

# 렌즈 사출성형 공정 상태 특징 추출 및 진단 알고리즘의 개발

## A Development of Feature Extraction and Condition Diagnosis Algorithm for Lens Injection Molding Process

백대성<sup>1</sup>, 남정수<sup>1</sup>, 이상원<sup>2,✉</sup>

Dae Seong Baek<sup>1</sup>, Jung Soo Nam<sup>1</sup>, and Sang Won Lee<sup>2,✉</sup>

<sup>1</sup> 성균관대학교 대학원 기계공학과 (Department of Mechanical Engineering, Graduate School, Sungkyunkwan University)

<sup>2</sup> 성균관대학교 기계공학부 (School of Mechanical Engineering, Sungkyunkwan University)

✉ Corresponding author: sangwonl@skku.edu, Tel: +82-31-290-7467

Manuscript received: 2014.1.20 / Revised: 2014.10.13 / Accepted: 2014.10.22

*In this paper, a new condition diagnosis algorithm for the lens injection molding process using various features extracted from cavity pressure, nozzle pressure and screw position signals is developed with the aid of probability neural network (PNN) method. A new feature extraction method is developed for identifying five (5), seven (7) and two (2) critical features from cavity pressure, nozzle pressure and screw position signals, respectively. The node energies extracted from cavity and nozzle pressure signals are also considered based on wavelet packet decomposition (WPD). The PNN method is introduced to build the condition diagnosis model by considering the extracted features and node energies. A series of the lens injection molding experiments are conducted to validate the model, and it is demonstrated that the proposed condition diagnosis model is useful with high diagnosis accuracy.*

Key Words: Lens Injection Molding Process (렌즈 사출성형 공정), Condition Diagnosis Algorithm (상태 진단 알고리즘), Feature Extraction (특징요소 추출), Node Energy (노드 에너지), Probabilistic Neural Network (확률신경망)

### 1. 서론

사출성형 공정은 단일 캐비티 금형이나 복수의 캐비티 금형을 장착하여 한 번의 공정으로 다수의 부품을 생산할 수 있다. 따라서 사출성형공정은 단일 공정만으로도 높은 생산성을 얻을 수 있어서 다양한 분야에서의 복잡한 형상을 갖는 정밀 부품을 대량 생산하는데 광범위하게 적용되고 있다.<sup>1</sup>

특히, 최근 사출성형기의 기능 및 사출성형 부품의 정밀도가 현저히 향상되고 있어 핸드폰 카메라

라용 렌즈와 같은 광학부품의 경우 대부분 플라스틱 재료를 이용한 사출성형 공정을 통하여 제조되고 있는 상황이다.<sup>2</sup> 이러한 광학부품의 경우 높은 치수정밀도가 요구되기 때문에 사출성형 공정 중 치수정밀도에 영향을 미치는 주요 인자의 도출 및 모니터링, 제어를 통한 품질 향상에 관한 연구가 진행되어 왔다.

특히, 플라스틱 렌즈의 사출성형에 있어서 가공 중 변형은 더욱 크게 발생하는데 이에 영향을 주는 인자가 많다. 즉, 게이트 및 러너의 크기와

위치, 공정변수 등 사출성형 조건 인자의 변화에 따라 제품 수축과 같은 외관 불량 발생하기 쉽고 사출성형 공정 중 받은 압력이나 냉각 이력이 성형이 완료된 후에도 제품 품질에 영향을 끼친다.<sup>3</sup>

상기 특성을 갖는 사출성형 공정에서의 불량을 개선함으로써 재료의 낭비를 줄이고 양질 부품의 생산을 통한 원가절감을 달성하기 위해 최근 사출성형 공정변수에 대한 모니터링 및 이를 기반으로 한 사출성형 부품의 품질 관리에 관한 연구가 진행되고 있다. Ribeiro는 플라스틱 사출성형 공정 데이터를 모니터링하고 Support Vector Machines (SVM) 방법론을 이용하여 사출성형 제품의 품질을 진단하는 연구를 수행하였다.<sup>4</sup> 또한, Zhu와 Chen은 재생 혼합 플라스틱을 사용한 사출성형 제품에서 발생하는 플래시를 예측하는 퍼지 신경망 이론 기반 알고리즘 개발을 수행하였다.<sup>5</sup> 즉, 사출 속도, 용융온도, 보압 등의 공정변수와 가속도계를 통해 측정된 진동신호를 기반으로 신경망 및 퍼지 추론 알고리즘, 그리고 다중 회귀 모델을 적용하여 상이한 공정 조건에서의 플래시 예측 시스템을 개발하였다. Zhang과 Alexander는 사출성형 공정 중 측정된 금형 캐비티 압력 신호에 패턴 인식을 적용한 공정 모니터링 및 진단에 관한 연구를 수행하였으며, Kuek은 금형 캐비티 압력 신호에서 추출된 최대압력값과 압력 프로파일 면적이 사출성형 품질평가 인자 중 하나인 무게와 밀접한 관련이 있음을 발견하고 사출성형 부품의 품질 모니터링 및 진단을 위한 캐비티 압력 신호의 유용성에 관하여 논의하였다.<sup>6,7</sup> 또한, 박형필 등은 압력 센서와 Potentiometer를 금형 및 사출성형기에 장착하여 캐비티 압력, 노즐 압력 및 사출 속도를 측정하고 이를 이용하여 사출성형 공정 모니터링 및 사출성형품 중량과의 상관관계 분석에 관한 연구를 수행하였다.<sup>8</sup>

전술한 바와 같이 사출성형 공정변수에 대한 모니터링 및 이를 활용한 사출성형 품질인자와의 상관 분석에 대한 다양한 연구가 진행되고 있으며 또한, 사출성형 품질에 직접적인 영향을 미치는 금형 캐비티 압력 등에 대한 모니터링과 사출성형 품질 인자 예측에 관한 연구가 진행되고 있으나 이러한 금형 캐비티 압력 등에 대한 상세한 분석을 통해 구체적인 사출공정 단계를 식별하고 진단하는 연구는 아직까지 활발하게 진행되고 있지 않다.

