

적응 뉴로퍼지 추론기법에 의한 SRM의 토크모델 (Adaptive Neuro-Fuzzy Inference based Torque Model of SRM)

홍정표^{*1} · 박성준² · 홍순일³ · 김철우¹

(Jeng-Pyo Hong · Sung-Jun Park · Soon-Il Hong · Cheul-U Kim)

부산대학교¹ · 거제대학² · 부경대학교³

Abstract

Although the switched reluctance motor (SRM) has a several advantages such as simple magnetic structure, robustness, wide range of speed characteristics and simple driving, it has a considerable inherent torque ripple and speed variation due to the driving characteristics of pulse current waveform and the nonlinear inductance profile. The high torque ripple and speed variation inhibits wide application. The minimization of the torque ripple is very important in high performance servo drive applications, which require smooth operation with minimum torque pulsations.

This paper presents the new SRM torque modeling technique for the control of instantaneous torque. The SRM is modeled by the database of torque profiles for every small variation in currents and rotor angles, which is inferred from the several measured data by the adaptive neuro-fuzzy inference technique. Simulation results demonstrating the effectiveness of proposed torque modeling technique are presented.

1. 서론

SRM은 구조가 간단하여 제작이 용이하고 관성이 적을 뿐만 아니라 발생토크가 크고 넓은 범위에서 속도 제어가 용이하며 제어회로가 간단한 등의 많은 장점을 가지고 있으나 적절한 스위칭을 위한 회전자 위치정보가 필요하며, 펄스형 전원에 의해 구동되므로 토크의 맥동과 소음이 크다는 단점이 있다[1~3]. 특히, SRM의 상용화에 가장 큰 장애요인으로 작용하는 것은 회전축에서 발생하는 맥동토크이며 이에 의해 기기 자체는 물론이고 주변장치에 까지 여러 가지 악영향을 미친다.

지금까지 발표된 SRM의 토크를 제어하기 위한 연구는 주로 기기의 인덕턴스 프로파일을 측정하고 이를 이용하여 토크를 계산하는 방식을 취해 왔다[4,5]. 이 경우 운전가능 영역범위에서 모든 전류값과 회전자위치각에 대한 연속적인 인덕턴스값을 구해야 한다. 그러나 이러한 연속적인 인덕턴스 프로파일 모두를 측정에 의해서 구하기는 불가능하므로, 몇가지 경우의 측정된 데이터들로부터 적절한 수단에 의해 이 값들을 얻는 방법을 사용해 왔지만 그 결과는 그다지 만족스럽지 못했다. 더욱이 SRM의 자기회로가 포화되면 인덕턴스와 토크 사이의 관계에 오차가 발생하므로 정도 높은 토크를 제어할 수 없게 된다. 또한 가장 큰 단점인 맥동토

오크를 억제하기 위해 다양한 제어기법이 제시되어 있지만, 시스템의 제어정도를 높이고 응답특성을 개선하기 위해서는 순시적인 토크 제어가 필수적이다.

따라서 본 연구에서는 SRM의 토크를 순시적으로 제어하기 위해 기존의 방식과는 달리 인덕턴스 프로파일 아닌 토크 프로파일로써 기기를 모델링하고자 한다. 이는 SRM의 토크를 제어하기 위해 인덕턴스 프로파일에 의한 간접적인 방법보다는 직접 토크 프로파일을 이용하는 것으로 당연한 접근방식이라 하겠다. 이를 위해 먼저, 몇가지 대표적인 경우에 대해 SRM의 토크를 측정하고, 이 데이터로부터 적응 뉴로퍼지 추론기법(Adaptive Neuro-Fuzzy Inference Technique, 이하 ANFIT)을 사용하여 전류 및 회전자위치각의 미소변화에 대한 토크 프로파일을 구한다. 시뮬레이션을 통해 얻은 결과로부터 제안된 방식의 타당성을 입증함으로써, 본 연구가 SRM의 순시토크를 제어하기 위한 기본적인 모델로써 정확성면에서 매우 우수한 결과를 나타냄을 보이고자 한다.

2. SRM의 토크 및 전류특성

그림 1은 본 연구에서 사용된 대표적인 형태의 6/4 SRM의 구조와 구동회로를 나타낸다.




