

누설 인덕턴스를 포함한 DAB 컨버터용 고주파 변압기의 머신러닝 활용한 최적 설계

노은총¹, 김길동², 이승환[†]

Machine-Learning Based Optimal Design of A Large-leakage High-frequency Transformer for DAB Converters

Eunchong Noh¹, Kildong Kim², and Seung-Hwan Lee[†]

Abstract

This study proposes an optimal design process for a high-frequency transformer that has a large leakage inductance for dual-active-bridge converters. Notably, conventional design processes have large errors in designing leakage transformers because mathematically modeling the leakage inductance of such transformers is difficult. In this work, the geometric parameters of a shell-type transformer are identified, and finite element analysis (FEA) simulation is performed to determine the magnetization inductance, leakage inductance, and copper loss of various shapes of shell-type transformers. Regression models for magnetization and leakage inductances and copper loss are established using the simulation results and the machine learning technique. In addition, to improve the regression models' performance, the regression models are tuned by adding featured parameters that consider the physical characteristics of the transformer. With the regression models, optimal high-frequency transformer designs and the Pareto front (in terms of volume and loss) are determined using NSGA-II. In the Pareto front, a desirable optimal design is selected and verified by FEA simulation and experimentation. The simulated and measured leakage inductances of the selected design match well, and this result shows the validity of the proposed design process.

Key words: Multi-objective optimization, High-frequency transformer, Machine learning, DAB (Dual-Active-Bridge) converter

1. 서 론

Dual active bridge (DAB) 컨버터는 양방향 전력 전달이 가능하고 구조가 간단한 장점으로 최근 전기 자동차, 태양광 발전 시스템 등에서 널리 사용되고 있다^{[1]-[4]}. DAB는 회로에 포함된 직렬 인덕턴스를 이용하여 전력

을 전달하기 때문에, 변압기의 누설 인덕턴스를 이용하거나 별도의 인덕터를 설치해야 한다. 변압기의 누설 인덕턴스를 이용하는 경우 별도의 인덕터를 이용하는 경우보다 부피나 가격 면에서 유리해 많은 연구가 진행되고 있다^{[5]-[7]}. 하지만 큰 누설 인덕턴스 값을 갖는 변압기는 효율이 낮아질 수 있어 설계에 주의가 필요하다. 따라서 DAB 용 고주파 변압기 설계는 효율과 누설 인덕턴스를 동시에 고려하는 것이 바람직하다.

고주파 변압기 설계에서는 높은 주파수에 따른 표피 효과 (skin effect)나 근점 효과 (proximity effect)로 인한 권선의 유효 단면적 감소가 반영되어야 한다. Dowell's equation은 이를 반영한 방정식이며 식 (1)과 같다^[8]. 이때 m 은 권선의 레이어 개수이다.

$$\frac{R_{ac}}{R_{dc}} = \frac{\Delta}{2} \cdot \left\{ G_1(\Delta) + \frac{(m^2 - 1)}{3} G_2(\Delta) \right\} \quad (1)$$

Paper number: TKPE-2022-27-6-7

Print ISSN: 1229-2214 Online ISSN: 2288-6281

[†] Corresponding author: seunghlee16@uos.ac.kr, Dept. of Electrical & Computer Engineering, University of Seoul, Korea

Tel: +82-2-6490-2350

¹ Dept. of Electrical & Computer Engineering, University of Seoul, Korea

² Korea Railroad Research Institute (KRII)

Manuscript received Aug. 5, 2022; revised Aug. 24, 2022; accepted Sep. 19, 2022

TABLE I
TRANSFORMER SHAPE PARAMETER LIST

Parameters	Description
N_1	Primary side number of turns
N_2	Secondary side number of turns
w_1	Core geometry parameter(see Fig 1)
l_1	Core geometry parameter(see Fig 1)
l_2	Core geometry parameter(see Fig 1)
h_1	Core geometry parameter(see Fig 1)
μ_{per}	Ferrite core relative permeability
$space_1$	Winding interval parameter(see Fig 2 ①)
$space_2$	Winding interval parameter(see Fig 2 ②)
$space_3$	Winding interval parameter(see Fig 2 ③)
$space_4$	Winding interval parameter(see Fig 2 ④)
$space_5$	Winding interval parameter(see Fig 2 ⑤)
$space_6$	Winding interval parameter(see Fig 2 ⑥)
d_1	Primary side winding diameter
d_2	Secondary side winding diameter
$movez_1$	Pri. side height direction winding interval
$movez_2$	Sec. side height direction winding interval
$offsetz_1$	Pri. side height direction winding offset
$offsetz_2$	Sec. side height direction winding offset