따라서, 본 논문에서는 휴대폰 카메라 모듈에 사용되는 렌즈를 제작하는 사출성형 공정에 있어

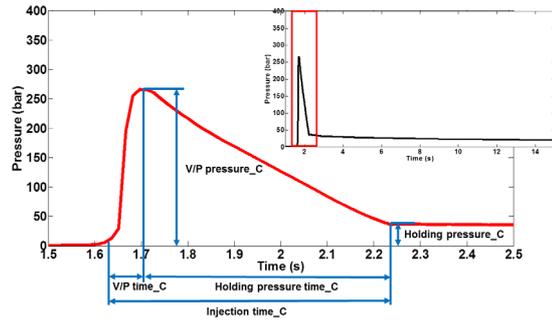


Fig. 1 Extraction of features from cavity pressure signal

서 금형 및 사출성형기에 장착된 압력센서를 통해 측정된 금형 캐비티 압력과 노즐 압력, 그리고 Potentiometer를 통해 측정된 스크류 위치를 이용하여 사출성형 공정상태를 진단하는 알고리즘을 개발하였고 이를 실험적으로 검증하였다. 즉, 주요 특징 요소를 상기한 측정 신호 프로파일로부터 추출하는 알고리즘을 개발하였고, 웨이블릿 변환 기법을 통해 추출된 노드에너지와 상기 개발된 알고리즘을 통해 추출된 특징 요소를 확률신경망 이론에 적용하여 구체적인 사출성형 공정상태를 진단하고 식별하였다.

## 2. 사출성형 공정상태 진단 방법

### 2.1 특징요소 추출 알고리즘

렌즈사출성형 실험에서 얻은 캐비티 및 노즐 압력, 스크류 위치 신호 프로파일로부터 추출되는 주요 특징요소는 렌즈 형상 오차, 렌즈 중심 두께, 복굴절 등 다양한 렌즈 품질에 영향을 미친다. 따라서 본 절에서는 상기한 렌즈 품질에 영향을 미치는 주요 특징요소를 추출하는 알고리즘 개발에 관하여 논의하고 있다. 이러한 특징요소의 추출을 통한 사출성형 공정상태의 진단은 공정변수를 변화시키기에 따라 각 공정 상태별로 각각 다른 형태의 압력 및 스크류 위치 신호 프로파일이 생성되기 때문에 가능하다.

특징요소 추출 알고리즘을 적용하여 Fig. 1, 2 및 3에 주어진 것처럼 캐비티 압력 신호로부터 5가지, 노즐 압력 신호로부터 7가지, 그리고 스크류 위치 신호로부터 2가지의 특징요소를 추출하였다.

캐비티 압력 신호에서는 Fig. 1에 주어진 것처럼 (1) 보압절환 압력(V/P pressure\_C), (2) 보압(Holding pressure\_C), (3) 보압절환 시간(V/P time\_C),

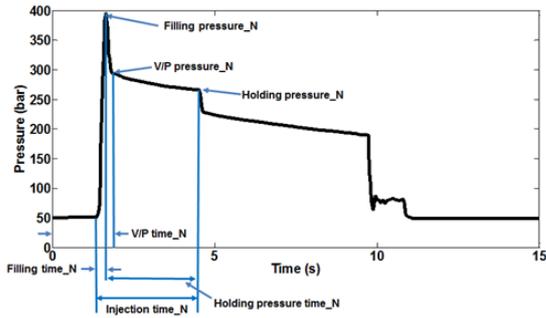


Fig. 2 Extraction of features from nozzle pressure signal

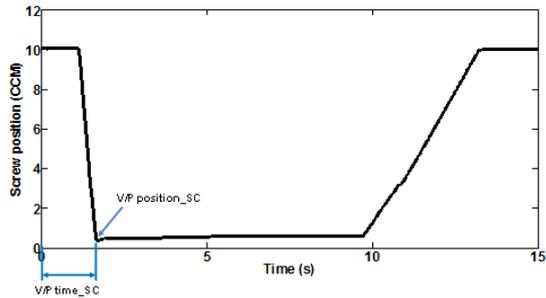


Fig. 3 Extraction of features from screw position signal

(4) 보압 시간(Holding pressure time\_C), (5) 사출시간(Injection time\_C)이 추출된다.

또한, 노즐 압력 신호에서는 Fig. 2에서 알 수 있듯이 (1) 충전 압력(Filling pressure\_N), (2) 보압절환 압력(V/P pressure\_N), (3) 보압(Holding pressure\_N), (4) 충전 시간(Filling time\_N), (5) 보압절환 시간(V/P time\_N), (6) 보압 시간(Holding pressure time\_N), (7) 사출 시간(Injection time\_N)의 총 7가지의 특징 요소가 추출된다.

스크류 위치 신호로부터는 (1) 보압절환 위치(V/P position\_SC), (2) 보압절환 시간(V/P time\_SC) 총 2가지의 특징요소가 추출되며 Fig. 3에 주어졌다.

