

수직 원형관에서 서브쿨비등시 매우 높은 임계열유속의 예측

권영민*, 한도희*

Prediction of Very High Critical Heat Flux for Subcooled Flow Boiling in a Vertical Round Tube

Young-Min Kwon, Dohee Hahn

Key Words : Subcooled boiling, Critical Heat Flux (CHF), Artificial Neural Network

Abstract

A critical heat flux (CHF) prediction method using an artificial neural network (ANN) was evaluated for application to the high-heat-flux (HHF) subcooled flow boiling. The developed ANN predictions were compared with the experimental database consisting of a total of 3069 CHF data points. Also, the prediction performance by the ANN was compared with those by mechanistic models and a look up table technique. The parameter ranges of the experimental data are: $0.33 \leq D \leq 37.5$ mm, $0.002 \leq L \leq 4$ m, $0.37 \leq G \leq 134$ Mg/m²s, $0.1 \leq P \leq 20$ MPa, $50 \leq \Delta h_{sub,in} \leq 1660$ kJ/kg, and $1.1 \leq q_{CHF} \leq 276$ MW/m². It was found that 91.5% of the total data points were predicted within a $\pm 20\%$ error band, which showed the best prediction performance among the existing CHF prediction methods considered.

기호설명

q_{CHF}	임계열유속 (CHF) (MW/m ²)
D	관 직경 (m)
L	관 길이 (m)
G	유량 (Mg/m ² s)
P	압력 (MPa)
$\Delta h_{sub,in}$	입구 과냉도 (kJ/kg)

1. 서론

상 변화를 수반하는 서브쿨비등은 강화된 열전달 특성으로 인하여 매우 높은 열유속을 제거할 수 있다. 매우 높은 유량과 과냉 상태에서의 임계열유속 (critical heat flux, CHF)은 핵융합로, 제트엔진 등과 같은 고열유속 장치의 중요한 설계변수가 되므로 공학적인 필요성에 의해 많은 연구가 수행되어 왔다. 열전달 장치는 열전달 벽면 또는 튜브의 손상 (burnout)을 피하기 위해 반드시 벽면온도

가 CHF 조건 아래에서 운전되어야 한다. 강제대류 서브쿨비등 조건에서의 CHF 발생기구에 대한 많은 실험이 수행되었고 여러 가지 이론적인 모델이 제안되었으나 아직까지 명확한 CHF 발생기구가 정립되어 있지 않다.

지금까지 개발된 수많은 이론적 CHF 모델 중에 고열유속 서브쿨비등 CHF 에 적용할 수 있는 모델은 소수에 불과하다. 이론적 CHF 모델을 평가한 저자의 연구에⁽¹⁾ 의하면 Celata et al.⁽²⁾, Weisman-Pei⁽³⁾, Kwon-Chang⁽⁴⁾의 모델들만이 비교적 신뢰도 높은 정확성을 가지고 고열유속 서브쿨비등 조건의 CHF 를 예측 가능하였다. 최근에는 인공신경회로망 (artificial neural network, ANN)을 CHF 예측에 이용하는 연구가^(5, 6) 수행되고 있다. ANN 기법은 변수들 간에 있을 수 있는 상호관계를 수식으로 표현하지 않고서도 복잡한 계를 모델링 할 수 있는 장점을 가지고 있다. 즉, CHF 와 관련된 기본적인 열수력 변수에 대한 정보를 가지고 CHF 실험 데이터를 통하여 일정한 규칙을 학습한 후, 미지의 조건에서의 CHF 를 예측한다. 본 연구에서는 ANN 기법을 사용하여 고열유속 서브쿨비등 CHF 를 예측할 수 있는 방법론을 개발하고 그 예측성

* 한국원자력연구소

능을 기존의 이론적 모델과 비교하였다.

2. 고열유속 장치에서의 CHF

전자장비 또는 경수원자로 (LWR)에서의 열유속은 일반적으로 1 MW/m^2 전후의 수준이므로 비교적 저 유속, 저 과냉의 강제대류를 이용하여 CHF를 초과하지 않고 열을 제거할 수 있다. 그러나 핵융합로, 입자 가속기, 고출력 레이저, 로켓 엔진과 같은 고열유속 장치는 매우 높은 열유속의 제거가 요구된다. 특히 핵융합로의 부품 냉각을 위해서는 80 MW/m^2 의 열유속이 제거되어야 한다. 고열유속 장치는 열유속이 일정한 상태에서 운전되므로 벽면온도가 너무 증가하게 되면 냉각채널이 파손될 수 있다.