식 (1)에서 $G_1(\Delta)$ 과 $G_2(\Delta)$ 는 각각 표피 효과와 근접 효과 성분이며 각각 식 (2), (3)과 같다. 이때 Δ 는 porosity factor와 표피 깊이(skin depth)를 일반화한 값이다.

$$G_1(\Delta) = \frac{\sinh(\Delta) + \cos(\Delta)}{\cosh(\Delta) - \cos(\Delta)} \quad (2)$$

$$G_2(\Delta) = \frac{\sinh(\Delta) - \cos(\Delta)}{\cosh(\Delta) + \cos(\Delta)} \quad (3)$$

Dowell's equation은 고주파 변압기의 권선을 포일 형태로 치환한 후 1차원 직선상의 자기장을 계산하는 방식으로 비교적 간단하고 정확하게 AC 저항을 계산할 수 있다. 같은 가정으로 직선상의 자기장 값을 적분하여 식 (4)와 같이 누설 인덕턴스를 계산할 수 있다. 식 4에서 E는 자기에너지, L은 누설 인덕턴스, I는 권선 전류이다.

$$E_{mag} = LI^2 \quad (4)$$

그러나 3차원의 형상을 1차원으로 단순화하여 계산하기 때문에 변압기의 porosity factor가 낮거나, 1차 측 권선과 2차 측 권선의 높이가 달라 비대칭이 발생한 경우에는 AC 저항과 누설 인덕턴스의 계산 정확도가 떨어지게 된다. 특히 고주파 변압기의 누설 인덕턴스 확보를 위해 1차 측과 2차 측 권선을 높이 방향으로 이격시키




Fig. 1. Transformer core modeling parameter




Fig. 2. Transformer winding modeling parameter

는 경우에는 AC 저항과 누설 인덕턴스의 계산 정확도가 크게 떨어지게 되는 문제가 존재한다. 이러한 누설 인덕턴스를 구하는 수식의 정확도 문제는 누설을 고려한 고주파 변압기 최적 설계를 어렵게 만든다.

Mogorovic 등은 수식 모델 기반으로 손실 및 누설 인덕턴스를 계산하여 100kW급 10kHz 고주파 변압기를 최적 설계 하였다. 하지만 해당 논문의 누설 인덕턴스 계산 수식은 특정한 형상에서만 누설 인덕턴스를 정확하게 계산할 수 있어 설계 경우의 수가 제한되는 단점이 존재한다^[9].

본 논문은 Dowell's equation의 형상에 따른 정확도 문제를 극복하기 위해 다수의 finite element analysis(FEA)를 통한 데이터의 수집과 수집된 데이터를 이용한 머신러닝 회귀 모델 학습, 유전 알고리즘을 이용한 DAB 용 고주파 변압기 최적 설계 방법을 제안한다. 회귀 모델 학습을 위하여 1만 개의 FEA 시뮬레이션 결과를 만들었으며, 이 데이터를 이용하여 회귀 모델을 학습하였다. 또한 회귀 모델의 파라미터 추론 성능을 향상시키기 위해 모델 튜닝을 진행하였다. 최종적인 최적 설계는 학습된 회귀 모델과 기존 변압기 관련 수식을 이용하여 유전 알고리즘을 이용하여 진행하였다. 설계된 고주파 변압기는 다시 FEA 시뮬레이션을 이용하여 검증하였다. 마지막으로 실험을 통해 실제 변압기 누설 인덕턴스 측정 결과와 동일 형상 변압기의 FEA 시뮬레이션 결과를 비교하여 회귀 모델 학습에 FEA 시뮬레이션을 이용한 해당 논문의 타당성을 확인하였다.