### 2.2 웨이블릿 패킷 분해 방법

웨이블릿 패킷 분해 방법은 불규칙적인 신호를 분석하지 못하는 푸리에 변환을 보완하기 위해 개발되었다. 기존 신호 분석을 위해 많이 사용되었던 푸리에 변환은 시간 도메인의 신호 정보를 주파수 도메인의 신호로 전환하거나 또는 반대로 주파수 성분으로부터 원래의 시간 도메인의 신호를 복원하는데 적용이 가능하다. 하지만 분석하고자

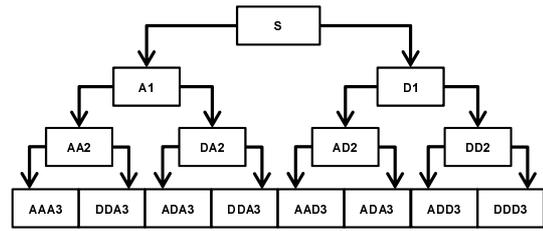


Fig. 4 Wavelet Packet Decomposition (WPD) tree

하는 신호가 멀티스케일 특성을 지니고 있을 경우, 푸리에 변환은 신호의 주파수 특성을 정확하게 분석하지 못한다. 이러한 푸리에 변환의 단점을 보완하고자 한 번의 연산으로 신호가 지닌 모든 스케일 성분을 분석할 수 있는 웨이블릿 패킷 분해 방법이 개발되었다.<sup>7</sup>

Fig. 4는 수평 및 수직 필터링에 기반한 웨이블릿 패킷 분해 방법을 도식적으로 보여주고 있다. Fig. 4에 주어졌듯이 초기 신호는 저주파 밴드(A) 및 고주파 밴드(D)의 2가지 주파수 밴드로 분해되고 이는 수평 및 수직 필터링을 통해 하위 밴드로 추가적으로 분해된다. 여기서 특정 주파수 밴드의 특성은 노드에너지로 표현될 수 있으며 식 (1)에 정의가 주어졌다.

$$e_n = \sum_k (c_{j,k}^n)^2 \tag{1}$$

여기서  $e_n$  은 노드에너지를 의미하고  $c_{j,k}^n$  은  $n$ 차 웨이블릿 패킷 계수를 의미한다. 노드에너지는 특정 주파수 밴드에 저장된 에너지를 의미하며 신호의 지배적인 주파수 성분을 추출하는데 사용된다.<sup>9</sup> 본 연구에서도 웨이블릿 패킷 분해 방법을 적용하여 캐비티 및 노즐 압력 신호의 노드에너지를 계산하고 이를 공정상태 진단에 이용하였다.

### 2.3 확률신경망 이론

확률신경망 이론은 주어진 개체가 어느 클래스에 속하는지를 판단하는 분류 방법론으로서 두 개 이상의 훈련 패턴에서 학습된 알고리즘으로 모델이 구축되며, 새로운 입력 신호에 대해 기존 클래스에 속한 신호들과의 거리행렬에 근거하여 그 신호가 해당 클래스에 속할 확률을 계산하고 분류한다.<sup>10</sup>

확률신경망 이론은 은닉층(Hidden layer)에서의 패턴 매핑을 통한 신경망의 구성 및 학습을 요구하지 않기 때문에 신경망 구조의 불확실성이 낮아

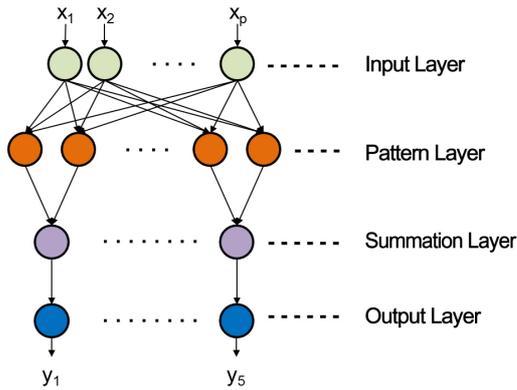


Fig. 5 Layers of Probabilistic Neural Network (PNN)

지고 또한 연산 시간을 상당히 감소시키게 된다. Fig. 5에 입력값이 특정한 클래스로 분류되는 도식도가 주어져 있다. Fig. 5에 주어져 있듯이 확률신경망은 입력층(Input layer), 학습층(Pattern layer), 합산층(Summation layer), 출력층(Output layer)의 총 4개의 층으로 구성된다. 입력층은 분산층의 한 종류로서 모든 훈련 유형에 동일한 입력 유형을 입력하고 이후 학습층에서는 각 입력 유형에 대한 가중치 벡터와 입력 유형간의 내적을 구한 후 이를 비선형 활성화 함수에 입력하여 비선형 연산을 수행한다. 또한 합산층에서는 학습층에서 계산한 비선형 출력 결과를 합산하고 최종적으로 출력층에서는 입력 유형이 특정 훈련 유형에의 해당 여부를 0과 1로 구성된 2진수로 출력한다.<sup>11</sup>

3. 렌즈사출성형 실험

3.1 렌즈사출성형 실험 설계

렌즈사출성형 실험은 Fig. 6에 주어진 것처럼 Arburg사의 25 Ton 유압식 사출성형기를 사용하였고, 사출성형 재료는 실제 산업현장에서 카메라 렌즈를 생산하기 위해 사용하는 Zeon Chemicals사의 Zeonex E48R을 사용하였다. 렌즈 사출성형 실험에 있어서 품질에 가장 큰영향을 미치는 보압절환점과 사출속도를 변동 공정변수로 고려하여 총 5개의 실험조건을 설계하였다.<sup>8,12</sup> 또한, 고정 공정변수는 노즐 온도, 냉각수 온도, 보압, 보압시간, 1 사이클 당 가공시간이며 각각의 구체적인 설정조건은 Table 1에 주어져 있다.

