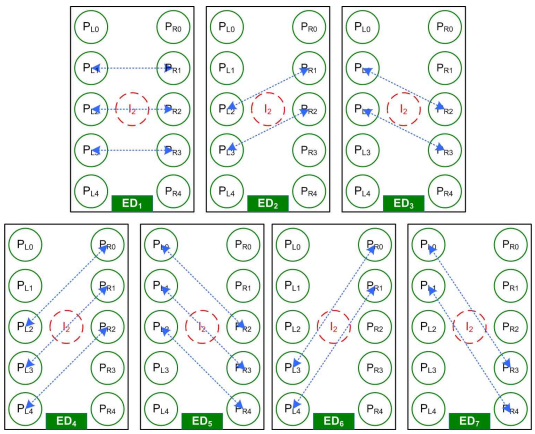

<그림 3> 에지방향기반보간기법에서 사용되는 방향별 주변 화소 위치

가변 예측함수를 활용한 보간방법은 보간하고자 하는 화소의 위치값에 따라 서로 다른 보간예측함수를 적용하는 방법으로 대표적으로 에지의 크기 및 방향에 따라 가변적으로 예측하는 에지방향기반보간(EDI, edge direction-based Interpolation) 기법을 들 수 있다.

가로방향으로의 보간 수행과정에서 <그림 3>과 같이 I_2 주변 10개의 화소값을 방향 예측에 사용하는데 식 (7)을 이용하여 7개의 서로 다른 방향 중 최적의 방향(ED_{best})를 도출한다.

$$ED_{best} = \underset{ED_k}{argmin}\left(\sum_{i,j} |ED_k(P_{Li}) - ED_k(P_{Rj})|\right) \quad (7)$$

여기서 $ED_k(P_{Li})$과 $ED_k(P_{Rj})$은 각각 <그림 3>에 포함된 ED_1~ED_7에서 사용된 좌측과 우측의 화소 값을 의미한다. 예를 들어 ED_1의 경우 P_{Li}와 P_{Rj}는 각각 P_{L1}, P_{L2}, P_{L3}와 P_{R1}, P_{R2}, P_{R3}의 값을 가진다. 즉, $|(P_{L1}-P_{R1})| + |(P_{L2}-P_{R2})| + |(P_{L3}-P_{R3})|$의 값이 ED_1 방향에서의 크기를 나타내며 나머지 ED_2~ED_7까지의 크기를 포함하여 가장 작은 크기의 ED_k의 값을 ED_{best}로 산정한다.

이제 식(7)을 통해 구한 ED_{best}에 따라 $PF_{EDI}(0.5)$ 위치에서 구한 <그림 3>의 I_2값은 식(8)과 같다.

이렇게 가로 방향으로의 보간을 수행한 후 같은 방법으로 세로방향으로 적용함으로써 에지방향기반 보간기법을 수행할 수 있다.

2.3 의사결정나무 (Decision Tree)

머신러닝 분야에서 의사결정나무는 데이터 집합을 분석하여 데이터들 사이에 존재하는 패턴을 예측 가능한 규칙들의 조합으로 나타내는 방식으로 루트노

$$PF_{EDI}(0.5) = I_2 = \begin{cases} 0.5P_{L2} + 0.5P_{R2} & , ED_{best} = ED_1 \\ 0.25P_{L2} + 0.25P_{L3} + 0.25P_{R1} + 0.25P_{R2} & , ED_{best} = ED_2 \\ 0.25P_{L1} + 0.25P_{L2} + 0.25P_{R2} + 0.25P_{R3} & , ED_{best} = ED_3 \\ 0.5P_{L3} + 0.5P_{R1} & , ED_{best} = ED_4 \\ 0.5P_{L1} + 0.5P_{R3} & , ED_{best} = ED_5 \\ 0.25P_{L3} + 0.25P_{L4} + 0.25P_{R0} + 0.25P_{R1} & , ED_{best} = ED_6 \\ 0.25P_{L0} + 0.25P_{L1} + 0.25P_{R3} + 0.25P_{R4} & , ED_{best} = ED_7 \end{cases} \quad (8)$$

드(root node)에서 말단노드(terminal node)까지의 모양이 나무를 뒤집어 놓은 모양을 가진다[8-9].