2. 변압기 시뮬레이션 및 회귀모델 학습

2.1 변압기 파라미터화

회귀모델 학습을 위해서는 데이터가 다량 필요하다. 그러나 이 데이터를 실제 변압기의 제작 및 측정을 통해 얻을 경우 시간적 금전적 비용이 과도하게 소비된다. 따라서 본 논문에서는 회귀모델의 학습 데이터를 수식 모델에 비해 상대적으로 높은 정확도를 갖는 FEA 시뮬레이션을 통하여 습득하였다. 학습 데이터 각각은 서로 다른 변압기여야 하므로, 임의의 변압기 모델을 손쉽게 생성하고, 효율적인 학습을 위해 변압기의 특성을 반영해 간략화하여 파라미터화 하였다. 본 논문에서는 이를 형상 파라미터라고 지칭한다. 형상 파라미터의 개수는 19개이며 표 1과 같다. 표 1의 파라미터 변동 범위는 목표하는 스펙의 변압기를 충분히 포함하면서 너무 넓은 범위를 갖지 않게 설정하였다. 그림 1과 그림 2에는 표 1의 일부 형상 파라미터에 대한 설명이 나타나 있다.

그림 3은 코어와 권선 형상을 표 1의 형상 파라미터를 이용하여 파라미터화 한 타겟 셸타입 고주파 변압기 모델이다. 파라미터화 된 모델은 형상 파라미터를 변경하면 변압기의 형상을 손쉽게 바꿀 수 있다. 이를 이용하여 랜덤으로 임의의 범위 내에서 각각의 형상 파라미터를 생성하고, 생성한 형상 파라미터로 변압기 형상 모델을 생성한 후 시뮬레이션하여 결과를 수집하는 스크립트를 작성하였다. 해당 스크립트를 이용해 랜덤한 형상의 셸타입 고주파 변압기 모델링 및 해석했다. 시뮬레이션 데이터의 수에 따라 데이터 확보 시간과 학습된 모델의 성능이 달라지기 때문에 두 요소를 절충한 약 1만 개의 고주파 변압기 시뮬레이션을 진행하였다. 시뮬레이션은 ANSYS 사의 해석 툴인 MAXWELL을 이용해 고주파 변압기의 타겟 주파수인 40kHz 동작에 대해 해석을 진행했으며, 적절한 수준의 해석 정확도와 해석 속도를 모두 만족하기 위해 energy error가 3% 미만이면 추가적인 meshing 및 해석을 중지하도록 설정하였다. 시뮬레이션을 통해 얻은 결과값은 1차 측과 2차 측의 자화 인덕턴스, 누설 인덕턴스, 권선 저항이다.

2.2 회귀모델 학습

2.1에서 얻어진 시뮬레이션 데이터를 이용하여 회귀모델 학습을 진행하였다. 회귀모델의 학습 알고리즘은 의사 결정 트리(decision tree) 모델 중 하나인 LightGBM(light gradient boosting machine) 알고리즘을 사용하였다. 회귀모델은 1차 측과 2차 측의 자화 인덕턴스, 누설 인덕턴스, 권선 저항 총 6개 파라미터를 각각 학습하였다. 트레인 셋(training set) 과 테스트 셋(test set) 은 학습 데이터 확보와 적절한 성능 평가를 위해 8:2로 분할 하였으며 트레인 셋으로 학습한 후 학습에 영향을 주지 않은 독립적인 데이터 셋인 테스트 셋으로 추론 성능을 검증하였다.




Fig. 3. Target transformer model

TABLE II
HYPER PARAMETER LIST

Hyper parameter	Value
n_estimator	2000
learning rate	0.025
num_leaves	31

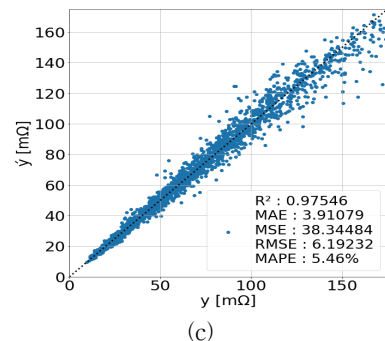
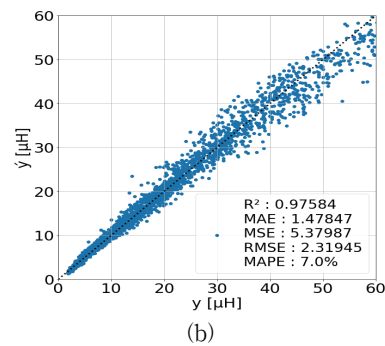



Fig. 4. Primary-side regression model validation result (a) magnetizing inductance (b) leakage inductance (c) winding resistance