Table 2에 보압절환점과 사출속도를 변동 공정변수로 고려하여 설계된 총 5개의 실험조건이 구



Fig. 6 Photo of injection molding machine (Arburg)

Table 1 Conditions for Lens Injection Molding Experiment

Material	Zeonex E48R	
Injection molding machine	Company	Arburg
	Max. Capacity	25 Ton
Fixed variables	Nozzle temperature : 260 °C Coolant temperature : 150 °C Holding pressure : 300 bar Holding time : 3 s Cycle time : 15 s Sampling frequency : 67Hz	

Table 2 Design of Injection Molding Experiments

Run	Switch-over (ccm)	Injection velocity (ccm/s)	Condition
Ex.1	2.5	20	Standard
Ex.2	3	20	Premature switch-over
Ex.3	2	20	Late switch-over
Ex.4	2.5	30	High injection velocity
Ex.5	2.5	10	Low injection velocity

체적으로 주어져 있다. Table 2에 주어져 있듯이 Ex. 1을 기준으로 2가지 공정변수를 모두 3수준으로 조절하였다. 즉, 보압절환점은 2.5 ccm을 기준으로 이른 보압절환점의 경우는 3 ccm으로 설정하였고, 늦은 보압절환점의 경우는 2 ccm으로 설정하였다. 또한, 사출속도는 20 ccm/s을 기준으로 빠른 사출속도의 경우 30 ccm/s, 느린 사출속도의 경우 10 ccm/s로 설정하였다. 이러한 실험조건들의 설정은 실제 산업현장에서 사용하는 수치값을 참고하여 수행되었다. 각각의 조건 별로 90샷의 사출성형실험이 수행되었고 Fig. 7에 사출성형 공정으로 제작된 렌즈의 사진이 주어져 있다.

Table 2에 주어진 각 실험에서 캐비티 압력 및 노즐 압력은 각각 금형에 장착한 압력센서와 노즐

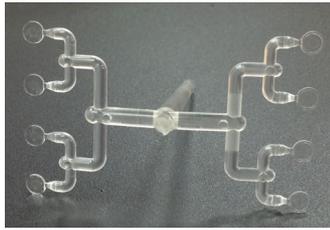


Fig. 7 Sample photo of lens fabricated with 8-cavity mold in the injection molding experiments

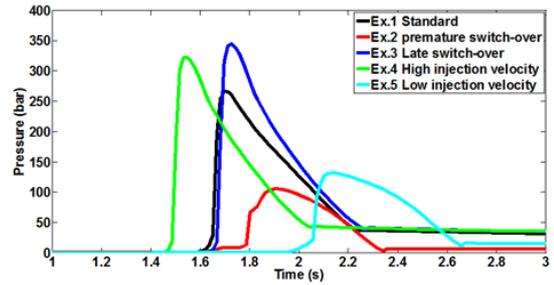
에 위치한 압력센서를 이용하여 측정하였고 스크류 위치는 사출성형기에 설치된 Potentiometer 변위 센서를 이용하여 측정하였다.

**3.2 렌즈사출성형 실험결과**

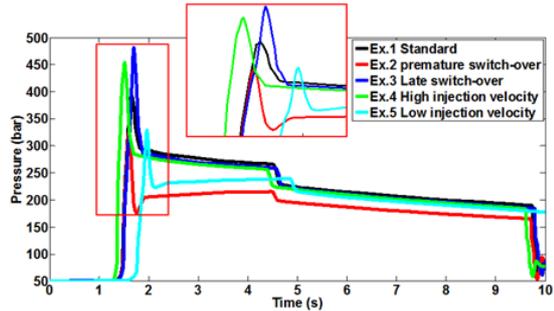
렌즈 사출성형 공정 중에 발생한 캐비티 압력, 노즐 압력 및 스크류 위치 신호는 주요 공정 변수 변화에 따른 공정 상태를 파악할 수 있고, 생산될 제품 품질 예측을 가능하게 하는 중요한 척도이다. 따라서, 보압절환점과 사출속도가 변화하는 각각의 실험에서 측정된 캐비티 및 노즐 압력 그리고, 스크류 위치 신호에 대한 분석이 필요하였고 Fig. 8에 각 실험에서 측정된 캐비티 압력, 노즐 압력 및 스크류 위치 신호의 대표적인 프로파일이 주어 져 있다.

Fig. 8(a)에 주어진 측정된 캐비티 압력 프로파일에서 알 수 있듯이 이른 보압절환인 Ex. 2의 경우 사출속도에 의한 스크류 전진으로 수지가 캐비티를 모두 채우기 전에 보압으로 수지가 전진하여 캐비티를 채우기 때문에 캐비티 압력이 상승하는 시점이 상대적으로 느리다. 또한, 캐비티 압력 신호가 상승하다가 잠시 주춤하면서 압력이 떨어진 후 다시 상승하는 완만한 형태의 압력 프로파일을 나타내며 이 때 최대압력은 5가지의 실험 중 가장 낮은 것을 확인 할 수 있다. 늦은 보압절환의 Ex. 3의 경우는 Ex. 2의 경우와 반대로 캐비티가 차 있는 상태에서 계속해서 사출속도에 의한 스크류 전진으로 수지를 캐비티에 채우기 때문에 압력이 급격하게 상승하였다가 보압절환이 되고 나서 압력이 떨어진다. 이 때 최대 캐비티 압력은 5가지의 실험 중 가장 크다.

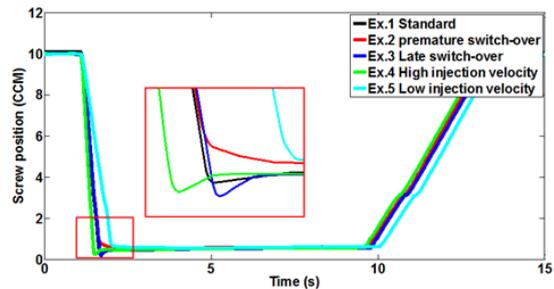
Ex. 4의 경우, 빠른 사출속도로 인해 수지가 캐비티에 빨리 채워져 기준인 Ex. 1의 경우보다 일찍 압력이 상승하고 최대 압력 크기 및 형태는 늦은 보압절환의 경우인 Ex.3의 프로파일과 유사하다.