본 논문에서는 의사결정나무 분류 알고리즘을 적용을 위해 Weka 라이브러리를 사용하였으며 해당 라이브러리에서 의사결정나무 분류 알고리즘은 J48이라 불린다. J48 분류 알고리즘은 D3 알고리즘을 개선한 분류 기법으로서 ID3와 비교하여 수치형 속성 처리 및 결측치(missing attributes values) 처리, 결정 트리의 깊이 문제 및 속성들을 서로 다른 가중치를 반영하여 사용할 수 있는 등의 기능이 개선된 알고리즘이다. 이중 가장 큰 차이점은 ID3가 모든 속성이 명목형(nominal)인 경우만 처리가 가능한 것과는 달리 J48 분류 알고리즘은 수치형 속성의 처리가 가능하여 실세계의 다양한 분야에 적용이 가능하다는 장점이 있다. 이는 분류(classification)와 회귀(regression)가 모두 가능함을 의미한다. 기본적으로 ID3와 같이 엔트로피 기반으로 분류 기준을 결정하며 단계적으로 엔트로피를 낮추는 방향으로 분류를 수행한다. 즉 분류이후 말단노드(terminal node)간의 상관도를 최소화하는 방향으로 분류가 수행된다. 식 (9)는 분류기준인 정보이득(information gain)을 산정하는데 사용되는 엔트로피의 계산 수식을 나타낸다. 엔트로피는 개념적으로 데이터의 혼잡도를 의미하며 여러 개의 클래스 데이터가 혼재되어 있는 루트노드에서 데이터의 혼잡도가 가장 높고 말단 노드로 갈수로 엔트로피는 적어진다. 이상적인 경우 최종 말단노드에서 하나의 클래스 데이터 집합만 존재하며 이 경우 엔트로피는 0의 값을 가진다[10].

$$Entopy(S) = -\sum_{i=1}^{m} P_i \log_2(P_i)$$

$$\text{여기서, } P_i = freq(C_i, S)/|S| \qquad (9)$$

여기에서 S는 주어진 데이터 집합에 모든 집합을 의미하며 $C=\{C_1, C_2, \ldots, C_k\}$는 클래스들의 집합 즉, 터미널 노드의 집합을 의미한다. $freq(C_i, S)$는 S 데이터 집합에 포함된 여러 개의 레코드 중에서 C_i 말단노드에 속하는 데이터의 개수를 나타내며 마지막으로 $|S|$는 주어진 전체 데이터의 개수를 말한다.

식 (9) 엔트로피를 이용하여 노드의 분기 기준이 되는 정보이득은 식 (10)과 같이 구할 수 있다.

$$Gain(T, X) = Entopy(T) - Entopy(T, X) \qquad (10)$$

여기서 $Entropy(T)$는 상위노드의 엔트로피를 의미하고 $Entropy(T, X)$는 상위노드를 속성 X로 분기하였을 때 생성된 하위노드들의 엔트로피의 가중평균을 의미한다. 여기서 가중치는 각 하위노드에 포함된 데이터의 비율이 사용된다.

III. 제안하는 알고리즘

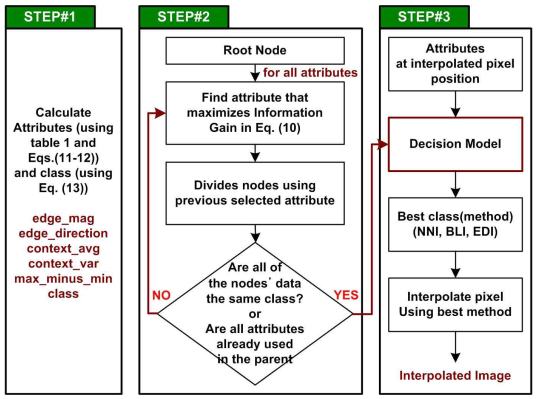

<그림 4> 제안하는 알고리즘의 블록다이어그램

제안하는 이미지 보간에 머신러닝의 의사결정나무 분류법을 적용하는 과정은 <그림 4>와 같이 크게 3단계로 분류할 수 있다. 분류를 위한 속성집합을 결정하고 각 속성집합의 값에 따라 결정된 클래스를 하나의 레코드로 연결한 학습데이터 집합을 구성하는 것이 첫 번째 단계이다. 두 번째는 학습데이터를 사용하여 의사결정나무 분류법을 통해 분류모델을 산

정하고 마지막 단계에서 산정된 분류모델을 이용하여 데이터의 클래스를 분류한다. 즉 STEP#1과 STEP#2는 의사결정나무 분류 모델을 만들기 위한 단계이며 STEP#3에서 생성된 모델을 활용하여 선택된 방법을 사용하여 보간을 수행한다.