TABLE III
REGRESSION MODEL PERFORMANCE

Parameter	R ²	MAE	RMSE	MAPE
L_{mp}	0.9913	0.2225	0.4554	5.77%
L_{ms}	0.9932	0.2096	0.3913	6.27%
L_{tp}	0.9758	1.4785	2.3195	7.00%
L_{ts}	0.9756	1.4513	2.3037	6.91%
R_p	0.9755	3.9108	6.1923	5.46%
R_s	0.9750	4.2328	6.4285	5.86%

회귀 모델에는 학습을 통해 설정되는 파라미터가 아닌 사용자가 직접 설정하는 하이퍼 파라미터 값이 존재하며, 같은 데이터를 이용했다 하더라도 하이퍼 파라미터 값에 따라 모델의 성능이 달라질 수 있다. 따라서 모델이 고성능을 갖게 하는 하이퍼 파라미터 값 설정이 필요하다. 표 2는 학습에 사용한 하이퍼 파라미터값이며, 표 2에 명시되지 않은 나머지 하이퍼 파라미터값은 디폴트로 설정하였다. 각 파라미터는 해당 파라미터를 변경시켰을 때 더 이상 유의미한 성능 향상이 나타나지 않는 값을 선정하였다.

그림 4 (a), (b), (c)는 1차 측 자화 인덕턴스, 누설 인덕턴스, 권선 저항 모델을 테스트 셋으로 검증한 결과이다. 각각 그림에서 x축은 시뮬레이션을 통해 얻은 데이터, y축은 동일 파라미터를 회귀 모델로 추론했을 때 나온 추론 값이다. 따라서 $y=x$ 축 선상에 데이터가 밀집해 있을 경우 추론의 정확도가 높다고 볼 수 있다.

표 3은 주어진 데이터를 이용해서 학습해서 얻은 각각 모델의 성능을 나타낸 것이다. R², MAE, RMSE, MAPE는 회귀 모델의 성능지표이며 각각의 정의는 식 (5), (6), (7), (8), (9)과 같다.

$$(R^2) = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$


$$(MAE) = \sum_{i=1}^n (\hat{y}_i - y_i) / n \quad (6)$$

$$(MSE) = \sum_{i=1}^n (\hat{y}_i - y_i)^2 / n \quad (7)$$


$$(RMSE) = \sqrt{\sum_{i=1}^n (\hat{y}_i - y_i)^2 / n} \quad (8)$$

$$(MAPE) = \sum_{i=1}^n \left(\frac{\hat{y}_i - y_i}{y_i} \right) / n \quad (9)$$


R² 값이 1에 가까울수록 예측 정확도가 높으며, MAE, RMSE, MAPE 값이 작을수록 실제 값과 추론 값의 오



(a)



(b)



(c)

Fig. 5. Primary-side regression model validation result (a) magnetizing inductance (b) leakage inductance (c) winding resistance after adding featured parameter

차가 작아진다. 성능 평가 결과 R²값이 0.99 이상인 자화 인덕턴스 학습 결과에 비해 누설 인덕턴스와 권선 저항의 성능이 낮게 나타나는데, 이는 권선 턴수와 코어 형상에만 크게 영향을 받는 자화 인덕턴스와 달리 누설 인덕턴스와 권선 저항은 권선 간격과 위치 등에 추가적으로 영향을 받기 때문이다.

2.3 추가 파라미터를 이용한 성능 향상

회귀 모델은 독립변수로 종속변수를 예측할 수 있는 모델이며, 본 논문의 경우 독립변수는 형상 파라미터이고 종속변수는 자화 인덕턴스, 누설 인덕턴스, 권선 저항이다. 이때, 독립변수에 해당하는 형상 파라미터들을 조합

TABLE IV
REGRESSION MODEL PERFORMANCE WITH TUNING

Parameter	R ²	MAE	RMSE	MAPE
L_{mp}	0.9933	0.1765	0.4000	4.65%
L_{ms}	0.9948	0.1765	0.3425	4.87%
L_{tp}	0.9861	1.1356	1.7581	5.52%
L_{ts}	0.9863	1.1036	1.7248	5.45%
R_p	0.9859	3.1618	4.9615	4.55%
R_s	0.9835	3.4462	5.2720	4.81%

TABLE V
TRANSFORMER DESIGN PARAMETER

Parameter	Value
Primary side voltage	1400V
Secondary side voltage	537V
Power rate	2kW
Operating frequency	40kHz
Desired leakage inductance	20μH
Ferrite core relative permeability	3200

하여 변압기의 물리적인 특성을 더 잘 반영하는 새로운 파라미터를 추가해주면 같은 수의 데이터를 이용했을 때 성능을 더 향상할 수 있다^[10]. 따라서 성능 향상을 위해 형상 파라미터를 조합한 추가 파라미터를 일부 추가하여 성능 향상을 시도하였다.

