

오류역전과 알고리즘을 이용한 사출성형 금형 냉각회로 최적화

이병옥*, 태준성⁺, 최재혁⁺

(논문접수일 2009. 7. 6, 심사완료일 2009. 8. 7)

Injection Mold Cooling Circuit Optimization by Back-Propagation Algorithm

B. O. Rhee*, J. S. Tae⁺, J. H. Choi⁺

Abstract

The cooling stage greatly affects the product quality in the injection molding process. The cooling system that minimizes temperature variance in the product surface will improve the quality and the productivity of products. The cooling circuit optimization problem that was once solved by a response surface method with 4 design variables. It took too much time for the optimization as an industrial design tool. It is desirable to reduce the optimization time. Therefore, we tried the back-propagation algorithm of artificial neural network(BPN) to find an optimum solution in the cooling circuit design in this research. We tried various ways to select training points for the BPN. The same optimum solution was obtained by applying the BPN with reduced number of training points by the fractional factorial design.

Key Words : Injection Molding(사출성형), Cooling System Optimization(냉각 최적화), Artificial Neural Network(인공 신경망), Back-Propagation Algorithm(오류 역전파 알고리즘), Fractional Factorial Design(부분 요인배치법)

1. 서론

냉각단계는 사출성형 과정 중 가장 많은 시간을 차지하며 성형제품의 품질에 주요한 영향을 주는 단계이다. 제품 냉각의 균일성은 제품의 수축이나 잔류 응력 등에 영향을 주며

냉각시간은 사출성형 공정의 생산성에 직접적인 연관이 있다. 제품 냉각의 균일성을 위해서는 금형의 냉각회로 설계를 최적화 할 필요성이 높다. 냉각회로 최적화를 통한 균일한 금형 표면온도는 결과적으로 냉각시간도 단축할 수 있는 효과가 있다. 금형의 냉각시간은 제품의 냉각시간에 의해 결정되는데

* 아주대학교 기계공학과 (rhex@ajou.ac.kr)
주소: 443-749 경기도 수원시 영통구 원천동 산 5번지 아주대학교
+ 아주대 기계공학과

제품의 냉각시간이 이론적인 최소 냉각시간이 된다. 균일한 금형온도를 달성하는 것이 이론적인 최소 냉각시간에 가깝게 금형냉각시간을 감소하는 방법이다. 균일한 금형 냉각을 위해 냉각회로의 자동최적화에 관한 선행연구가 이루어졌었다^(1,2). 선행연구^(1,2)에서는 대형 자동차 부품의 평균 온도편차를 최소화하기 위해 냉각관 간격과 깊이, 배플관(Baffle tube) 간격과 깊이의 4개 설계변수를 적용하고, 면중심 합성법을 적용하여 추출된 결과를 이용, 반응표면을 구한 뒤 최적조건을 찾아내는 방법으로 최적화 연구를 진행 하였다. 해당연구^(1,2)에서는 4개의 설계변수에 대한 반응표면을 찾아내기 위해 면중심 합성법을 적용하여 25set의 조건을 해석하였다. 그러나, 대형 자동차 부품에 대한 냉각해석을 진행하기 위해서는 1개 조건에 대한 해석시간이 약 1시간이 넘게 걸렸으며 이로 인하여 최적설계를 위한 전체 해석시간이 매우 길게 걸리는 단점이 있었다. 선행연구 결과인 냉각회로 자동최적화 프로그램이 실용적인 설계도구로서 역할을 하려면 전체 해석시간이 단축되어야 할 필요성이 높다. 본 연구에서는 자동최적화 프로그램의 해석시간 단축을 위해 인공신경망 방법을 활용하는 방법을 연구하였다.