고열유속 장치의 개발 및 안전운전을 위하여 이런 상태에서의 CHF에 대한 많은 연구가 수행되어왔다. Bergles는⁽⁷⁾ 직경이 작은 튜브에서 고유속, 고과냉도의 서브쿨비등 CHF 특성을 조사한 실험에서 튜브의 직경이 작아질수록 CHF는 크게 증가함을 발견하였다. Nariai-Inasaka는⁽⁸⁾ 작은 직경의 튜브에서 고유속, 고과냉도의 서브쿨비등이 수반되는 강제대류 특성을 조사한 결과, 예측된 기공율이 기존의 상관식이나 이론모델의 예측치보다 훨씬 적음을 알았다. 기공율의 감소는 결국 CHF를 증가시킨다. 최근에 Mudawar-Bowers는⁽⁹⁾ 균일가열관에서 276 MW/m^2 에 이르는 매우 높은 CHF 실험을 수행하였다.

본 연구를 위하여 KAIST가 보유한 CHF 데이터 베이스에서 균일가열관 서브쿨비등 조건의 10개 참고문헌으로부터 총 3069 실험 데이터⁽¹⁾를 선택하였다. 모든 CHF 데이터는 관 출구의 평형건

도가 0 이하이며 1 MW/m^2 이상의 값을 가진다. 이들 데이터는 실험결과를 참고하여 관내경과 유량을 기준으로 $G \geq 10 \text{ Mg/m}^2\text{s}$ 이고 $D < 3 \text{ mm}$ 인 HMSD (High Mass velocity and Small Diameter) 영역과 $G < 10 \text{ Mg/m}^2\text{s}$ 이거나 $D \geq 3 \text{ mm}$ 인 일 normal 영역으로 분류하였다. HMSD 영역에는 843 개, normal 영역에는 2226 개의 데이터가 포함된다.

3. CHF 예측방법

CHF 예측방법에는 현재까지 4 가지가 있다. 즉 실험적 상관식, 그래프 또는 도표 (look-up table), 해석적 이론모델, ANN 기법을 이용하는 것이다. CHF 발생기구를 기반으로 개발된 해석적 이론모델은 운전조건에 따라 쉽게 수정될 수 있으므로 광범위한 운전상태의 CHF 예측에 적용 가능하다. 본 장에서는 이론모델과 ANN 기법에 대하여 간략하게 기술한다.

3.1 이론적 CHF 모델

CHF가 발생하는 시점에서 이상유동 구조에 대한 제한된 이해와 CHF와 관련된 복잡한 현상 때문에 이론적 CHF 모델은 예측의 정확도보다는 CHF의 물리적 현상을 이해하는데 더 큰 중요성을 가진다. 모든 CHF 이론모델은 제한된 실험관측에 근거하므로 가상적인 유동구조와 가정을 사용한다. 그림 1은 대표적인 CHF 이론모델의 개념을 도식화한 것이다. 그림에서 Celata-Katto et al. 모델은 근본적으로 Celata et al. 모델과⁽²⁾ 비슷한 liquid sublayer dryout 개념이며, Weisman-Pei 모델은 bubble crowding 개념, Kwon-Chang 모델은 wall-attached bubble coalescence 개념을 기본으로 하고