그림 5 (a)는 자화 인덕턴스 모델을 형상 파라미터를 조합하여 새로운 파라미터를 추가한 후 다시 학습하여 검증한 결과이다. 추가한 파라미터는 식 (10), (11), (12)에 나타나 있으며 각각 자화 인덕턴스 결정에 영향을 미치는 턴 수의 제곱, 변압기 코어의 단면적, 변압기 코어의 부피이다.

$$N_{1s} = N_1^2, \quad N_{2s} = N_2^2 \quad (10)$$

$$area = 2l_1w_1 \quad (11)$$

$$volume = (4l_1 + 2l_2)(w_1)(2l_1 + h_1) - 2l_2w_1h_1 \quad (12)$$

그림 5 (b)는 누설 인덕턴스의 경우이며 추가한 파라미터는 식 (13)에 나타나 있다. 해당 파라미터는 누설 인덕턴스 확보를 위해 1차 측과 2차 측 권선을 높이 방향으로 이격시킨 거리를 의미한다.

$$offset = abs(offsetz_1 - offsetz_2) \quad (13)$$

그림 5 (c)는 권선 저항의 경우이며, 추가한 파라미터는 식 (14), (15) 및 식 (1)의 Dowell's equation이다. 식

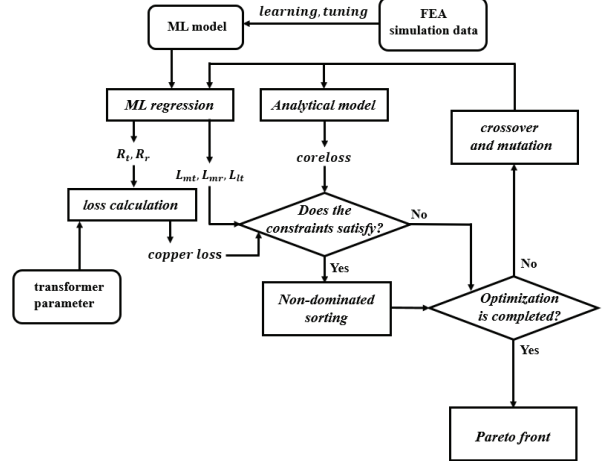


Fig. 6. Overall design process

(14)와 식 (15)는 각각 1차 측과 2차 측의 총 권선의 길이를 의미한다.

$$N_1(2w_1 + 4l_1 + 4d_1 + 2space1 + 2space2 + 4space5) \quad (14)$$

$$N_2(2w_1 + 4l_1 + 8d_1 + 4d_2 + 2space1 + 2space2 + 2space3 + 2space4 + 4space5 + 4space6) \quad (15)$$

표 4는 파라미터 추가 후 각 모델의 성능을 나타낸 것이다. 표 3과 비교하였을 때 파라미터 추가 후 모든 모델의 R² 값이 소폭 상승하였으며 MAE와 RMSE가 약 20~25%가량 감소하여 유의미한 성능 향상을 보여주었다.

3. NSGA-II를 이용한 최적 설계

학습한 회귀 모델과 기존 수식 모델을 이용하여 고주파 변압기의 최적화 설계를 진행하였다. 최적 설계 탐색 알고리즘은 다변수 최적화(multi-objective optimization) 알고리즘의 일종인 NSGA-II(non-dominated sorting genetic algorithm-II)를 이용하였다. NSGA-II는 유전 알고리즘의 일종이며 비 지배적 정렬을 트레이드오프 관계를 갖는 여러 설계를 파레토 곡선의 형태로 얻을 수 있다. 그림 6에는 회귀 모델과 NSGA-II를 이용한 최적 설계 절차가 나타나 있다. 본 논문에서는 설계 결과가 부피와 총손실에 대한 트레이드오프 관계를 갖도록 설정하였다. 해당 논문에서 고주파 변압기의 철손은 회귀 모델로 추론한 자화 인덕턴스값을 토대로 Steinmetz's equation을 이용하여 계산하였다.