그림 1. 6/4 SRM의 구조 및 구동회로
Fig. 2. The structure of 6/4 SRM and its drive circuit

SRM은 토크 발생기구가 매우 비선형적이고 불연속적이기 때문에 기존의 전동기에 비해 소음이나 맥동 토크가 큰 단점이 있다. SRM의 총합토크는 독립적으로 제어되는 고정자 각 상의 토크 성분의 합으로 나타나므로, 상전류가 인접한 상으로 여자가 전이되는 순간에 토크맥동이 가장 크게 나타난다. 따라서 맥동 토크를 최소화할 수 있는 최적의 기준토크를 설정하고 이를 추종하기 위해 대응하는 상전류 파형을 도출할 필요가 있다. 이때, 토크를 직접 제어하기 위해서는 회전자 위치각과 상전류의 크기에 따른 토크 프로파일을 측정하여, 이를 SRM의 모델로 사용한다.

SRM의 토크는 자기적 코에너지 개념으로부터 식(1)과 같이 표현할 수 있다.

$$T(\theta, i) = \frac{\partial W(\theta, i)}{\partial \theta} \quad (1)$$

여기서 T 는 토크, θ 는 회전자의 위치각, i 는 상전류, $W(\theta, i)$ 는 자기적 코에너지를 나타낸다. 고정자 및 회전자 사이의 상호인덕턴스가 무시된다면 식(1)은 식(2)로 표현될 수 있다.

$$T(\theta, i) = \frac{1}{2} \frac{dL(\theta, i)}{d\theta} i^2 \quad (2)$$

여기서 $L(\theta, i)$ 은 고정자와 회전자간의 인덕턴스를 나타낸다. 식(2)에서 알 수 있는 바와 같이 SRM의 발생토크는 여자방법에 따라 결정되는 상전류 파형 및 인덕턴스의 기울기로 표현된다. SRM에서 발생 토크의 한 인자인 상전류 해를 구하기 위한 전압 방정식은 식(3)과 같다.

$$\begin{aligned} V &= Ri + \frac{d\lambda(\theta, i)}{dt} \\ &= Ri + L(\theta, i) \frac{di}{dt} + i \frac{dL(\theta, i)}{d\theta} \frac{d\theta}{dt} \end{aligned} \quad (3)$$

식(3)의 우변 첫째 항은 권선 저항의 전압강하이며 둘째 항은 리액턴스의 전압강하이고 셋째 항은 속도 역기전력 항이 됨과 동시에 기계적인 출력을 나타내는 성분이 된다. 식(3)으로부터 상전류 해를 구하기 위해서는 SRM의 인덕턴스 프로파일에 대한 정확한 정보가 필수적이다.

일반적인 운전조건하의 SRM에서는 자기포화 현상으로 인해 인덕턴스 증가구간에서의 인덕턴스 변화율은 전류에 의존하는 함수가 되며, 또한 일정한 값이 되지 않고 회전자와 고정자의 극이 일치할수록 그 기울기는 완만해진다. 뿐만 아니라 고정자극과 회전자극이 만나기 시작하는 부근에서 단부효과(fringing effect)로 인해 최소 인덕턴스 구간에서도 인덕턴스값이 일정한 값을 가지지 않아 인덕턴스의 기울기가 존재하게 된다. 따라서 회전자 위치와 인가되는 전류에 따라 인덕턴스가 비선형적으로 변하며 이를 고려하지 않고 제어할 경우 필연적으로 토크리플이 발생한다. 또한 SRM을 구동하기 위해서는 전자계 구조상 단순적인 구형과 전원이 각 상권선에 순차적으로 인가되어 구동되므로 선간 상전류 중첩을 고려하여 맥동 토크를 최소로 하기 위한 스위칭 제어기법이 요구되어진다. 이러한 제어를 위해서는 상전류에 따른 토크 및 인덕턴스에 대한 정보가 필수적이다. 그러나 토크 및 인덕턴스의 프로파일은 비선형적이므로 수식적으로 정확한 해를 구하기는 매우 어렵다. 토크의 해를 얻기 위해서는, 전류의 크기 및 회전자 각도에 대한 인덕턴스의 값을 알아야 한다. 그러나 측정할 수 있는 전류의 크기에 대한 인덕턴스의 값은 한계가 있어서 이 측정된 데이터로부터 평활토크를 위한 완전한 전류해를 구하기란 불가능하다. 따라서 한정된 데이터로부터 전류크기의 미소변화에 대한 인덕턴스 값을 얻기 위해서는 특별한 추론기법이 필요하다. 또한 특별한 기법으로 연속적인 인덕턴스 값을 얻을 수 있어도 SRM의 자기적포화로 인하여 선형의 토크 식으로부터 계산된 토크는 약간의 오차가 발생한다. 따라서 토크를 순시적으로 제어하기 위해서는 전류와 회전자 위치각에 따른 정확한 토크 값을 구할 필요가 있다.