Table 1. Experimental CHF data for the HHF subcooled flow boiling

Parameter	No.	D (mm)	L (m)	P (MPa)	\bar{G} (Mg/m ² s)	$\Delta h_{\text{sub},in}$ (kJ/kg)	q_{CHF} (MW/m ²)
Thompson et al.	541	1.14 ~ 37.5	0.04 ~ 1.97	2.1 ~ 19.0	0.7 ~ 7.5	49 ~ 1659	1.1 ~ 14.8
Becker et al.	101	6.0 ~ 10.0	0.4 ~ 3.0	3.04 ~ 20.0	0.37 ~ 6.98	648 ~ 1384	1.05 ~ 7.48
Zenkevich	244	5.8 ~ 11.0	1.0 ~ 4.0	7.85 ~ 19.6	0.96 ~ 5.06	239 ~ 1617	1.05 ~ 7.29
Chen et al.	109	10.0 ~ 16.0	0.3 ~ 0.4	0.15 ~ 1.7	1.4 ~ 13.4	228 ~ 701	4.17 ~ 14.56
Boyd	23	10.2	0.5 ~ 1.17	0.45 ~ 1.6	1.14 ~ 7.45	544 ~ 772	1.53 ~ 11.5
Nariai et al.	14	6.0	0.1	0.1 ~ 1.5	4.59 ~ 8.69	245 ~ 671	8.5 ~ 22.1
Mudawar et al.	169	0.4 ~ 0.9	0.0045 ~ 0.03	0.25 ~ 17.2	5.0 ~ 134.0	322 ~ 1584	9.4 ~ 276
ENEA	1868	0.33 ~ 25.4	0.002 ~ 0.61	0.09 ~ 8.41	0.93 ~ 90.0	88 ~ 1018	3.33 ~ 228
Total	3069	0.33 ~ 37.5	0.002 ~ 4.0	0.1 ~ 20.0	0.37 ~ 134	49 ~ 1659	1.05 ~ 276




Fig.1 Concept of Mechanistic CHF Models

있다. Celata et al. 모델은 고열유속 CHF 데이터를 사용하여 국한된 범위에서 개발되었다. 반면에 Weisman-Pei 와 Kwon-Chang 모델은 초기에는 경수 원자로 운전 조건인 저열유속 CHF 데이터를 사용하여 개발되었지만 고열유속 고과냉도에 맞는 열수력 상관식을 사용함으로써 고열유속 CHF 데이터에도 성공적으로 적용되고 있다. 특히 Celata et al. 모델을 제외한 모든 이론모델은 실험데이터를 fitting 하기 위해 실험적인 상수 또는 상관식을 포함하고 있다. Kwon-Chang 모델은 CHF 발생기준으로 1 개의 임계 벽면기공율 (critical wall-void fraction) 상관식을 사용하고 Weisman-Pei 모델은 3 개의 실험상수를 사용한다. 특히 Weisman-Pei 모델에서 도입된 기체와 액체의 밀도 비에 대한 실험상수는 고압의 CHF 데이터를 기준으로 설정되었으므로 밀도 차이가 커지는 저압의 경우에는 모델을 적용하기 곤란하다.

3.2 인공신경회로망 기법

ANN 기법은 패턴 인식, 변수 평가, 제어 등과 같은 여러 공학적인 분야에서 응용되고 있다. ANN 에서는 실험데이터를 상관시키기 위한 구체적인 모델구조를 찾을 필요가 없다. Yapo et al.와(5) 와 Moon et al.은(6) ANN 기법이 기존의 CHF 평가 방법의 한 대안이 될 수 있음을 보여 주었다. Back Propagation Technique (BPN)은 현재 사용되는 ANN 중 가장 잘 알려져 있고 널리 사용되고 있다. BPN 학습 알고리즘은 인간의 학습방법과 유사하다. 감독 프로그램은 문제와 해답으로 구성된 회로망을 훈련시킨 후 문제를 일반화한다. 이렇게 일반화된 학습결과는 새로운 문제의 해답을 찾는 데 적용된다.

본 연구에 사용된 BPN 네트워크의 일반적인 구조가 그림 2 에 나타나 있다. 민감도 연구 결과, 3 계층의 BPN 구조를 채택하였다. 이들은 각각 input layer, 두개의 hidden layers, output layer 로 구성되며, 각 계층은 다시 노드로 구성되어 있다. input 노드를 통해 외부에서 입력 데이터가 들어오면 일반적으로 비선형 변환을 거친 후 output 노드를 통해 출력 데이터가 생산된다. 인공신경회로망의 수학적 원리와 CHF 예측에 적용절차는 참고문서에 자세히 기술되어 있으므로 여기서는 생략한다.