3.1 속성집합과 클래스의 구성

다양한 이미지 보간기법을 가변적으로 사용하기 위해 제안하는 알고리즘에서 사용한 속성집합은 에지의 크기, 에지의 방향, 주변 화소값들의 평균, 주변 화소값들의 분산, 주변 화소값 중 최대값과 최소값의 차이값까지 5개의 속성을 사용하였다. 또한 클래스 즉, 말단노드 값으로는 제안하는 알고리즘의 복잡도를 고려하여 최근접화소보간법, 양선형보간법, 에지방향기반보간법을 적용하였다. <표 1>은 의사결정나무 분류에 사용하는 5가지의 속성과 말단노드인 세 개의 클래스를 나타낸다.

<표 1> 의사결정나무 분류모델 산정을 위한 학습데이터의 구성
(5개의 속성 및 클래스)

속성집합과 클래스	주요 내용
edge_mag	에지의 크기
edge_direction	에지의 방향
context_avg	주변화소값들의 평균
context_var	주변화소값들의 표준분산
max_minus_min	주변화소값의 최대 및 최소값
class	최근접화소보간기법(NNI) 양선형보간기법(BLI) 에지방향기반보간기법(EDI)

에지의 크기(edge_mag) 및 방향(edge_direction)에 관한 속성들은 에지의 특징이 강한 영역에서 에지방향기반보간 기법 분류 결정에 영향을 주며, 주변 화소값의 평균(context_avg) 및 분산(context_var), 그리고 최대화소값과 최소화소값의 차이값(max_minus_min)은 주로 최근접화소보간기법과 양선형보간법기법의 분류 결정에 영향을 미친다.

각 속성집합의 데이터값의 산출을 자세히 살펴보면 먼저 가로 방향 및 세로 방향으로의 보간과정에서 사용되는 주변화소의 값을 포함한 윈도우는 <그림 5>와 같다. 가로방향의 경우 윈도우의 크기는 3×4이며 세로방향의 경우 가로 방향에서 보간된 화소를 포함하여 2×7크기의 윈도우를 가진다. 먼저 에지의 크기 및 방향은 가로방향으로의 보간에는 식 (11)을, 세로방향의 보간에는 식(12)를 사용하여 산출한다. 식(11)에 포함된 *edge_x* 및 *edge_y*는 각각 가로방향의 윈도우인 *w_hor*(<그림 5>의 (a))와 $filter_x$(식 (11)의 $filter^1_x$ 및 $filter^2_x$) 및 $filter_y$(식(11)의 $filter^1_y$ 및 $filter^2_y$)와의 컨볼루션(convolution) 결과들의 합을 의미한다. 식(12)는 세로방향의 보간 과정에서 참조화소 위치가 달라짐에 따라 *w_ver*(<그림 5>의 (b)) 윈도우를 사용한다는 점과 다른 필터(식 (12)의 $filter_x$, $filter_y$)를 사용한다는 점을 제외하면 *edge_x*와 *edge_y* 값을 구하는