3. 다변수 적응 뉴로퍼지 기법에 의한 모델 추정

3.1. 추정 알고리즘의 기본 원리

본 논문에서는, 불연속적이고 비선형적인 SRM의 토오크 데이터로부터 연속적인 데이터를 얻기 위해 비선형 파라메타 추정에 우수한 성능을 보이고 있는 Jang[6]에 의해 제안된 적응 네트워크에 기초한 퍼지추론 시스템 (Adaptive Network Fuzzy Inference System, 이하 ANFIS)을 사용하여 연속적인 전류 및 회전자위치각에 대한 토오크 값을 추정하고자 한다. 이것에 의해 모든 형태의 퍼지모델을 얻을 수 있으며, 본 논문에서는 Takagi-Sugeno형의 퍼지모델을 동정한다. 적응 네트워크에 기초한 다변수 퍼지추론 시스템의 기본구조는 그림 2와 같다. 여기서 입력은 x, y 로서 2개이고 출력은 z 이다.




그림 2. 적응 네트워크에 기초한 퍼지 추론 시스템의 기본 구조

Fig. 2. An basic example of the structure of ANFIS

퍼지규칙은 다음과 같은 두개의 Takagi-Sugeno형으로 이루어져 있다.

Rule 1 : If x is A_1 and y is B_1

$$\text{Then } f_1 = p_1x + q_1y + r_1$$

Rule 2 : If x is A_2 and y is B_2

$$\text{Then } f_2 = p_2x + q_2y + r_2$$

ANFIS가 L 개의 층(Layer)을 가지고, k 번째 층은 M 개의 노드를 가졌다고 하면, k 번째 층의 i 번째 노드의 출력은 O_i^k 로 표시한다. 이 출력값은 이전층에서 들어

오는 입력신호와 각 노드가 가지는 파라메터에 의해 계산된다. 즉,

$$O_i^k = F(O_i^{k-1}, \dots, O_{M-1}^{k-1}, a, b, c, \dots) \quad (4)$$

여기서 a, b, c, \dots 는 각 노드에 속한 파라메터들이다. 각 층의 각 노드에서 수행되는 연산은 다음과 같다.

Layer 1 : 이 층의 각 i 번째 노드에 대한 출력은 식 (5)와 같다.

$$O_i^1 = \begin{cases} \mu_{A_i}(x) \\ \mu_{B_i}(y) \end{cases} \quad (5)$$

여기서 x 와 y 는 노드 i 의 입력, A_i 와 B_i 는 퍼지언어 변수이다. O_i^1 은 A_i 및 B_i 소속함수 값으로 입력 x 및 y 가 A_i 및 B_i 를 만족하는 정도를 나타낸다.

Layer 2 : 여기에 속한 각 노드는 입력되는 신호들을 곱해서 출력한다. 예를 들면,

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2 \quad (6)$$

이것은 각 퍼지규칙의 전반부의 적합도를 계산하는 것을 의미한다.

Layer 3 : 이 층에 속한 각 노드는 i 번째 규칙의 적합도에 대한 모든 규칙의 적합도의 합의 비를 계산한다.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (7)$$

즉, 각 노드의 출력은 규준화된 적합도가 된다.