BPN 적용의 첫 단계는 가능한 모든 정보를 사용하여 신경회로망을 설계하는 것이다. BPN의 성능을 향상시키기 위해서는 입력형태를 적절하게 선택하여야 하므로 본 연구에서는 Moon et al.이 제시한 방법을 따라 다음 5 개의 무차원 변수를 선택하였다. 이들 변수는 수직형 균일가열관에서 강제대류 서브쿨비등 CHF 에 영향을 주는 인자이다.

$$\frac{q_c''}{Gh_{fg}} = f\left(\frac{\rho_g}{\rho_f}, \frac{\sigma\rho_f}{G^2L}, \frac{L}{D}, \frac{\Delta h_m}{h_{fg}}\right) \quad (1)$$

BPN 성능은 hidden layer 의 노드 수에 민감하므로 민감도 해석을 통하여 첫번째와 두번째의 노드를 각각 30 과 40 으로 결정하였다. 이때 네트워크를 훈련시키기 위해서 3000 번의 반복 실험을 수행하였다. 여기에서는 BPN 적용목적이 주어진 조건에서 CHF 를 예측하는 것이므로 output layer 는 단일 노드로 하였다. BPN 적용방법의 신뢰도를 높이기 위하여 전체 CHF 데이터를 두 경우로 분류하였다. 랜덤추출 방법을 사용하여 선택된 전체의 90%에 해당하는 데이터로 BPN 을 학습시킨 후, 학습과정에 사용되지 않은 나머지 10% 데이터로 훈련된 BPN 의 CHF 예측성능을 평가하였다. 그림 3 은 BPN 의 훈련 및 CHF 예측 전 과정을 보여준다.




Fig. 2 The back-propagation neural network

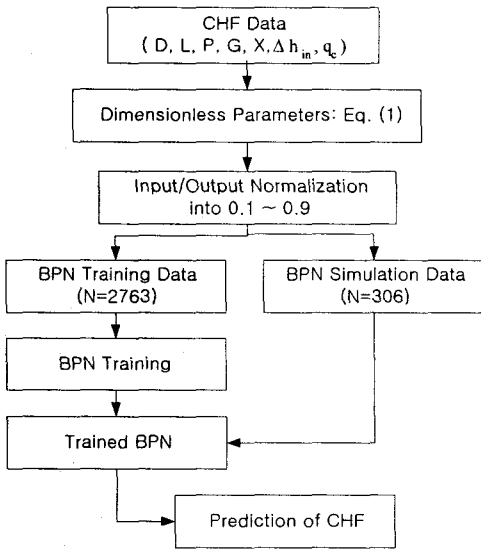


Fig. 3 BPN procedure for CHF prediction

4. 고열유속 CHF 데이터와의 비교

각 CHF 예측방법은 예측값과 실험값의 비율로 정의되는 CHFR로 정량적인 평가를 하였다. 이때 μ 는 CHFR의 평균값, σ 는 CHFR의 표준편차, RMS는 CHFR의 root-mean-square error를 의미한다. 각 CHF 예측방법을 2장에서 언급한 두 경우의 CHF 데이터 집합에, 즉 HMSD 영역과 normal 영역, 적용하였다.

본 연구에서 채택된 CHF 데이터 베이스는 표 2에 제시된 각 CHF 이론모델의 적용범위를 초과할 수 있음에 유의하여야 한다. 이론모델의 예측성능은 그 모델이 개발되고 검증된 적용범위 내에서만 보장되기 때문이다. 본 연구에서 예측성능을 비교하는 목적은 서브쿨비등시 각 CHF 이론모델의 일

Table 2. Parameter ranges of the mechanistic CHF models

	Celata et al. [2]	Weisman - Pei [3]	Kwon-Chang [4]
Pressure (MPa)	0.1 - 8.4	2 - 20.5	2 - 20
Mass flux (kg/m ² s)	900 - 90000	972 - 3611	450 - 7500
Diameter (mm)	0.3 - 25.4	1.15 - 37.5	1 - 37.5
Length (m)	0.0025 - 0.61	0.035 - 3.6	0.035 - 6
Subcooling	$\Delta T_{sub,in} \leq 25$ K	$\alpha < 0.6$	$\Delta h_{sub,in} \leq 1660$ kJ/kg
Used constants	No	3	1

반성을 평가하기 위함이다. 서브쿨비등 조건에서도 저열유속 CHF와 고열유속 CHF의 열수력 상태는 크게 차이가 나므로 각 이론모델의 적용범위를 평가할 수 있다.