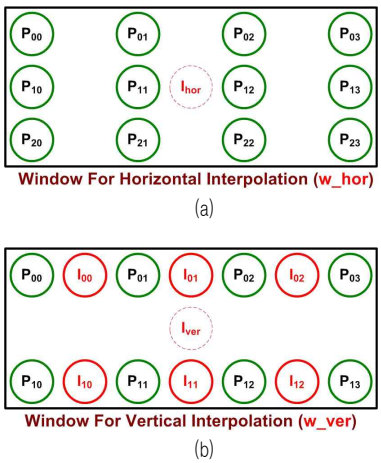

<그림 5> 속성집합을 산정하기 위해 사용되는 가로 방향 및 세로방향 보간과정에서의 윈도우 (w_hor, w_ver)

$$edge_mag = \sqrt{edge_x^2 + edge_y^2}\ ,\ \ edge_direction = tan^{-1}(edge_y/edge_x) \times 180/\pi$$

$$\text{여기서,}\ \ edge_x = \sum_{All}(\sum_{i=1}^{2}(w_hor * filter_x^i)) \quad edge_y = \sum_{All}(\sum_{i=1}^{2}(w_hor * filter_y^i))$$

$$filter_x^1 = \begin{bmatrix} -1 & 0 & 1 & 0 \\ -1 & 0 & 1 & 0 \\ -1 & 0 & 1 & 0 \end{bmatrix}/3, \qquad filter_x^2 = \begin{bmatrix} 0 & -1 & 0 & 1 \\ 0 & -1 & 0 & 1 \\ 0 & -1 & 0 & 1 \end{bmatrix}/3$$

$$filter_y^1 = \begin{bmatrix} -1 & -1 & -1 & 0 \\ 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 \end{bmatrix}/3, \qquad filter_y^2 = \begin{bmatrix} 0 & -1 & -1 & -1 \\ 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 1 \end{bmatrix}/3 \tag{11}$$

$$edge_mag = \sqrt{edge_x^2 + edge_y^2}\ ,\ \ edge_direction = tan^{-1}(edge_y/edge_x) \times 180/\pi$$

$$\text{여기서,}\ \ edge_x = \sum_{All}(\sum_{i=1}^{5}(w_ver * filter_x^i)) \quad edge_y = \sum_{All}(\sum_{i=1}^{1}(w_ver * filter_y^i))$$

$$filter_x^1 = \begin{bmatrix} -1 & 0 & 1 & 0 & 0 & 0 & 0 \\ -1 & 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix}/2, \quad filter_x^2 = \begin{bmatrix} 0 & -1 & 0 & 1 & 0 & 0 & 0 \\ 0 & -1 & 0 & 1 & 0 & 0 & 0 \end{bmatrix}/2$$

$$filter_x^3 = \begin{bmatrix} 0 & 0 & -1 & 0 & 1 & 0 & 0 \\ 0 & 0 & -1 & 0 & 1 & 0 & 0 \end{bmatrix}/2, \quad filter_x^4 = \begin{bmatrix} 0 & 0 & 0 & -1 & 0 & 1 & 0 \\ 0 & 0 & 0 & -1 & 0 & 1 & 0 \end{bmatrix}/2$$

$$filter_x^5 = \begin{bmatrix} 0 & 0 & 0 & 0 & -1 & 0 & 1 \\ 0 & 0 & 0 & 0 & -1 & 0 & 1 \end{bmatrix}/2, \quad filter_y^1 = \begin{bmatrix} -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix}/7 \tag{12}$$

방식은 식(11)과 동일하다. *edge_x*와 *edge_y*가 구해지면 이를 통해 에지의 크기 및 방향을 나타내는 *edge_mag*와 *edge_direction*을 구할 수 있다.

윈도우 내 화소값의 평균 및 분산을 나타내는 context_avg, context_var와 max_minus_min 값은 가로 방향과 세로 방향에서 사용되는 윈도우(w_hor, w_ver)의 평균과 분산 및 최대값과 최소값의 차이로 구한다.

마지막으로 의사결정나무의 터미널 노드를 의미하는 클래스는 식(13)에서 볼 수 있는 바와 같이 세 가지 보간 기법(최근접화소보간법(NNI), 양선형보간기법(BLI), 에지방향기반보간법(EDI))을 적용하여 예측한 값(P_{NNI}, P_{BLI}, P_{EDI})과 실제 값(*original*) 사이의 오차가 가장 적은 방법을 해당 속성집합에서의 클래스로 정한다.

$$class = \underset{method}{argmin}(|original - P_{method}|)$$

$$\text{여기서,}\ method = NNI, BLI, EDI \tag{13}$$

이상의 과정으로 속성집합이 구성되면 실제 이미지를 대상으로 학습데이터 집합을 생성하고 이를 활용하여 의사결정나무 분류 모델을 도출한다. 이후 도출된 모델을 사용하여 화소위치별 속성집합의 값에 따라 서로 다른 보간기법을 적용하여 보간을 수행한다.