사출성형 연구에 인공신경망 방법을 이용한 사례로서, Lin⁽³⁾은 신경망 알고리즘을 이용하여 해석데이터를 학습시킨 후 임의의 설계값에 대한 수축 예측값을 예측하도록 하여 최소의 수축값을 가지도록 하는 냉각시스템을 설계하였다. 이와 같이 인공신경망을 이용하여 설계조건에 의한 목적함수값을 예측할 수 있거나 목적함수값의 분포가 상대적으로 변하지 않는다면, 설계 가능한 모든 조건에 대하여 결과값을 예측하고 최소의 목적함수값을 갖는 설계변수의 최적값을 찾아낼 수 있을 것이다. 또한 인공신경망 학습 과정에서 중요도가 높은 설계조건을 선별하여 학습을 진행함으로써 학습데이터 생성을 위해 실행하는 CAE 해석 수를 최소화할 수 있다.

본 연구에서는 오류역전파 알고리즘을 이용한 인공신경망(Back-propagation algorithm of artificial neural network, 이하 BPN)을 이용, CAE 해석을 통해 산출된 결과를 학습시켜 설계 가능한 모든 조건에 대한 제품의 온도편차를 예측한 후 온도편차를 최소로 하는 최적 설계조건을 산출하였으며 해석의 횟수를 줄여 전체적인 소요시간을 감소하도록 학습점 선정에 부분 요인배치법(Fractional Factorial Design)을 적용하였다.

2. 오류역전파 알고리즘

오류역전파 알고리즘은 주어진 입력값과 목표로 하는 출

력값과의 관계를 자체적인 적응성 알고리즘으로 도출하는 과정이다. 기본 구성은 Fig. 1과 같이 입력층, 은닉층, 출력층으로 나뉘며 각 층마다 여러 노드로 나뉘어 있다.

전방향 전파 시 입력층 각 노드는 은닉층 노드와의 초기 연결강도에 의해 값이 전달되고 은닉층은 입력층 각 노드에서 받은 값의 합을 Sigmoid함수로 출력층에 전달한다. 은닉층 각 노드에서 받은 값의 합은 Sigmoid함수를 거쳐 출력층 값으로 산출된다. 출력값을 산출하는 방법에 대한 도해가 Fig. 2에 나타나 있다.

최종적으로 산출된 출력값과 목표 출력값을 비교, 오차만큼 역으로 전파하면서 각 층의 연결강도를 수정한다. 이때 연결강도는 경사하강법(Gradient descent method)을 이용하여 출력값과 목표값의 오차가 최소를 갖는 방향으로 수정하며, 오차가 초기 설정한 오차한계값 이하가 될 때까지 연결강도를 수정하며 반복 학습한다. 학습이 종료된 BPN의 연결강도는 수정이 불가능 하며 연결강도의 수정을 위해서는 재학습을 진행해야 한다⁽⁵⁾. 본 연구에서 작성한 BPN은 Fig. 3에 나타나 바와 같은 구조를 가진다.




Fig. 1 Structure of Back-propagation algorithm⁽⁴⁾




Fig. 2 Calculation of actual output⁽⁵⁾

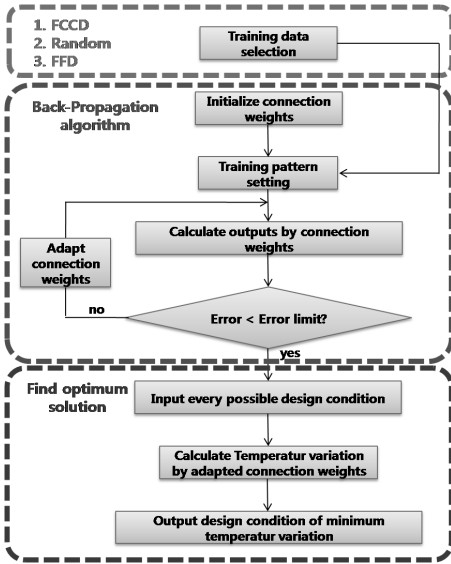


Fig. 3 Flow chart of cooling system design

3. 냉각회로 설계

3.1 학습데이터 선별

모델은 특정 자동차 모델의 전방 범퍼를 선정했으며 보안 문제상 세부적인 표시는 생략한다. BPN을 학습시키기 위하여 냉각관 간격(A)과 깊이(C) 그리고 배플관 간격(B)과 깊이(D)에 대한 설계조건을 면중심 합성법, 부분 요인배치법 그리고 무작위 채택법으로 선정하여 비교하였다. 설계변수의 정의는 Fig. 4에 나타난 바와 같다.