표 3은 본 연구에서 선택된 CHF 데이터 베이스에 대한 각 CHF 예측방법의 성능을 평가한 결과이다. 표에서 나타난 "original"의 뜻은 각 이론모델이 제안한 적용 범위이다. Celata et al. 모델은 전체 3069개 데이터의 89%를 오차범위 $\pm 30\%$ 내에서 예측하였다. 그러나 이 모델은 전체적으로 CHF를 낮게 예측하였다. Celata et al. 모델은 고열유속 조건의 ENEA의 CHF 데이터 베이스를 사용하여 개발된 모델로서 ENEA 데이터는 본 연구의 데이터 베이스에 모두 포함되어 있다. 총 2167 데이터가 Celata et al. 모델의 적용범위에 속하고 있으며 이들 데이터의 90%가 오차범위 $\pm 30\%$ 내에서 실험값과 일치하였다. Weisman-Pei 모델은 일반적으로 CHF를 높게 예측하고 있으며 이 모델의 예측성능은 예상한대로 저압영역에서는 좋지 않았다. 그러나 Weisman-Pei 모델의 적용범위 내에 속하는 999 데이터에 대해서는 $\mu = 1.11$ 로 양호한 예측성능을 보이고 있다. Kwon-Chang 모델은 그림 4에서 처럼 HMSD 영역에서는 상대적으로 큰 편차를 보이고 있으나 843 데이터의 89%가 오차범위 $\pm 30\%$ 내에서 실험값과 잘 일치하고 있다. 이때 평균값 μ 는 0.99로 0.92인 Celata et al. 모델보다 양호하지만 σ 와 RMS 측면에서 예측성능이 떨어진다. 그러나 normal 영역의 경우는 다른 모

Table 3. Prediction performances by the mechanistic models and ANN method

	Type	No	μ	RMS	σ
Celata et al. [2]	HMSD	843	0.92	20.8	19.1
	normal	2226	0.92	18.7	16.7
	total	3069	0.92	19.3	17.4
	original	2167	0.96	18.0	17.5
Weisman-Pei. [3]	HMSD	843	1.16	26.3	20.6
	normal	2222	1.21	28.9	19.7
	total	3065	1.20	28.2	20.1
	original	999	1.11	17.4	13.5
Kwon-Chang[4]	HMSD	843	0.99	22.0	22.0
	normal	2226	1.01	17.0	16.9
	total	3069	1.01	18.5	18.5
	original	886	1.02	10.4	10.0
ANN	HMSD	843	1.02	18.3	18.2
	normal	2226	1.025	10.9	10.6
	total	3069	1.02	13.3	13.1
Look-up Table	normal	1575	0.99	17.4	17.3

Number of CHF data successfully converged

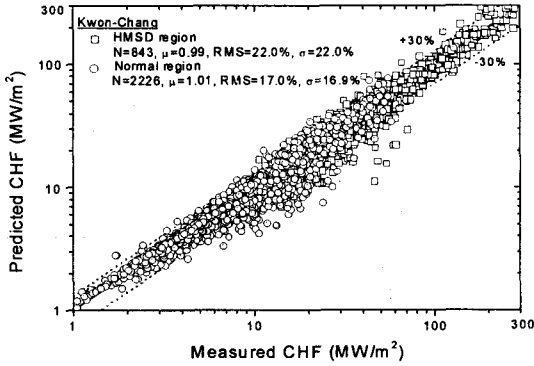


Fig. 4 Predicted vs measured CHF by the Kwon-Chang Model

델보다 좋은 예측성능을 보여 주었으며 3069 데이터의 90%를 오차범위 $\pm 30\%$ 내에서 예측하였다. 따라서 이 모델은 HMSD 영역의 열수력 변수를 계산하는 상관식을 개선할 필요가 있다.

2063 데이터를 사용하여 훈련된 BPN 을 가지고 학습훈련에 전혀 사용되지 않은 306 데이터에 적용한 시험결과, $\mu = 1.02$, $RMS = 12.3\%$, $\sigma = 12.0\%$ 의 좋은 통계치를 얻었다. 이렇게 작은 오차는 BPN 이 성공적으로 훈련되었으며 여기서 개발된 BPN 적용절차가 CHF 예측에 사용될 수 있음을 입증한다. 전체 3069 데이터에 대한 예측결과가 그림 5에 표시되어 있다.