IV. 실험 및 분석 결과

제안하는 의사결정나무 분류법을 적용한 이미지 보간을 위해 두 가지 다른 조건의 속성집합을 생성하였다. 첫 번째는 다양한 에지 특성을 가지는 6개의 서로 다른 영상(akiyo_cif, bus_cif, coastguard_cif, container_cif, foreman_cif, hall_monitor_cif)의 첫 번째 프레임을 이용하여 데이터 집합을 생성(생성데이터 수 49,762)하였으며 이 때 각 속성들의 통계적 특성은 다음 <표 2>와 같다.

두 번째 속성집합은 1920×1080 크기의 갖는 bigship_720p 영상의 첫 번째 프레임 하나만을 가지고 속성집합을 구성(생성데이터 수 77,319)하였으며

이들의 통계적 특성은 <표 3>과 같다.

<표 2> 속성집합 1 - 6개 영상의 첫 번째 프레임에 대한 속성의 통계적 특성

attributes	min	max	mean	stdDev
edge_mag	0	254.001	17.631	25.293
edge_direction	0	179.917	86.653	47.617
context_avg	14.583	254.667	123.255	53.404
context_var	0	118.292	12.922	15.206
max_minus_min	0	255	40.118	43.521

<표 3> 속성집합 2 - 1개 영상의 첫 번째 프레임에 대한 속성의 통계적 특성

attributes	min	max	mean	stdDev
edge_mag	0	137.494	12.431	14.931
edge_direction	0	179.857	86.134	46.174
context_avg	37.083	204.667	133.173	24.675
context_var	0.276	69.268	8.532	8.102
max_minus_min	1	178	27.359	24.041

<표 2>와 <표 3>의 속성에 대한 통계적 특성을 비교해보면 다양한 영상에 대한 에지 정보를 함께 포함하고 있는 속성집합 1의 값에 대한 편차(stdDev)가 상대적으로 큰 것을 알 수 있다.

생성된 속성집합을 활용하여 의사결정나무 분류모델을 도출하기 위해 Weka ToolKit을 사용하였으며 전체 데이터 중 66%를 학습에 사용하였고 나머지 34%를 검증에 사용하였다. <표 4>와 <표 5>는 각 속성집합에 대한 분류모델 결과를 나타낸다.

예측 가능한 것처럼 분류모델의 결과를 보면 6개의 영상을 사용하여 학습을 수행한 경우 속성 값의 편차가 커 분류의 정확도가 1개의 영상에 대해서 수행한 것 보다 낮게 나왔다. 하지만 실제 다양한 이미지에 대해 적용 시에는 다양한 에지의 형태를 학습한 첫 번째 속성집합이 유리할 것이다. 50%의 정확도가 낮게 보일 수 있으나 말단노드인 클래스의 개수가 3개임을 고려하면 평균 33.3%에서 약 150%의 정확도를 올린 수치라고도 볼 수 있다.

<표 4> 속성집합 1에 대한 분류모델 결과

Correctly Classified Instances	25286	50.8139 %
Kappa statistic	0.097	
Mean absolute error	0.4009	
Root mean squared error	0.4548	
Relative absolute error		96.2812 %
Root relative squared error		99.6114 %
Total Number of Instances	49762	

<표 5> 속성집합 2에 대한 분류모델 결과

Correctly Classified Instances	43476	56.2294 %
Kappa statistic	0.0093	
Mean absolute error	0.3882	
Root mean squared error	0.4419	
Relative absolute error		99.3978 %
Root relative squared error		100.0989 %
Total Number of Instances	77319	

제안하는 알고리즘은 Weka ToolKit으로 얻은 분류모델을 Weka 라이브러리를 사용하여 자바(Java)에서 구현하였으며, <표 6>은 최소근접화소보간법(NNI), 양선형보간법(BLI), 에지방향기반보간법(EDI), 그리고 제안한 방법의 식 (14)의 PSNR(peak signal-to-noise ratio)을 통해 산정한 객관적 화질을 비교하고 있다. 이 식에 포함된 m과 n은 영상의 가로 및 세로 화소수이며 I(i,j)와 Pmethod(i,j)는 각각 원본 영상과 NNI, BLI, 또는 EDI 방법으로 보간된 영상을 의미한다.