면중심 합성법은 선행연구^(1,2)에서 사용한 방법이며 주로 반응표면법에 사용되는 방법으로서 각 요인의 최대값과 최소값을 선정하고 전체 요인들의 중심값과 요인 간의 중간값을 선정하는 방법으로서 Fig. 5에 3개의 요인에 대한 3수준 선정 예를 그림으로 나타내었다⁽⁶⁾. 선행연구^(1,2)에서는 면중심 합성법을 이용하여 얻어진 값을 이용하여 반응표면을 만들고 이를 토대로 최적값을 계산하였다. 본 연구에서는 선행 연구와의 비교를 위해 BPN 프로그램을 위한 학습점 선정을 위해 면중심 합성법을 적용하였다. 면중심 합성법에 의하면 설계변수 4개에 대하여 3수준으로 채택하였을 때 직교표에 의해 총 31회의 해석이 필요하나. 이 중 7회는 중복되는 중간점이므로 실제로 해석을 위한 회수는 중복점 6회를 제외한 25회가 된다. 결국 BPN 프로그램 학습을 위해서는 25개의 설계조건에 대한 제품 온도편차의 CAE 해석 결과가 필




Fig. 4 Definition of optimization variables⁽¹⁾




Fig. 5 Face-centered central composite design⁽⁶⁾

요하므로 선행연구에 비해 해석시간 단축 효과는 없었다. 다만 본 연구에서는 선행연구에서 적용하였던 반응표면법과 본 연구에서 조사한 BPN 프로그램의 비교를 통해 BPN 프로그램의 신뢰성 평가를 위해 진행하였다.

본 연구의 목적인 최적화를 위한 해석시간의 단축을 위해 면중심 합성법에 의한 학습점 선정은 아무런 개선 효과가 없었으나, 학습점 선정 과정에서 시간을 줄일 수 있는 방법으로서 부분 요인배치법을 조사 하였다. 부분 요인배치법은 모든 인자 간 수준의 조합으로 나타내는 완전 요인배치법(Full Factorial Design)과 달리 의미가 적은 고차의 상호작용을 제외시켜 데이터 채택 횟수를 적게 하고자 하는 방법이다⁽⁶⁾. 부분 요인배치법은 일반적으로 2수준의 완전 요인배치법에서 요구되는 요인 수에서 하나의 요인을 줄인 상태로 선정점 수를 결정하는 방법으로서 전체적으로 실험횟수를 반으로 줄이는 효과가 있다⁽⁶⁾. 부분 요인배치법에 대한 예로서 3개의 요인에 대한 2수준 부분 요인배치법을 완전 요인배치법과 함께 Fig. 6에 그림으로 나타내었다. 설계변수 4개에 대하여 2수준으로 채택하면 8개의 실험횟수를 얻을 수 있다⁽⁶⁾.

마지막으로 무작위 채택법은 위와 같은 체계를 가진 학습점 선정이 아닌 무작위로 학습점을 선정하는 방법으로서 앞




Fig. 6 Fractional factorial design compared with full factorial design⁽⁶⁾

Table 1 Composition of training set by the face-centered central composite method (25set)

set	Design Variables (mm)			
	A	B	C	D
1	120	90	30	60
2	60	90	90	60
3	120	90	60	30
4	90	90	90	90
5	120	90	90	60
6	60	90	30	60
7	90	90	30	90
8	90	90	30	30
9	60	120	60	60
10	120	90	60	90
11	90	90	90	30
12	120	120	60	60
13	90	60	30	60
14	90	120	90	60
15	90	120	60	30
16	90	60	90	60
17	90	120	60	90
18	90	60	60	30
19	60	90	60	90
20	90	60	60	90
21	120	60	60	60
22	60	90	60	30
23	90	120	30	60
24	90	90	60	60
25	60	60	60	60