Groeneveld et al. 이⁽¹⁰⁾ 개발한 CHF look-up table 의 적용범위에 포함되는 1575 데이터에 대한 평가결과가 표 3에 제시되어 있다. Look-up table 은 유량이 $8 \text{ Mg/m}^2\text{s}$ 를 초과하면 적용할 수 없으므로 HMSD 영역에는 적용할 수 없다. 튜브 직경이 8 mm 가 아닌 튜브에 대해서는 수정계수를 사용하였다. Normal 영역의 1575 CHF 데이터에 대해 $\mu = 0.99$, $RMS = 17.4\%$, $\sigma = 17.3\%$ 의 좋은 성능을 보였다.

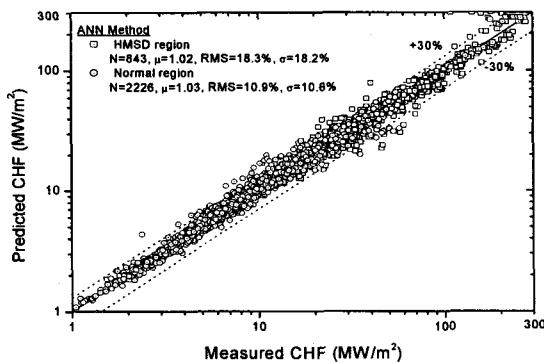


Fig. 5 Predicted vs measured CHF by the ANN

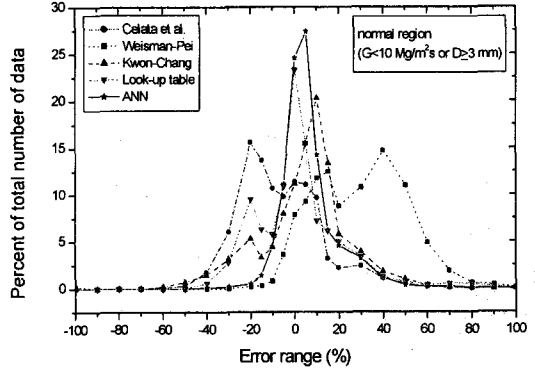


Fig. 6 Comparison of error distribution (normal region)




Fig. 7 Comparison of error distribution (HMSD region)

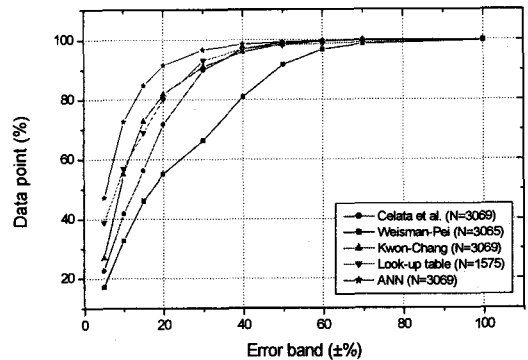


Fig. 8 Comparison of prediction performance of various CHF prediction methods

다.

HMSD 와 normal 영역에 대해 여러 CHF 예측방법의 평가결과를 그림 6 과 그림 7 에 각각 나타내었다. 여기서 고려한 5 가지 예측방법 중 ANN 이 HMSD 및 normal 모든 영역에 대해 가장 좋은 성능을 보였다. 이론모델의 경우 HMSD 영역에서는 Celata et al. 과 Kwon-Chang 모델이 비교적 양호한 예측성능을 보였으며, normal 영역의 경우는

Kwon-Chang 모델이 가장 우수하였다. ANN 방법으로 예측된 CHF가 실험데이터와 잘 일치할 뿐 아니라 기존의 CHF 이론모델보다 더 좋은 예측성능을 보여주는 것은 흥미로운 사실이다. 그림 8은 열유속이 1 MW/m² 이상 되는 전체 서브콜비딩 CHF 데이터 베이스에 대한 각 예측방법의 성능을 평가한 결과이다. 그림에 나타난 N은 각 방법을 사용하여 계산에서 성공적으로 수렴된 데이터 수이다. ANN 방법은 총 CHF 데이터의 91.5%를 오차범위 ±20% 내에서 성공적으로 예측하고 있다.