$$PSNR_{method} = 20\log_{10}\left(\frac{255}{\sqrt{MSE}}\right)$$

여기서,

$$MSE = \frac{1}{mn}\sum_{i=0}^{m-1}\sum_{j=0}^{n-1}(I(i,j) - P_{method}(i,j))^2 \qquad (14)$$

$$method = NNI, BLI, EDI$$

<표 6> 최소근접화소보간법(NNI), 양선형보간법(BLI), 에지방향기반보간법(EDI), 그리고 제안한 방법의 객관적 화질(PSNR)을 비교

attributes		NNI	BLI	EDI	Proposed	PROPOSED 선택빈도수		
						NNI	BLI	EDI
qcif	akiyo_qcif	27.74	31.80	31.79	31.86	225	11,943	5,427
	claire_qcif	28.08	33.10	33.52	33.25	682	7,111	9,802
	grandma_qcif	28.38	32.13	32.09	32.13	124	12,888	4,583
cif	bus_cif	22.63	26.72	25.64	26.55	833	67,377	4,969
	foreman_cif	28.49	32.92	34.15	33.50	410	59,127	13,642
	highway_cif	30.06	32.96	33.60	33.04	1,062	52,078	20,039
720p	city_corr_720p	26.55	30.63	29.59	30.51	4,072	639,312	38,843
	crew_720p	32.30	36.64	36.08	36.45	4,820	530,856	146,551
	shuttlestart_720p	37.48	40.83	40.28	40.80	2,023	292,154	388,050

결과를 살펴보면 가로 또는 세로방향 이외의 에지 성분이 거의 없는 영상의 경우 양선형보간법이 상대적으로 높은 객관적 화질을 보이며 반대로 대각선분의 에지가 다수 포함되어 있는 영상의 경우 에지방향기반보간법이 높은 객관적 화질을 보인다. 제안하는 알고리즘은 객관적 화질면에서는 양선형보간방법과 에지방향기반보간방법의 중간정도에 위치하며 에지의 방향성 여부와 관계없이 비교에 사용된 방법 중 2번째로 높은 값을 가지고 있다. 제안하는 알고리즘에서 선택된 방법들의 빈도수를 보면 영상의 크기가 클수록 인접 화소간의 상관도가 증가하여 양선형보간방법 또는 최근접화소보간방법이 극단적으로 많이 선택되며, 영상의 크기가 작을수록 그리고 대각방향의 에지성분을 많이 포함된 영상일수록 에지방향기반보간기법이 선택되는 빈도수가 증가됨을 볼 수 있다.

마지막으로 <그림 6>는 각 방법으로 생성된 주관적 화질을 비교하고 있다. 영상별 보간에 사용된 선택클래스의 빈도수가 양선형보간법에 치우쳐 제안하는 방법도 양선형보간법과 유사한 성능을 보이나 대각선 방향의 에지가 다수 존재하는 foreman_cif 영상의 경우 에지 부분에서 양선형보간법보다 우수한 성능을 보이며, 평탄영역에서는 에지방향기반보간법보다 주관적화질의 우위를 보인 것을 알 수 있다.

IV. 결론 및 향후연구

머신러닝의 의사결정나무 분류기법은 학습데이터들 사이에 존재하는 예측 가능한 규칙을 조합하여 말단노드의 엔트로피를 최소화하는 분류 기법이다. 제안하는 알고리즘은 이러한 의사결정나무 분류법을 이미지의 보간에 적용 및 구현하였다. 학습데이터의 사용된 클래스는 전통적인 이미지 보간기법인 최근접화소보간법, 양선형보간법, 에지방향기반보간법을 선택하여 사용하였지만 클래스의 확장 및 새로운 보간법을 클래스로 채용하는 것은 얼마든지 가능하다. 본 논문에서는 어떤 클래스를 조합하느냐의 문제가 아닌 다양한 클래스를 의사결정나무 분류법을 이용하여 다양하게 선택할 수 있음을 보이고자 하였다. 실험 결과 제안하는 알고리즘은 속성집합의 특징에 따라 서로 다른 빈도의 클래스(적용한 각각의 보간 알고리즘)를 선택하며 객관적 및 주관적 화질도 우수함을 보였다.