Table 2 Composition of training set by the random selection (10set)

set	Design Variables (mm)			
	A	B	C	D
1	60	60	30	30
2	120	60	30	30
3	60	60	90	30
4	120	60	90	30
5	120	60	30	90
6	60	60	90	90
7	120	60	90	90
8	60	120	30	90
9	120	120	30	90
10	90	90	90	60

Table 3 Composition of training set by the fractional factorial design (8set)

set	Design Variables (mm)			
	A	B	C	D
1	120	60	90	30
2	60	120	30	90
3	120	60	30	90
4	60	120	90	30
5	60	60	90	90
6	120	120	90	90
7	60	60	30	30
8	120	120	30	30

서 설명한 2가지의 체계적인 선정방법과의 효과를 비교하기 위해 적용하였다. 본 연구에서는 실제로 다양한 수의 학습점을 무작위로 선정하여 조사하였으나 본 논문에서는 총 10개의 학습점을 무작위로 선정한 경우를 다른 방법과 비교하였다. 무작위 학습점 선정을 위한 모집단으로서 본 연구에서는 면중심 합성법에서 계산한 25회의 결과를 이용하였다. 즉, 해당 25회의 결과 중 임의로 10개를 선정하여 사용하였다. Table 1 - 3은 각각 면중심 합성법, 무작위 채택법 그리고 부분 요인배치법을 적용하여 선정된 CAE 해석을 위한 설계 조건을 나타낸다.

3.2 신경망 학습

BPN을 Labview 7.1로 구현하였으며 프로그램의 구조는 Fig. 3과 같다. 입력값은 설계조건(노드 수 4개), 목표값은 Moldflow사의 MPI 6.2로 해석한 제품의 온도편차(노드 수 1개)로 설정하였으며 목표값과 출력값간 오차한계는 0.001, 학습률은 0.2, 은닉층은 1개이며 은닉노드는 10개로 설정하였다. 학습은 모든 세트에 대하여 오차한계 이하의 출력값을 가질 때까지, 또는 반복학습수가 150,000번 이상 될 때 강제 종료하도록 프로그래밍 하였다.

3.3 학습점 선정

본 연구에서는 설계조건 A, B는 최소 60mm 최대 120mm, 설계조건 C, D는 최소 30mm 최대 90mm로 설정하였으며 세부 설계조건은 Table 1, 2, 3에 나타내었다.

3.4 최적값 도출

학습 완료된 프로그램에 임의의 설계조건을 입력하여 계산된 값은 입력 설계조건에 따른 제품의 온도편차 예측값이 된다. 냉각관의 위치는 실제로 연속적인 속성이 아니다. 금형 가공이 가능하여야 하는 점 등을 고려하면 현장의 경험에 따라 약 10mm 간격을 가지는 것이 타당하다. 따라서 설계 조건 간격을 10mm으로 설정했을 때 설계 가능한 모든 경우의 수는 2,401개 이다. 전역검색 프로그램을 이용하여 설계 가능한 모든 조건에 따른 온도편차 예측값을 계산하여 최소의 온도편차를 갖는 설계조건을 최적값으로 하였다.