$$P_v = \frac{1}{T} \cdot \int_0^T \left| \frac{dB(t)}{dt} \right|^a (\Delta B)^{a-b} dt \quad [kW/m^3] \quad (16)$$

식 (16)은 improved generalized Steinmetz's

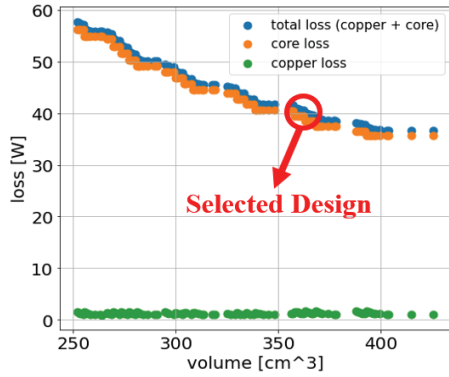


Fig. 7. Optimization result Pareto front




Fig. 8. Leakage inductance of each design

equation(IGSE)이며 정현과 전압을 가정하 기존 Steinmetz's equation과 달리 DAB처럼 구형 파 전압이 인가되는 경우에도 사용 가능하다^{[11]-[12]}. 이때, Steinmetz's equation 또는 IGSE로 구한 값은 코어의 단위부피당 철손이기 때문에 코어의 부피를 곱하면 고주파 변압기의 철손을 계산할 수 있다. 동손의 경우 회귀 모델로 추론하여 구한 1차 측과 2차 측 권선 저항과 표 5에서 정해지는 정격 RMS 전류를 이용하여 계산하였으며, 누설 인덕턴스도 마찬가지로 회귀 모델로 추론하여 계산하였다.

NSGA-II에서는 제약조건을 설정할 수 있으며 모든 제약조건을 만족하는 설계만 유효한 설계로 선택된다. 본 논문에서는 제약조건으로 먼저 표 5의 1차 측과 2차 측의 전압 비를 만족하는 자화 인덕턴스 비, 절연을 위한 일정 거리 확보, 목표하는 누설 인덕턴스값, 변압기 포화를 방지하기 위한 자속밀도 상한을 제약조건으로 설정하였다.

NSGA-II 알고리즘은 적절한 개수의 설계 후보군을 얻기 위해 population size를 100으로 설정하였으며, 빠른 수렴을 위해 한 세대당 offspring number를 1000으로 설정하였다. 또한 local minima를 방지하면서도 적절한 수렴 속도를 갖게 하기 위해 crossover와 mutation 비율을 8:2로 설정하였다. 설계 탐색은 충분히 수렴이 된다고 판단되는 1000세대 까지 진행하였다.

TABLE VI
SELECTED DESIGN PARAMETERS

Parameters	Value	Parameters	Value
N_1	20 turns	$space_4$	1mm
N_2	8 turns	$space_5$	1mm
w_1	56mm	$space_6$	1mm
l_1	10mm	d_1	0.6mm
l_2	15mm	d_2	1.9mm
h_1	35mm	$movez_1$	2mm
per	3200	$movez_2$	1.5mm
$space_1$	2mm	$offsetz_1$	0mm
$space_2$	3mm	$offsetz_2$	1mm
$space_3$	1mm		

TABLE VII
COMPARISON OF INFERRED AND SIMULATED PARAMETER RESULT

Parameter	Regression	FEA	Error
L_{mp}	14.57mH	14.91mH	2.33%
L_{ms}	2.44mH	2.39mH	2.05%
L_{lp}	20.18μH	19.04μH	5.65%
Primary side winding loss	0.631W	0.683W	8.24%
Secondary side winding loss	1.422W	1.344W	5.49%
core loss	37.64W	36.78W	2.34%

TABLE VIII
COMPARISON OF MEASURED & SIMULATED LEAKAGE INDUCTANCE OF A SMALL-SCALE TRANSFORMER

Parameter	FEA	Measurement	Error
L_{lp}	4.535μH	4.529μH	1.48%
L_{ls}	8.081μH	8.071μH	1.11%