(a) 원본 (b) NNI (c) BLI (d) EDI (e) Proposed

<그림 6> 최소근접화소보간법(NNI), 양선형보간법(BLI), 에지방향기반보간법(EDI), 그리고 제안한 방법의 주관적 화질을 비교

향후 의사결정나무 분류 알고리즘의 성능을 좌우할 수 있는 속성집합의 통계적 특성에 관한 연구를 진행하여 그 적용 범위와 정확도를 확대하고자 한다.

참고문헌

[1] F. A. Jassim and F. H Altaany, "Image Interpolation Using Kriging Technique For Spatial Data," Canadian Journal on Image Processing and Computer Vision, Vol.4, No.2, 2013, pp. 16-21.

[2] R Roy., M Pal. and T Gulati, "Zooming Digital Images Using Interpolation Techniques," International Journal of Application or Innovation in Engineering & Management (IJAIEM), Vol.2, No.4, 2013, pp.34-45.

[3] H. Demirel, G. Anbarjafari, "Image Resolution

Enhancement By Using Discrete and Stationary Wavelet Decomposition," IEEE Transaction on Image Process, Vol.20, No.5, 2011, pp.1458-1460.

[4] R. S Asamwar. K. M. Bhurchandi and A. S Gandhi., "Interpolation of Images Using Discrete Wavelet Transform to Simulate Image Resizing as in Human Vision," International Journal of Automation and Computing, Vol.7, No.1, 2010, pp.9-16.

[5] Y. C. Fan and Y. F. Chiang, "Discrete Wavelet Transform on Color Picture Interpolation of Digital Still Camera," VLSI Design, Article ID 738057, 2013, pp.1-9.

[6] M. R Choi, S. J. Ko, and G. R. Kwon, "Color Image Interpolation in the DCT Domain Using a Wavelet-based Differential Value," Multimedia Tools and Applications, Vol.77, No.16, 2018, pp.21539-21556.

[7] S. R. Aswathy, C. Reshmalakshmi, "Enhanced DCT Interpolation for Better 2D Image Up-Sampling," International Journal of Engineering Research & Technology, Vol.4, No.6, 2015, pp.672-676.

[8] O. O. Adeyemo and T.O. Adeyeye, "Comparative Study of ID3/C4.5 Decision Tree and Multilayer Perceptron Algorithms for the Prediction of Typhoid Fever," IEEE African Journal of Computing & ICT, Vol.8, No.1, 2015, pp.103-112.

[9] Z. Xiang and L. Zhang, "Research on an Optimized C4.5 Algorithm based on Rough Set Theory," International Conference on Management of e-Commerce and e-Government, 2012, pp. 272-274.

[10] S. Babu, N.R. Ananthanarayanan, and V. Ramesh, "A Study on Efficiency of Decision Tree and Multi Layer Perceptron to Predict the Customer Churn in Telecommunication using WEKA," International Journal of Computer Applecations, Vol.140, No.4, 2016, pp.26-30.

[11] 정수목, "영상의 지역성을 이용한 보간 영상의 화질 개선 기법," 디지털산업정보학회 논문지, 제6권, 제4호, 2010.

■ 저자소개 ■

김 동 형
Kim, Donghyung

2011년 3월~현재 한양여자대학교 컴퓨터정보과 부교수
2008년 9월 한라대학교 정보통신방송공학부 조교수
2007년 9월 한국전자통신연구원(ETRI) 선임연구원 (공학박사)
2007년 8월 한양대학교 전자통신전파공학과 (공학박사)
2001년 2월 충북대학교 전자공학과(공학석사)
1999년 2월 충북대학교 전자공학과(공학사)

관심분야 : 영상처리, 멀티미디어통신, 영상압축
E-mail : kimdh@hywoman.ac.kr

논문접수일 : 2019년 12월 10일
수 정 일 : 2019년 12월 20일
게재확정일 : 2020년 1월 6일