(a) Cavity pressure



(b) Nozzle pressure



(c) Screw position for each experimental case

Fig. 8 Representative profiles of measured

Ex. 5의 경우는 느린 사출속도로 인해 수지가 캐비티에 늦게 채워져 압력 상승이 가장 늦으며 전반적으로 프로파일의 형태는 이른 보압절환의 경우인 Ex.2와 유사하다.

Fig. 8(b)에서 알 수 있듯이 노즐 압력의 경우 구체적인 프로파일의 형태는 캐비티 압력과 상이하나 각 실험에 따른 거동은 유사하게 나타난다. 즉, 이른 보압절환인 Ex. 2의 경우 최대 노즐 압력이 기준인 Ex. 1의 경우와 비교하여 상대적으로 낮으며 늦은 보압절환인 Ex. 3의 경우는 최대 노즐 압력이 가장 크다. 또한, 빠른 사출속도의 Ex. 4 경우에는 노즐 압력이 증가하는 시점이 가장 빠르고 압력의 최대값은 Ex. 3 경우에 이어 두 번째로 크

다. 늦은 사출속도의 Ex. 5 경우 노즐 압력의 상승은 가장 늦게 나타나며 압력의 최대값은 이른 보압절환인 Ex. 2의 경우와 유사하다.

스크류 위치 신호가 주어진 Fig. 8(c)를 고찰하면 이른 보압절환인 Ex. 2의 경우 스크류 이동에 의해 수지가 캐비티를 모두 채우기 전에 보압절환이 되어 압력이 수지를 전진시키기 때문에 상대적으로 스크류가 덜 이동하게 되고 이후 천천히 정상상태로 수렴한다. 반면에 늦은 보압절환인 Ex. 3의 경우는 캐비티에 수지가 모두 채워졌음에도 불구하고 스크류 이동이 지속되므로 스크류가 Ex. 1의 경우보다 좀 더 전진하게 되고 이후에 정상상태로 수렴한다. Ex. 4의 경우는 빠른 사출속도로 인해 스크류가 가장 빨리 이동하고 늦은 보압절환인 Ex. 3의 경우와 마찬가지로 스크류가 추가적인 전진을 하게 된다. 마지막으로 Ex. 5의 경우는 느린 사출속도로 인해 스크류의 이동 속도가 가장 작으며 이로 인해 정상상태에 가장 늦게 도달한다.

전술한 바와 같이 Table 2에 주어진 각 실험조건에 따라서 측정된 캐비티 압력, 노즐 압력 및 스크류 위치 프로파일이 상이하다. 이러한 상이한 프로파일로부터 도출된 특징요소 및 노드에너지를 기반으로 상태 진단 알고리즘이 개발되었고 구체적인 기술은 다음 장에 주어지 있다.

#### 4. 렌즈사출성형 공정상태 진단

##### 4.1 특징요소 추출

Table 2에 주어진 각 조건 별로 90 사이클의 렌즈 사출성형 실험을 수행하였으며 각 사이클로부터 측정된 캐비티 및 노즐 압력, 스크류 위치 신호에 2.1절에 주어진 특징요소 추출 알고리즘을 적용하여 캐비티 압력으로부터 5가지, 노즐 압력으로부터 7가지 그리고, 스크류 위치로부터 2가지의 특징요소를 추출하였다. 각 실험에서의 대표적인 특징 요소 추출 사례가 각 신호 별로 1개씩 Fig. 9에 주어지 있다. 대표적인 사례로서 Fig. 9(a)에는 각 실험조건에서 수행한 90사이클의 캐비티 압력 프로파일로부터 보압절환압을 추출한 결과가 주어지 있고 Fig. 9(b)에는 노즐압력 프로파일로부터 추출한 보압의 결과가 주어지 있다. 또한, Fig. 9(c)에는 스크류 위치 프로파일로부터 추출한 보압절환시간의 결과가 주어지 있다.