Layer 4 : 이 층에 속한 각 노드의 출력은 다음과 같다.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (8)$$

여기서 \bar{w}_i 는 Layer 3의 출력이고 $\{p_i, q_i, r_i\}$ 는 동조되어야 할 파라메터의 집합이다. 이 층에 속한 파라메터들이 후반부 파라메터들이다.

Layer 5 : 이층의 노드는 모든 입력신호를 합하여 전체 퍼지모델 출력을 계산한다.

$$O_i^5 = \hat{y} = \frac{\sum w_i f_i}{\sum w_i} \quad (9)$$

ANFIS의 각 파라미터들을 동조하기 위해 gradient에 기초한 학습방법인 오차역전파(error back propagation) 방법과 최소자승법(least square estimation)을 합성하여 사용한다. 이러한 하이브리드 학습알고리즘의 전방향패스(forward pass)에서 각 노드의 출력신호는 Layer 4까지 계산되고 전반부 변수가 고정된 상태에서 후반부 변수가 최소자승법에 의해 동정된다. 후방향패스(backward pass)에서는 오차율이 출력노드에서 입력노드까지 역으로 전달되고 전반부 변수가 gradient descent에 의해 조정된다. 표 1은 이러한 과정을 나타내고 있다.

표 1. 하이브리드 학습 알고리즘의 구성
Table.1. Structure of the hybrid learning algorithm

구분	전방향 패스	후방향 패스
전건부 변수	고정	gradient descent
후건부 변수	최소자승법	고정
전달신호	노드 출력	오차율

3.2. 적용 알고리즘 및 추정 결과

본 논문에서 대상이 되고 있는 피시험기는 고정자와 회전자의 극이 6/4이며 정격출력이 2[kW], 인가전압이 300[V], 정격전류가 7[A]인 SRM이다. 토오크 프로파일은 일정한 크기의 전류를 고정하고 회전자를 회전시키면서 엔코더로부터의 위치각을 1° 씩 변화시키면서 토오크의 크기를 측정하여 구하였으며, 이때 전류의 크기는 0, 1, 2, 3, 5, 7[A]로 하였다. 따라서 3.1절에서 사용한 x 입력은 전류 i 로 설정하고 y 입력은 회전자 위치각 θ 로 하였으며, 각 입력의 수는 6개로 설정하였다. 또 다음 절에 주어지 있는 바와 같이 토오크 발생영역은 총 44° 이므로 전체 각도에 대한 추정을 위해서는 같은 전류입력에 대해 각도입력을 6° 씩 나누어 여러번 추정하였다. 이상과 같은 입력에 대해 ANFIS를 이용한 퍼지 모델링에 의하여 동정된 SRM의 토오크 프로파일의 퍼지규칙은 다음과 같다.

$$\begin{aligned}
 & \vdots \\
 R_{2,3} : & \text{If } \{i \text{ is } A_2\} \text{ and } \{\theta \text{ is } B_3\} \\
 & \text{Then } T(t+1) = a_{2,3} i + b_{2,3} \theta + c_{2,3} \\
 & \vdots \\
 R_{4,6} : & \text{If } \{i \text{ is } A_4\} \text{ and } \{\theta \text{ is } B_6\} \\
 & \text{Then } T(t+1) = a_{4,6} i + b_{4,6} \theta + c_{4,6} \\
 & \vdots \\
 R_{i,j} : & \text{If } \{i \text{ is } A_i\} \text{ and } \{\theta \text{ is } B_j\} \\
 & \text{Then } T(t+1) = a_{i,j} i + b_{i,j} \theta + c_{i,j}
 \end{aligned} \quad (10)$$

여기서 A_i 는 전류의 i 번째 멤버십 함수이고 ($i = 1, 2, \dots, 6$), B_j 는 각도의 j 번째 멤버십함수 ($j = 1, 2, \dots, 6$)이다. 전술한 $\mu_{A_i}(x)$ 는 본 논문의 경우 전류입력에 대한 멤버십함수를 나타내므로, 최소값이 0이고 최대값이 1인 식(11)로 표현되는 삼각형의 소속함수를 사용한다.