그림 7은 NSGA-II를 이용한 설계 결과이다. 그림 7의 점들 각각은 하나의 고주파 변압기 설계를 의미하며, 설계 탐색 과정에서 트레이드 오프 관계를 갖지 않는 설계를 배제하는 비지배적 정렬을 수행하였기 때문에 각각의 설계들이 부피-손실에 대한 트레이드오프 관계를 갖는 파레토 곡선 형태를 갖는 것을 확인할 수 있다. 따라서 설계자는 해당 파레토 곡선에서 여러 설계 중어 플리케이션에 적합한 성능을 갖는 설계를 선택할 수 있다. 그림 7에서 해당 논문 조건의 설계 결과는 전체 손실의 대부분을 철손이 차지하고 있음을 보여준다. 이는 변압기의 전류가 5A 이하로 매우 낮고, 철손을 감소시키기 위해 권선 턴수를 증가시킬 경우 목표하는 누설 인덕턴스를 초과하기 때문이다. 따라서 누설 인덕턴스를 고려한 설계를 진행할 경우 설계 파라미터에 따라 최고




Fig. 9. Simulation model and photo of small-scale transformer (a) FEA model (b) constructed transformer

효율을 갖는 동손과 철손 비율은 달라질 수 있다. 그림 8은 각 설계 결과의 누설 인덕턴스 값이며 제약조건으로 설정해 준 $20\mu\text{H}$ 를 모든 설계가 만족함을 확인할 수 있다. 이러한 방식으로 제약조건으로 임의의 누설인덕턴스를 설정해주면, 해당 누설 인덕턴스를 만족하는 고주파변압기 부피-손실 최적 설계가 가능하다.

4. 설계된 고주파 변압기의 검증

선정된 설계 각각의 파라미터는 회귀 모델로 추론한 값이기 때문에 모델 검증을 위해 FEA 시뮬레이션 결과와 비교하였다. 표 6은 그림 7에서 선정된 설계의 형상 파라미터이다. 선정된 설계는 Pareto-front 상의 설계 중 고효율을 보이면서 부피가 과도하게 커지지 않은 설계를 선택하였다. 표 7은 표 6의 형상 파라미터를 이용한 설계의 FEA 시뮬레이션 결과와 같은 형상 파라미터를 독립변수로 넣어 회귀 모델로 계산한 값을 비교한 결과이다. 각각의 파라미터는 회귀 모델로 추정된 결과와 FEA 시뮬레이션 결과가 2% - 8% 정도의 오차를 가지며 일치함을 확인할 수 있다.

다음으로 본 논문에서는 FEA 시뮬레이션을 통해 얻은 데이터를 바탕으로 회귀 모델 학습을 진행하였으므로 학습에 사용된 FEA 시뮬레이션 결과가 실제 결과와 유사하여야 모델이 타당성을 가질 수 있다. 이 연구에서는 표 6에서 설계된 full-scale 변압기를 제작할 수 없어, 그림 9(a)와 같은 small-scale의 쉘타입 변압기에 대해 FEA 해석을 진행해 누설 인덕턴스를 구하고, 이를 그림 9(b)와 같이 실제 제작하여 누설 인덕턴스를 측정하여 FEA 해석 결과의 신뢰성을 검증하였다. 즉, 이 small-scale 변압기의 누설 인덕턴스 측정값과 FEA 시뮬레이션 결과값을 비교해 FEA 결과의 신뢰성을 검증했다. 누설 인덕턴스의 측정은 네트워크 어널라이저를 이용하였으며, 사용한 기종은 Keysight의 E5061B이다. 측정 결과는 표 8에 나타냈으며, 표에서 볼 수 있는 것처럼 누설 인덕턴스는 측정된 값과 시뮬레이션 결과와 2% 이내의 오차를 가지며 매우 높은 정합성을 가지는 것을 볼 수 있었다.

5. 결론

본 논문에서는 고주파 변압기의 자화 인덕턴스, 누설 인덕턴스, 권선 저항의 추정을 위해 FEA 시뮬레이션 데이터 기반 회귀 모델을 학습하고, 이를 이용하여 누설 인덕턴스를 고려한 부피-손실 최적화 설계를 진행하였다. 그리고 FEA를 이용하여 모델의 정확성을 검증한 후 누설 인덕턴스 추정을 통하여 FEA 시뮬레이션 결과의 타당성을 검증하였다. 제안한 방법은 1차 측과 2차 측의 높이가 다르거나 1차 측과 2차 측이 누설 인덕턴스 확보를 위해 높이 방향으로 이격되어 있는 형태 등 수직 모델의 오차가 존재하는 형상에 대해서도 누설 인덕턴스를 고려한 설계가 가능하다. 따라서 누설 인덕턴스가 고려되어야 하는 DAB 용 고주파 변압기 설계의 경우, 더 성능적으로 유리할 가능성이 있는 다양한 형상에 대한 설계 및 최적화가 가능하다.