Fig. 9에 주어진 특징요소 추출 결과를 고찰해 볼 때 Fig. 9(b)의 Ex. 2 및 Ex. 5의 경우처럼 동일한

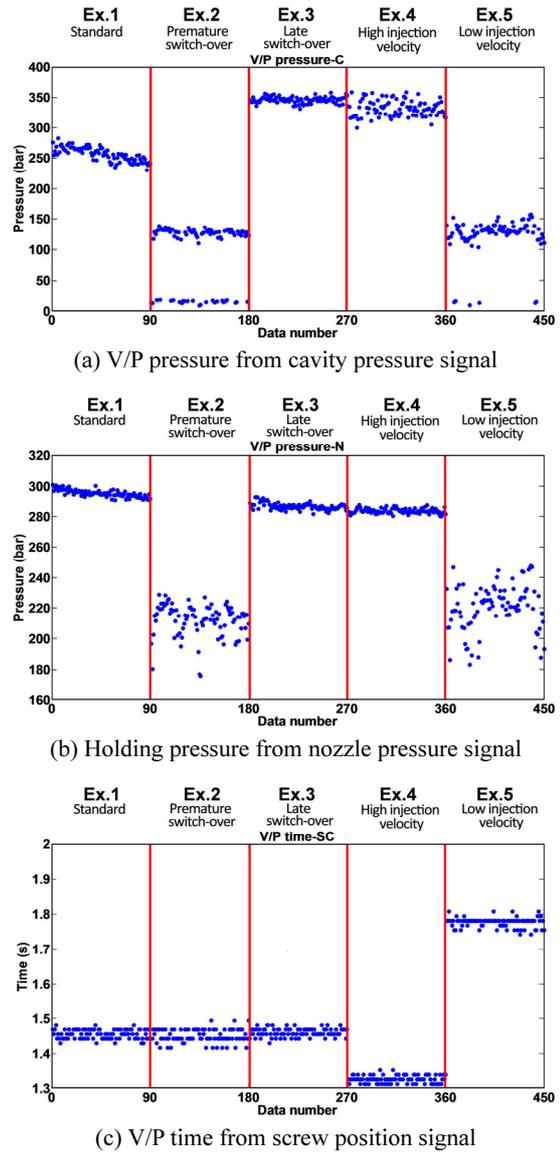


Fig. 9 Sample extracted features

실험조건 하에서도 추출된 특징요소 수치 값이 상대적으로 큰 산포도를 보이는 경우가 발생한다. 이는 노즐 압력의 경우 온도와 습도를 포함한 주위 환경으로 인해 해당 실험조건에서 추출되는 특징요소인 보압이 많은 영향을 받아 상대적으로 변화폭이 크므로 추정할 수 있다.

또한, 렌즈 사출성형 공정상태 진단의 정확도가 높아지기 위해서는 각 실험 경우에서 추출되는 특징 요소가 상호 구분되어야 한다. 다만 각 신호에서의 추출된 1가지 특징요소만을 고려하면 상호

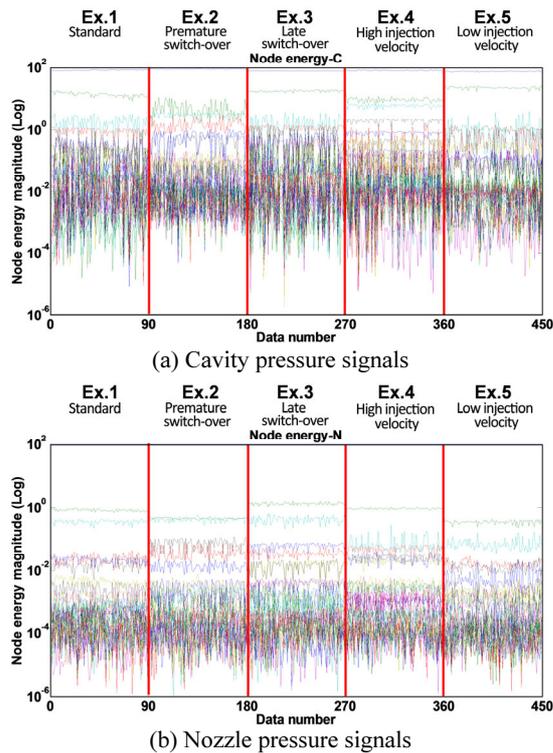


Fig. 10 Node energies extracted from

유사한 경우가 많이 발생하기 때문에 각 신호에서 추출된 복수의 특징요소를 이용하여 사출성형 공정상태 진단을 수행한다.

### 4.2 노드에너지 추출

2.2절에서 설명한 웨이블릿 패킷 분해 방법을 이용하여 각 실험 조건에서 측정된 캐비티 및 노즐 압력 신호로부터 노드에너지를 추출하였다. 웨이블릿 패킷 분해 방법을 적용하기 위해 상용 소프트웨어인 Matlab을 이용하였고 5 수준으로 캐비티 및 노즐 압력 신호로부터 각각 32개의 노드에너지를 추출하였으며 그 결과가 Fig. 10에 주어졌다.

### 4.3 사출성형 공정상태 진단결과

4.1절 및 4.2절에서 추출된 특징요소 및 노드에너지를 이용하여 확률신경망 이론에 기반을 둔 렌즈 사출성형 공정상태 진단 모델의 구축 및 검증을 위해 캐비티 압력 및 스크류 위치 신호를 사용한 경우와 노즐 압력 및 스크류 위치 신호를 사용한 경우의 2가지 경우를 고려하였다. Fig. 11에 사

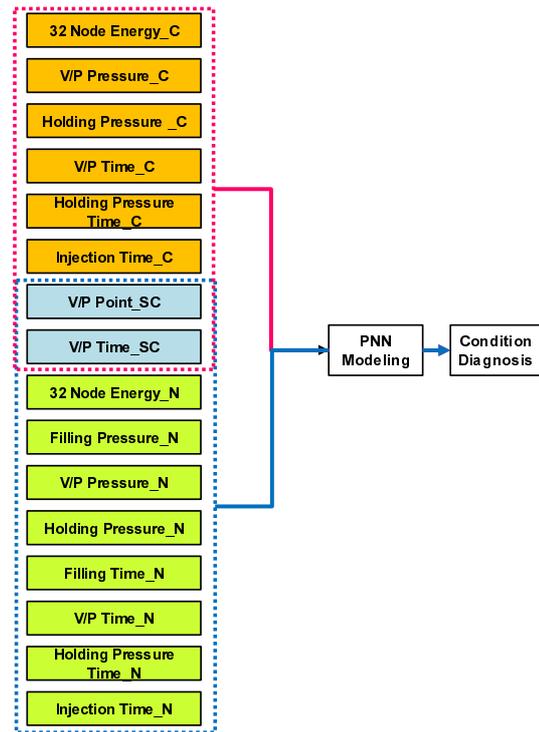


Fig. 11 List of extracted features and node energies used for lens injection molding condition diagnosis

출성형 공정상태 진단을 위해 캐비티 및 노즐 압력과 스크류 위치 신호로부터 추출한 인자의 리스트가 주어져 있다.

