

Рисунок 2 – Стрелки напряженности и эквипотенциальные линии электрического поля для сенсора с  $b=1$  мм и  $r = 4$  мм

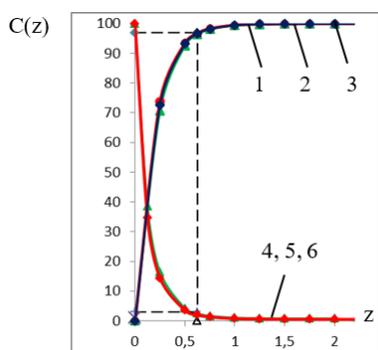


Рисунок 3 – Зависимость нормированной емкости от относительного расстояния  $z$

Точное значение глубины проникновения электрического поля определить невозможно [1, 2]. Для FEF sensors эмпирически связь между глубиной проникновения  $h$  и пространственным периодом электродов  $2r$  примерно принимается [2]:

$h=2r/4 - 2r/3$ , где  $h$  – эффективная глубина проникновения электрического поля,  $r$  – размер секции.

Контролировалась двуслойная среда: масло ( $\epsilon_2=3$ ) – воздух ( $\epsilon_3=1$ ). Глубина зоны контроля для сенсора открытого типа оценивалась из зависимости нормированной емкости  $C(z)$  от относительного расстояния  $z = h/r$  до плоскости, в которой лежат электроды рисунок.3.

Глубина зоны контроля соответствует положению  $z_0$ , когда различие между емкостью в положении  $z_0$  и максимальной емкостью  $C_{\max}(z = \infty)$  равно 3 % от различия между самой максимальной и минимальной емкостями:

$$C(z_0) = \frac{C - C_{\min}}{C_{\max} - C_{\min}} 100\% = 3\%$$

Кривые 1, 2, 3 построены для сенсоров с металлизацией поверхности 0,25, 0,5 и 0,75 соответственно и относятся к случаю увеличения слоя жидкого диэлектрика, кривые 4,5, 6 к его уменьшению. Анализ кривых говорит о совпадении глубин зоны контроля независимо от металлизации поверхности сенсоров. Глубина зоны контроля для сенсора открытого типа лежит в том же диапазоне, что и глубина зоны контроля для (FEF) sensors.

#### Литература

1. Xiaobei B. Li, Sam D. Larson, Alexei S. Zyuzin, and Alexander V. Mamishev “Design Principles for Multichannel Fringing Electric Field Sensors,” IEEE SENSORS JOURNAL, VOL. 6. № 2 , 2006. pp. 434–440.
2. Kim C. et al. Numerical analysis on effective electric field penetration depth for interdigital impedance sensor // Journal of Physics: Conference Series. – IOP Publishing, 2013. – Т. 418. – №. 1. – С. 012020.
3. Тихонов А.Н., Самарский А.А. Уравнения математической физики: 7-е изд.М.: Изд-во МГУ, 2004.

УДК 621.317.4; 621.317

### ПОСТРОЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ПРЕДСКАНИЯ НАМАГНИЧИВАЮЩЕГО СИГНАЛА, СИНУСОИЗИРУЮЩЕГО МАГНИТНЫЙ ПОТОК

Ерошенко А.С., Скурту И.Т., Брановицкий И.И.

Государственное научное учреждение «Институт прикладной физики НАН Беларуси»  
Минск, Республика Беларусь

Измерения магнитных характеристик магнитомягких материалов проводятся при синусоидальной форме магнитного потока в испытуемом образце [1]. Однако при значительной величине магнитного поля он претерпевает искажения, вызванные нелинейностью основной кривой намагничивания, а также активно-реактивным характером нагрузки намагничивающей системы. Величина этих искажений непосредственно влияет на измеренное значение такой важной характеристики, как удельные магнитные потери.

Задача синусоизации магнитного потока решается разными методами (аналоговыми, цифровыми или комбинированными), формирующими такой намагничивающий сигнал, при котором магнитный поток синусоидален. Наиболее эффективными являются цифровые и комбинированные методы. Однако такие методы производят коррекцию сигнала итерационно в процессе задания режима перемагничивания, что приводит к немонотонности движения в магнитных координатах, что сказывается на магнитном состоянии образца

и приводит к снижению точности и повторяемости измерений.

От этих недостатков можно избавиться если построить модель, предсказывающую для установленного режима перемагничивания форму сигнала генератора, при которой сигнал на измерительной обмотке будет иметь синусоидальную форму. Для построения такой модели использованы искусственные нейронные сети прямого распространения, так как они позволяют с высокой точностью моделировать зависимости с сильной нелинейностью, как в данном случае.