4. 결 과

Table 4는 면중심 합성법을 이용하여 선정한 설계조건에 따른 MPI 해석 결과 25set를 학습자료로 입력한 후 BPN 프로그램을 이용하여 예측한 예측값을 기준으로 얻은 최적 설계조건과 그에 해당하는 예측값 그리고 해당 최적 설계조

Table 4 Composition of training set by the face-centered central composite method (25set)

No.	Design Variables (mm)				Temp. Dev. (°C)	
	A	B	C	D	BPN	MPI
1st (Opt.)	60	60	30	30	3.756	3.285
2nd	60	70	30	30	3.764	3.887
3rd	60	80	30	30	3.769	3.807

건을 이용하여 얻은 MPI 해석값을 나타낸다. 표에 나타난 첫 번째와 두 번째 그리고 세 번째의 설계조건은 BPN 프로그램에서 얻어진 온도편차가 가장 낮은 순으로 열거한 3 가지 조건으로서 최적설계조건에 대한 비교를 위해 나타내었다. 이와 같은 결과는 동일한 모델에 대하여 선행연구^(1,2)와 동일한 반응표면법을 적용한 최재혁의 연구결과⁽⁷⁾와 일치하였다. 이 결과는 본 연구에서 사용한 BPN 프로그램이 반응 표면법을 사용한 선행연구와 동일한 결과를 도출함으로써 BPN 프로그램의 신뢰성을 입증하여 주었다.

Table 4에 나타난 인공신경망을 이용한 예측값이 해당 최적설계조건을 입력하여 얻은 MPI 해석값과 차이를 보이고 있으며 그 차이는 균일하지 않음을 알 수 있었다. 그러나 본 연구의 목적은 최적 설계조건을 인공신경망 방법을 이용하여 찾고자 함이며 온도편차 결과를 세부적으로 예측하고자 함이 아니므로 이와 같은 예측값의 차이는 이와 같은 오차로 인하여 최적설계 결과에 중대한 문제를 발생하지 않는 한 크게 문제가 되지 않는 것으로 사료된다.

Table 5는 25set의 데이터 중 임의로 10set를 선정한 후 BPN 프로그램을 학습시켜 예측한 예측값을 나타낸다. 임의로 학습점을 선정하는 방법으로는 앞에서 얻어진 결과와 동일한 최적설계조건을 얻을 수 없음을 알 수 있었다. 이 결과에서도 BPN 프로그램을 통해 얻어진 온도편차 예측값은 실제 MPI를 통해 얻어진 해석값과 차이를 나타내고 있다. 임

Table 5 Composition of training set by the random selection (10set)

No.	Design Variables (mm)				Temp. Dev. (°C)	
	A	B	C	D	BPN	MPI
1st (Opt.)	60	120	30	30	4.307	3.558
2nd	60	120	40	30	4.315	3.794
3rd	70	120	30	30	4.321	3.423

Table 6 Composition of training set by the fractional factorial design (8set)

No.	Design Variables (mm)				Temp. Dev. (°C)	
	A	B	C	D	BPN	MPI
1st (Opt.)	60	60	30	30	3.679	3.285
2nd	60	70	30	30	3.679	3.887
3rd	60	80	30	30	3.680	3.807

의로 선정된 학습점을 입력한 경우 규칙성 없이 축소된 학습 자료의 양이 프로그램의 부정확성을 야기하였다고 판단하였다. 즉, 상대적으로 중요도가 적은 학습자료가 포함되었기 때문에 학습률을 저하시켰다고 판단된다. 이를 통해 학습자료의 양보다는 학습점의 질이 결과에 영향을 크게 줄 수 있음을 알 수 있었다.

Table 6는 부분 요인배치법을 이용하여 8set의 학습점을 선정한 후 이를 BPN 프로그램에 입력하여 얻어진 예측값과 최적설계조건이다. 이 결과 면중심합성법을 사용하여 학습점을 선정한 경우와 동일한 최적설계조건을 도출하였다. BPN 프로그램에 의해 예측된 온도편차 예측값이 MPI 해석값과 오차를 보여주고 있었으나 다른 2가지 방법보다는 상대적으로 작은 오차를 발생하였다. 부분 요인배치법은 학습점 수는 줄었지만 상대적으로 많은 학습점을 가진 방법과 동일한 결과를 도출하였고 예측값 또한 크게 차이가 나지 않으므로써 매우 효과적임을 입증하였다. 이와 같이 부분 요인배치법을 이용하여 학습점의 수를 획기적으로 감소한 상태에서도 신뢰성이 높은 결과를 만들어 낼 수 있음으로써 사출금형 냉각회로 최적설계를 위해 필요한 CAE 해석시간을 대폭 줄일 수 있는 가능성이 높다고 판단하였다.