Fig. 11에 주어져 있듯이 첫 번째 사례연구에서는 캐비티 압력 프로파일에서 추출한 5가지 특징요소와 32개의 노드에너지, 그리고 스크류 위치 프로파일로부터 추출한 2가지 특징요소를 이용하였다. 또한, 두 번째 사례연구에서는 노즐 압력 프로파일에서 추출한 7가지 특징요소와 32개의 노드에너지, 그리고 첫 번째 경우와 같이 스크류 위치 프로파일에서 추출한 2가지 특징요소를 이용하였다. 상기 사례연구에서 각 실험의 경우 총 90사이클 중 60사이클에 해당하는 측정 데이터는 사출성형 공정상태 진단 모델 구축을 위한 훈련(Training) 단계에 사용하였으며 나머지 30사이클에 해당하는 데이터는 구축된 모델의 공정상태 진단 정확도를 검증하는데 적용하였다.

Fig. 12에 캐비티 압력과 스크류 위치 신호를 이용한 사출성형 공정상태 진단 결과가 주어져 있

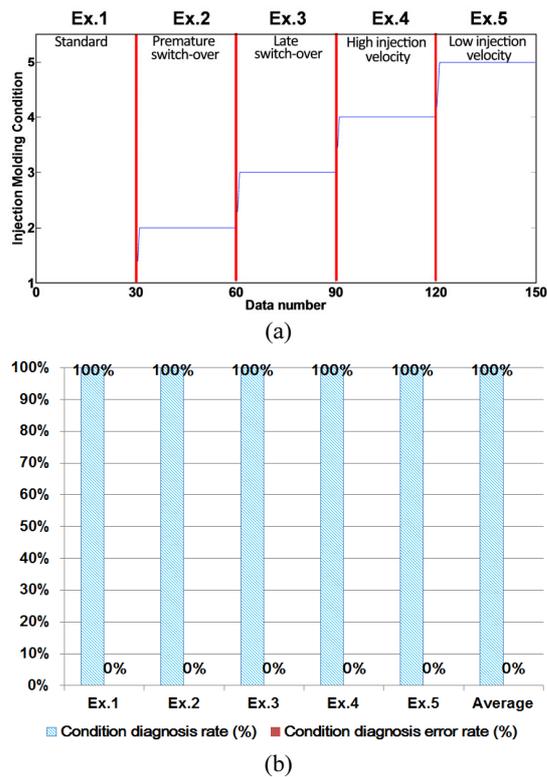


Fig. 12 (a) Condition diagnosis results and (b) rates for each experimental case using cavity pressure and screw position signals

으며, Fig. 13에는 노즐 압력과 스크류 위치 신호를 이용한 결과가 주어져 있다.

Fig. 12에서 보는 바와 같이 캐비티 압력 및 스크류 위치 신호를 적용한 경우 5가지 실험 조건에 대한 사출성형 공정상태 진단율은 100%로서 구축된 모델이 완벽하게 공정상태를 진단하는 것을 알 수 있다. 반면에 노즐 압력과 스크류 위치 신호를 적용한 경우는 Fig. 13에 주어져 있듯이 5가지 실험 조건에 대한 사출성형 공정상태 진단율은 평균적으로 85%이며 이 중 Ex. 3 및 Ex. 5의 실험 조건에 대한 진단율이 상대적으로 낮음을 알 수 있다. 이는 각 실험 조건에서 측정된 노즐 압력 프로파일이 캐비티 압력 프로파일의 경우보다 서로 더 유사함으로 인해 발생하는 것으로 분석된다. 즉, 이러한 유사성으로 인해 노즐 압력 프로파일로부터 추출되는 특징요소의 정확도가 상대적으로 낮은 것으로 판단된다. 특히, Fig. 13(a)에 주어진 각 실험 조건 진단결과에서 부족한 부분은 부정확한

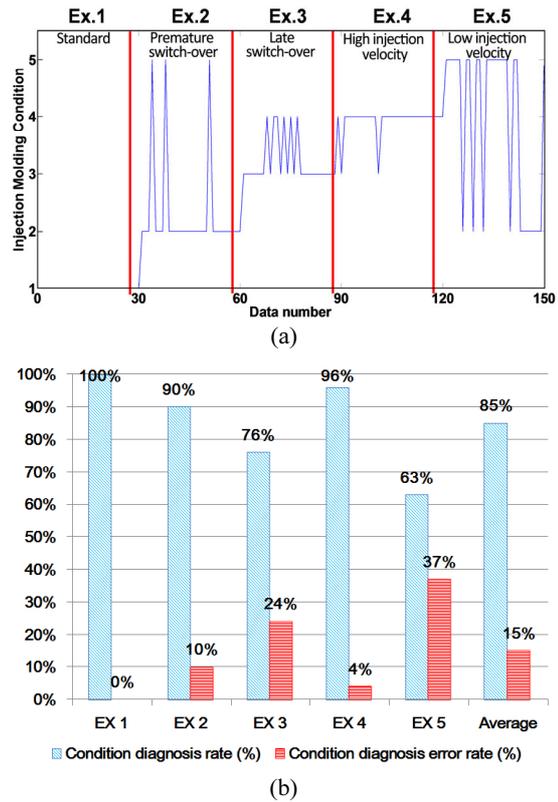


Fig. 13 (a) Condition diagnosis results and (b) rates for each experimental case using nozzle pressure and screw position signals

진단을 의미하는데 Ex. 3의 경우는 Ex. 4로, Ex. 5의 경우는 Ex. 2로 진단하는 에어율이 높은 것을 고찰할 수 있다. 이러한 노즐압력과 스크류 위치 신호를 사용한 경우의 렌즈 사출성형 공정상태 진단율인 85%는 현재 산업현장에서의 사출성형 렌즈의 단품 수율이 60~70%임을 고려한다면 실용적으로 적용할 수 있는 수치로 판단된다.