본 연구는 한국철도기술연구원 주요사업 (PK2203F1)의 연구비 지원으로 수행되었습니다.

References

- [1] D. Das, N. Weise, K. Basu, R. Baranwal and N. Mohan, "A bidirectional soft-switched DAB-based single-stage three-phase AC-DC converter for V2G application," in *IEEE Transactions on Transportation Electrification*, Vol. 5, No. 1, pp. 186-199, March 2019.
- [2] S. Kurm and V. Agarwal, "Dual active bridge based reduced stage multiport DC/AC converter for PV-battery systems," in *IEEE Transactions on Industry Applications*, Vol. 58, No. 2, pp. 2341-2351, March-April 2022.
- [3] Y. Shi, R. Li, Y. Xue and H. Li, "Optimized operation of current-fed dual active bridge DC-DC converter for PV applications," in *IEEE Transactions on Industrial Electronics*, Vol. 62, No. 11, pp. 6986-6995, Nov. 2015.
- [4] T. Liu et al., "High-efficiency control strategy for 10-kV/1-MW solid-state transformer in PV application," in *IEEE Transactions on Power Electronics*, Vol. 35, No. 11, pp. 11770-11782, Nov. 2020.
- [5] Y. Park, S. Chakraborty and A. Khaligh, "DAB converter for EV onboard chargers using bare-die SiC MOSFETs and leakage-integrated planar transformer," in *IEEE Transactions on Transportation Electrification*, Vol. 8, No. 1, pp. 209-224, March 2022.
- [6] E. S. Lee, J. H. Park, M. Y. Kim and S. H. Han, "An integrated transformer design with a center-core air-gap for DAB converters," in *IEEE Access*, Vol. 9, pp. 121263-121278, 2021.
- [7] A. Jafari, M. S. Nikoo, F. Karakaya and E. Matioli,

"Enhanced DAB for efficiency preservation using adjustable-tap high-frequency transformer," in IEEE Transactions on Power Electronics, Vol. 35, No. 7, pp. 6673-6677, July 2020.

- [8] P. L. Dowell, "Effects of eddy currents in transformer windings," Proc. Inst. Electr. Eng., Vol. 113, No. 8, pp. 1387 - 1394, Aug. 1966. Supervised Machine Learning : A Review of Classification Techniques
- [9] M. Mogorovic and D. Dujic, "100 kW, 10 kHz medium-frequency transformer design optimization and experimental verification," in IEEE Transactions on Power Electronics, Vol. 34, No. 2, pp. 1696-1708, Feb. 2019.
- [10] Supervised Machine Learning : A Review of Classification Techniques
- [11] Chas., Proteus, Steinmetz, "On the loss of hysteresis," Proc. of the IEEE Vol.72, No. 2, pp. 197-221, Feb. 1984.
- [12] K. Venkatachalam, C. R. Sullivan, T. Abdallah and H. Tacca, "Accurate prediction of ferrite core loss with nonsinusoidal waveforms using only Steinmetz parameters," 2002 IEEE Workshop on Computers in Power Electronics, 2002. Proceedings., 2002, pp. 36-41.



노은총(盧恩寵)

2020년 서울시립대 전자전기컴퓨터공학부 졸업. 2022년 서울시립대 전자전기컴퓨터공학과 졸업 (석사). 2022년~현재 서울시립대 전자전기컴퓨터공학과 박사과정 재학 중



김길동(金吉童)

1986년 명지대 전기공학과 졸업. 1991년 명지대 전기공학과 졸업. 2003년 명지대 전기공학과 졸업(공학). 1995년~현재 한국철도기술연구원 스마트전기신호 본부 추진시스템연구실 수석연구원.



이승환(李承桓)

2004년 서울대 공과대학 기계항공공학부 & 전기전자컴퓨터공학부 졸업. 2008년 8월 동대학원 전기전자컴퓨터공학부 졸업 (석사), 2013년 8월 미국 위스콘신 주립대 기계공학과(WEMPEC) 졸업(공학), 2013년 9월~2016년 2월 한국철도기술연구원 선임연구원, 2016년 3월~현재 서울시립대 전자전기컴퓨터공학부 부교수. 당 학회 국제이사.