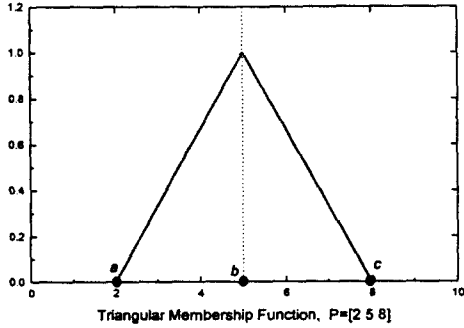
$$f(x; a_i, b_i, c_i) = \begin{cases} 0, & x \leq a_i \\ \frac{x-a_i}{b_i-a_i}, & a_i \leq x \leq b_i \\ \frac{c_i-x}{c_i-b_i}, & b_i \leq x \leq c_i \\ 0, & c_i \leq x \end{cases} \quad (11)$$

여기서 a_i, b_i, c_i 는 적응네트워크에 의해 조정되어야 할 파라미터들로서 이것을 조정함으로써 소속함수의 모양을 변경시킨다. 각 파라미터들은 일정한 물리적 의미를 지닌다. a_i 와 c_i 는 소속 삼각함수의 시작과 끝을 나타내고, b_i 는 삼각함수의 꼭지점의 위치를 나타낸다. 한편, $\mu_{B_j}(y)$ 는 회전자 위치각 입력에 대한 멤버십함수를 나타내므로, 최소값이 0이고 최대값이 1인 식(11)로 표현되는 Two-sided Gaussian curve형의 소속함수를 사용한다.

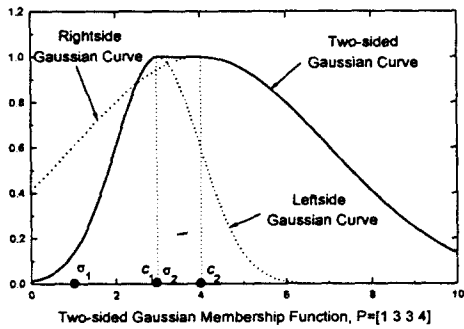
$$f(y; \sigma_1, c_1, \sigma_2, c_2) = \left[\epsilon \frac{-(y-c_1)^2}{2\sigma_1^2} \oplus \epsilon \frac{-(y-c_2)^2}{2\sigma_2^2} \right] \quad (12)$$

위 식에서 알 수 있듯이 이 소속함수는 두 개의 Gaussian curve의 조합으로 이루어져 있으며, \oplus 는 논리합을 나타낸다. σ_1 및 c_1 은 첫 번째 곡선인 좌반부 Gaussian curve의 기울기와 중심을 나타내며, σ_2 및 c_2 는 두 번째 곡선인 우반부 Gaussian curve의 기울기

와 중심을 나타낸다. 또 파라미터 α_1 과 α_2 사이의 크기는 1로써 한정된다. 그림 3은 이러한 각 파라미터들의 물리적인 의미를 보여준다.



(a) Membership function



(b) Membership function of the current input of rotor position angle input
 그림 3. 각 소속 함수의 파라미터들의 물리적인 의미
 Fig.3. Physical meanings of the parameters in each membership function

이상과 같은 멤버십 함수들의 각 파라미터를 적용 신경망을 이용한 이득조정기법(gain scheduling method)에 의해 동정시킨다. 그림 4는 SRM의 토크 프로파일을 예측하기 위해 구성된 적응 뉴로퍼지 모델의 전체적인 알고리즘을 나타내고 있다. 본 연구에서는 SRM의 전체를 모델화하지 않은 관계로, 전반부 변수와 후반부 변수를 같은 전류와 각도로 설정하여 간단하게 구성하였다. 이들의 조합에 의하여 36개의 퍼지규칙이 만들어졌다.




그림 4. SRM의 퍼지 모델을 위한 ANFIS의 구조
 Fig. 4. The structure of ANFIS for a fuzzy model of the SRM

그림 5는 피시험 전동기에서 1~7[A]의 일정한 전류를 흘렸을 때 회전자 위치각 1° 마다 측정된 토크 값과 추정된 전체 토크 프로파일 중 측정전류에 해당하는 것만을 각각 점과 실선으로 나타내고 있다. 그림에서 보는 바와 같이 토크 발생영역은 0° 부터 44° 까지로 44° 의 범위를 가지고 있으며, 동정된 퍼지모델이 실제 토크 프로파일을 정확히 잘 추정하고 있음을 알 수 있다.