### 5. 결론

본 논문에서는 렌즈 사출성형의 주요 공정 파라미터인 캐비티 압력, 노즐 압력 및 스크류 위치 신호를 모니터링하고 이를 기반으로 공정상태 진단을 수행하는 새로운 알고리즘을 개발하였다. 즉, 렌즈 사출성형 공정 시 측정된 캐비티 압력 프로파일로부터 5가지, 노즐 압력 프로파일로부터 7가지, 그리고 스크류 위치 프로파일로부터 2가지의 특징요소를 추출하는 알고리즘을 개발하였고, 또

한 추출된 상기한 특징요소와 웨이블릿 패킷 분해 방법을 통해 추출된 캐비티 및 노즐 압력의 노드 에너지를 확률신경망 이론에 적용하여 사출성형 공정상태 진단 알고리즘을 개발하였다.

렌즈 사출성형 공정진단 모델 구축 및 타당성 검증을 위해 보압절환점과 사출속도의 변화를 고려한 실험을 설계하였으며, 각 조건 별로 90사이클의 사출성형 실험을 수행하여 이 중 60 사이클의 데이터는 공정상태 진단 모델 구축을 위한 훈련단계에서 사용하였고 30 사이클의 데이터는 구축된 모델의 타당성 검증에 사용하였다. 캐비티 압력 및 스크류 위치 신호를 고려한 경우와 노즐 압력 및 스크류 위치 신호를 고려한 경우의 2가지 사례연구를 수행하였고 각각 100%, 85%의 평균 공정상태 진단율을 확보하여 렌즈 사출성형 공정상태 진단을 위한 제안한 알고리즘의 적절성을 입증하였다.

향후에는 렌즈 사출성형의 주요 공정 파라미터인 캐비티 압력, 노즐 압력 및 스크류 위치 신호로부터 추출된 주요 특징요소를 기반으로 렌즈 형상오차, 렌즈 중심두께, 복굴절 등의 렌즈 품질을 예측하는 알고리즘의 개발을 수행할 예정이다. 또한 이러한 알고리즘을 기반으로 한 사출성형 렌즈 품질 예측 시스템을 구축하여 실제 산업현장에서의 적용을 통한 검증을 수행할 예정이다.

## 후 기

본 연구는 산업통상자원부 및 한국산업기술평가관리원의 산업융합원천기술개발사업(정보통신)의 일환으로 수행하였습니다[10040952, 신속대응 가능한 BIS(Built-In Sensor) 기반 자율 지능형 사출성형 시스템 개발].

또한, 렌즈 사출성형 실험 수행을 위해 아주대학교 성형가공실험실과 협력하였고 관계자님께 감사 드립니다.

## REFERENCES

1. Ko, B., Kim, J., and Choi, H.-G., "Estimation of Process Parameters Using QFD and Neural Networks in Injection Molding," *IE Interfaces*, Vol. 21, No. 2, pp. 221-228, 2008.
2. Lee, S. W., Joh, H. H., Hong, J. S., and Lyu, M.-Y., "Birefringent Analysis of Plastic Lens Injection Molding for Mobile Phone Camera," *Transactions of Materials Processing*, Vol. 20, No. 1, pp. 54-59, 2011.
3. Kwak, T. S., Ko, Y. H., Kang, H. W., and Jung, J. K., "Application of Birefringence CAE in mould design of Injection molding optic lenses," *Proc. of Spring Conference of KSMTE*, pp. 467-468, 2011.
4. Ribeiro, B., "Support Vector Machines for Quality Monitoring in a Plastic Injection Molding Process," *IEEE Transactions on Systems, Man, and Cybernetics-Par C: Applications and Reviews*, Vol. 35, No. 3, pp. 401-410, 2005.
5. Zhu, J. and Chen, J. C., "Fuzzy Neural Network-based in-process Mixed Material-Caused Flash Prediction (FNN-IPMFP) in Injection Molding Operations," *International Journal of Advanced Manufacturing Technology*, Vol. 29, pp. 308-316, 2006.
6. Zhang, J. and Alexander, S. M., "Fault Diagnosis in Injection Moulding via Cavity Pressure Signals," *International Journal of Production Research*, Vol. 46, No. 22, pp. 6499-6512, 2008.
7. Kuek, S. C., "An Investigation of Cavity Pressure as A Process and Quality Indicator in The Micro-Injection Molding Process," M.Sc. Thesis, Mechanical Engineering, Clemson University, 2007.
8. Park, H. P., Cha, B. S., Tae, J. S., Choi, J. H., and Lee, B. O., "Comparative Analysis of Injection Molding Process by On-line Monitoring in Cylinder of Injection Molding Machine and in Cavity of Mold," *Transactions of KSME A*, Vol. 34, No. 10, pp. 1513-1519, 2010.
9. Shinde, A. D., "A Wavelet Packet Based Sifting Process and its Application for Structural Health Monitoring," M.Sc. Thesis, Mechanical Engineering, Worcester Polytechnic Institute, 2004.
10. Park, S. H., Lee, J. J., Yun, C. B., and Roh, Y. R., "Application of Lamb Waves and Probabilistic Neural Networks for Health Monitoring of Joint Steel Structures," *Transactions of KSNVE*, Vol. 15, No. 1, pp. 53-62, 2005.
11. Kim, Y. S., Joo, N. A., Lee, J. J., and Lee, S. J., "Application of Probabilistic Neural Network for Evaluating the Lateral Flow Occurrence on Soft Ground," *Transactions of Korean Society of Civil Engineers*, Vol. 28, No. 1, pp. 1-8, 2008.

12. Huang, M. S., "Cavity Pressure based Grey Prediction of the Filling-to-packing Switchover Point for Injection Molding," Journal of Materials Processing Technology, Vol. 183, No. 2-3, pp. 419-424, 2007.