중요한 변수들에 대한 예측 정확도의 의존성을 조사한 결과, ANN은 특정한 열수력 조건이나 기하학적 변수들의 영향을 심각하게 받지 않음을 알 수 있었다. 또한 고 유속과 작은 튜브직경에 대한 CHF 실험에서 밝혀진 이들 변수의 영향을 조사한 결과, normal 영역에서는 ANN으로 예측한 CHF가 실험데이터와 비교적 잘 일치하는 반면에 HMSD 영역 중에서도 매우 작은 직경이나 고 유속 조건에서는 데이터의 분산 정도가 심하였다.

5. 결론

ANN을 이용하여 서브콜비딩의 고열유속 CHF를 예측할 수 있는 방법을 개발하여 예측성능 측면에서 기존의 이론모델 및 look-up table 방법과 비교 평가하였다. 본 연구를 위해 10개의 참고문헌으로부터 총 3069 CHF 실험데이터를 선택하였으며 각 변수의 영역은 다음과 같다: $0.33 \leq D \leq 37.5$ mm, $0.002 \leq L \leq 4$ m, $0.37 \leq G \leq 134$ Mg/m²s, $0.1 \leq P \leq 20$ MPa, $50 \leq \Delta h_{sub,in} \leq 1660$ kJ/kg, $1.1 \leq q_{CHF} \leq 276$ MW/m².

ANN 방법은 총 CHF 데이터의 91.5%를 오차범위 ±20% 내에서 실험값과 일치하게 예측하였을 뿐 아니라 기존의 CHF 이론모델들보다 더 좋은 예측성능을 나타내었다.

후 기

본 연구는 과학기술부 원자력 중장기 과제의 지원으로 수행하였습니다.

참고문헌

- (1) Kwon, Y. M. and Chang, S. H., A Procedure to Predict Subcooled-Water-Flow-Boiling CHF in Uniformly Heated Tubes for High-Heat-Flux Applications, Nucl. Tech., Vol.130 (2000).
- (2) Celata, G. P. et al., Rationalization of Existing

- Mechanistic Models for the Prediction of Water Subcooled Flow Boiling Critical Heat Flux, Int. J. Heat Mass Transfer, Vol.37 (1994), pp.347-360.
- (3) Weisman, J. and Pei, B. S., Prediction of Critical Heat Flux in Flow Boiling at Low Qualities, Int. J. Heat Mass Transfer, Vol.26 (1983), pp.1463-1477.
- (4) Kwon, Y. M. and Chang, S. H., A Mechanistic Critical Heat Flux Model for Wide Range of Subcooled and Low Quality Flow Boiling, Nucl. Eng. Des., Vol.188 (1999), pp.27-47.
- (5) Yapo, T. et al., Prediction of Critical Heat Fluxes Using a Hybrid Kohonen-Backpropagation Neural Networks, Topics in Intelligent Engineering Systems Through ANNs, Vol.2, ed. Dali, C. H. et al. (1992).
- (6) Moon, S. K., Baek, W. P., and Chang, S. H., Parametric Trends Analysis of the Critical Heat Flux Based on Artificial Neural Networks, Nucl. Eng. Des., Vol.163 (1996), pp.29-49.
- (7) Bergles, A. E. et al., Critical Heat Flux and Flow Pattern Observations for Low Pressure Water Flowing in Tubes, J. Heat Transfer, Vol.69 (1967).
- (8) Nariai, H. and Inasaka, F., Critical Heat Flux and Flow Characteristics of Subcooled Flow Boiling with Water in Narrow Tubes, ed. Jones, O.C. and Michiyoshi, I., Dynamics of Two-Phase Flows, CRC Press (1992), pp.689-708.
- (9) Mudawar, I. and Bowers, M. B., Ultra-High Critical Heat Flux (CHF) for Subcooled Water Flow Boiling - I: CHF Data and Parametric Effects for Small Diameter Tubes, Int. J. Heat Mass Transfer, Vol.42, (1999), pp.1405-1428.
- (10) Groeneveld, D. C. et al., The 1995 Look-up Table for Critical Heat Flux in Tubes, Nucl. Eng. Des., Vol. 163 (1996), pp.1-23.