그림 5. 측정(점) 및 추정(실선) 토크 프로파일
 Fig.5. Measured (dot point) and inferred (solid line) torque profiles

그림 6은 측정된 토크 데이터로부터 본 논문에서 적용한 적응 뉴로퍼지 추론기법에 의해 추정된 전체 토크를 나타낸 것으로 전류는 $0.2[A]$ 마다, 회전자 위치각은 0.1° 마다 토크 값을 나타내고 있다. 전류의 미소증가에 대해 토크의 크기가 증가하되 그 경향성이 잘 유지되고 있으며, 추정의 정확도는 이미 그림 5에서 증명된 바 있다.




그림 6. 완전한 추정 토크 프로파일
Fig.6. Complete inferred torque profiles

따라서 본 논문에서 제시한 SRM의 토크 추정방법은 매우 우수한 결과를 나타냄을 알 수 있으며, 제시된 방법에 의해 얻어진 토크 프로파일에 의해 SRM의 순시토크를 제어할 수 있는 구간을 마련했다 할 수 있다.

4. 결론

SRM은 인덕턴스의 비선형성과 펄스전류에 의해 본질적으로 토크의 맥동성분이 커서 실제 전동기 응용 영역에 많은 제약을 주고 있다. 이러한 맥동토크를 억제하기 위한 다양한 제어기법이 제시되어 있지만, 시스템의 제어정도를 높이고 응답특성을 개선하기 위해서는 순시적인 토크 제어가 필수적이다. 따라서 본 논문에서는 SRM의 토크를 순시적으로 제어하기 위해 토크 프로파일로써 기기를 모델링하였다. 이를 위해 몇 가지 경우의 전류값과 회전자 위치각에 대해 측정된 토크 프로파일로부터 적응 뉴로퍼지 추론기법을 사용하여 모든 전류값 및 회전자 위치각에 대한 토크의 크기를 추정하였다. 측정된 토크값과 추정된 값을 비교함으로써 본 논문에서 제시한 SRM의 토크 추정방법은 매우 우수한 결과를 나타냄을 알 수 있으며, 제시된 방법에 의해 얻어진 토크 프로파일은 SRM의 순시토크를 제어할 수 있는 구간이 될 수 있다.

본 연구의 향후 과제는 회전자의 위치를 검출하기 위해 부착하는 고가의 엔코더를 제거하여 센스리스 구동을 실현함으로써 실용성 있는 구동시스템을 구현하는 것이다.

- [1] I. Husain, M. Ehsani, "Torque Ripple Minimization in Switched Reluctance Drives by PWM Current Control", *IEEE Trans. on Power Electronics*, Vol. 11, No. 1, pp.91-98, 1996.
- [2] C. Wu, C. Pollock, "Analysis and Reduction of Vibration and Acoustic Noise in the Switched Reluctance Drive", *IEEE Trans. on Industrial Applications*, Vol. 31, No. 1, pp.91-98, 1995.
- [3] D. E. Cameron, J. H. Lang and S. D. Umans, "The Origin and Reduction of Acoustic Noise in Doubly Salient Variable-Reluctance Motors", *IEEE Trans. on Industrial Applications*, Vol. 28, No. 6, pp.1250-1255, 1992.
- [4] B. K. Bose, T. J. E. Miller, P. M. Szezesny and W. H. Bocknell, "Microcomputer Control of Switched Reluctance Motor" *IEEE Trans. on Industrial Application*, Vol. 22, No. 4, pp.708-715, 1986.
- [5] Graham E. Dawson, Anthony REastham and Jerzy Mizia, "Switched Reluctance Motor Torque Characteristics : Finite Element Analysis and Test Results", *IEEE Trans. on Industrial Application*, Vol. 23, No. 3, pp.532-537, 1987.
- [6] M. Moallem, "Predicting Torque of Switched Reluctance Machine from Its Finite-Element Field Solution", *IEEE Trans. on Energy Conversion*, Vol. 5, No. 2, pp.733-739, 1990.