5. 결론

본 연구에서는 사출금형 냉각회로 최적설계에 오류역전과 알고리즘 인공신경망(BPN) 방법을 적용하여 최적설계에 소요되는 해석시간을 단축하기 위한 연구를 진행하였다. 면중심 합성법보다 학습점 수가 작은 부분 요인배치법을 통해 선정된 학습점에 대한 CAE 해석 결과를 입력하여 학습 완료된 BPN 프로그램을 이용하여 모든 설계조건 영역에 대한 결과값을 예측하도록 한 후 이를 토대로 최적값을 산출한 후 결과를 선행연구와 동일한 방법으로 얻은 결과와 비교하였다. 본 연구의 결과 다음과 같은 결론을 얻을 수 있었다.

- (1) 실제 대형 성형품 모델에 대해 3수준 면중심 합성법을 통해 선정된 학습점을 입력하여 학습시킨 BPN 프로그램은 선행연구와 동일한 반응표면법을 사용한 연구결과⁽⁸⁾와 동일한 최적 사출조건을 도출함으로써 사출금형 냉각회로 최적설계에 대한 신뢰도를 입증할 수 있었다.
- (2) BPN 프로그램에 대한 학습점 수를 감소하기 위해 사용한 2수준 부분 요인배치법을 통해서, 3수준 면중심 합성법을 통해 얻어진 학습점을 입력한 결과와 동일한 최적 설계조건을 얻을 수 있었다. 기존 반응표면법을 이용한

최적설계에 총 25회의 해석이 필요한 반면, 본 연구에서 적용한 2수준 부분 요인배치법을 이용한 BPN 프로그램은 총 8회의 해석에 동일한 결과를 얻을 수 있었으므로, 최적설계에 소요되는 해석이 25회에서 8회로 줄어들어 전체 시간이 32%로 감소하는 효과를 얻었다.

- (3) 학습점 선정을 무작위 채택법으로 한 경우 신뢰도가 낮은 최적해를 도출하였으며 이는 규칙성이 없이 축소된 학습자료의 양은 예측값의 정확성을 보장할 수 없음을 나타내는 결과라고 사료된다. 이렇게 단순한 학습자료량 축소에 의한 예측값의 부정확성이 실험계획법에 의한 체계적인 학습점 선정을 통해 크게 개선될 수 있음을 알 수 있었다.

후 기

본 연구는 지식경제부와 한국산업기술재단의 전략기술인력양성사업으로 수행된 연구결과임.

참 고 문 헌

- (1) Jang, H. G., 2008, *A study on automatic optimization of cooling circuit design in injection mold*, M.S. Thesis, Ajou University, Republic of Korea
- (2) Chung, H. W., 2008, *A study of automated optimization of injection-mold cooling-line design with predefined product temperature*, M.S. Thesis, Ajou university, Republic of Korea
- (3) Lin, J. C., 2002, "Optimum cooling system design of free-form injection mold using an abductive network," *Journal of Materials Processing Technology*, Vol. 120, pp. 226~236.
- (4) Kim, D. S., 1993, *Neural networks theory and applications*, Jinhan M&B, Republic of Korea
- (5) Lippman, R. P., 1987, "An introducing to computing with neural nets," *IEEE ASSP Magazine*, pp. 4~22.
- (6) Montgomery, D. C., 2005, *Design and Analysis of Experiments*, John Wiley & Sons, Hoboken, NJ, U.S.A.
- (7) Choi, J. H., 2009, "A study on the reduction of design variables for injection mold cooling system optimization," *Proceedings of 2009 Spring Conference of The Korean Society of Technology of Plasticity*, pp. 361~364.