На вход нейронной сети подается форма искаженного сигнала напряжения на измерительной обмотке испытываемого образца при синусоидальном сигнале генератора, на выходе ожидается форма сигнала генератора, которая синусоидирует сигнал на измерительной обмотке при данном режиме перемагничивания. Синусоидирующие сигналы генератора для обучения нейросетевой модели получены с помощью цифровой итерационной синусоизации [2]. Для создания и обучения модели использована открытая нейросетевая библиотека Keras [3] на основе фреймворка TensorFlow [4].

Всего получено 500 пар сигналов для амплитуд напряженностей магнитного поля от 25 до 200 А/м. Пары были случайным образом разбиты на три категории: обучающая выборка (300 пар), выборка для верификации модели (100 пар), тестовая выборка (100 пар).

Ошибка предсказания нейросетевой моделью синусоидирующей формы сигнала генератора  $\hat{U}_g$  рассчитывалась как средняя квадратичная ошибка  $MSE$  сигналов  $\hat{U}_g$  и  $U_g$ :

$$MSE(U_g, \hat{U}_g) = \frac{1}{n} \sum_{i=0}^{n-1} |U_{g(i)}^2 - \hat{U}_{g(i)}^2|, \quad (1)$$

где  $U_g$  – синусоидирующий сигнал, полученный цифровой итерационной синусоизацией;  $\hat{U}_g$  – синусоидирующий сигнал, предсказанный нейросетевой моделью;  $U_{g(i)}$  и  $\hat{U}_{g(i)}$  –  $i$ -е отсчеты сигналов  $U_g$  и  $\hat{U}_g$  соответственно. Погрешность  $\delta$  модели оценивалась как наибольшая ошибка предсказания  $MSE$  в тестовой выборке. Соответственно, макропараметры нейросетевой модели (архитектура сети, оптимизатор и др.) выбирались для минимизации данного показателя.

Для представления сигналов на входе и выходе нейронной сети вместо непосредственно отсчетов использовался их гармонический состав, где каждая гармоника представлена значениями амплитуды и фазы (полярные координаты). В разработанной модели входные и выходные сигналы представлены 15-ю гармониками. Используются

нечетные гармоники, так как только они присутствуют в намагничивающем сигнале [5].

Для упрощения обучения нейронной сети все данные должны принимать небольшие значения (как правило, в диапазоне 0-1) [6]. Для этого введена процедура нормализации параметров. Все фазовые значения гармоник сигнала разделены на  $2\pi$ , амплитудные – на значение базовой гармоники. Также данная процедура позволяет отстроиться от абсолютных значений электрических параметров и оперировать лишь величинами высших гармоник относительно базовой, что достаточно для выражения несинусоидальности сигнала.

Другой проблемой является стремительное убывание амплитуд высших гармоник, что приводит к тому, что при обучении параметры с крайне низкими значениями игнорируются. Для избавления от этого эффекта амплитудное значение каждой гармоники увеличивалось в  $k^2$  раз, где  $k$  – номер гармоники. Для отражения уменьшения влияния не только амплитуд, но и фаз высших гармоник, фазовое значение гармоники дополнительно уменьшалось в  $\sqrt{k}$  раз. При таком подходе значения амплитуд и фаз гармоник снижаются одинаково плавно. Нормализованные значения амплитуды  $\hat{W}_{r,n}$  и фазы  $\hat{W}_{\varphi,n}$   $k$ -й гармоники:

$$\hat{W}_{r,n}[k] = \frac{k^2 \hat{W}_r[k]}{\hat{W}_r[1]}, \quad 2$$

$$\hat{W}_{\varphi,n}[k] = \frac{\hat{W}_{\varphi}[k]}{2\pi\sqrt{k}}. \quad 3$$

Процесс предсказания требуемой формы сигнала генератора протекает следующим образом: искаженный сигнал напряжения на измерительной обмотке с помощью быстрого преобразования Фурье переводится в частотную область, его гармоники из комплексного представления переводятся в полярное, выбирается нужное их количество. Затем значения гармоник нормализуются и передаются в искусственную нейронную сеть прямого распространения. Гармоники, полученные на выходе сети масштабируются (операция, обратная нормализации), преобразовываются в комплексную форму и с помощью обратного преобразования Фурье переводятся во временную область.

Архитектура нейронной сети представляет собой три слоя: 1) 1500 нейронов с активационной функцией *relu*; 2) прореживающий слой с коэффициентом прореживания 0,1; 3) выходной слой из 30 нейронов с функцией активации *sigmoid*. Ключевым в архитектуре является наличие слоя с нелинейной функцией активации. Функция потерь рассчитывалась как средняя абсолютная

ошибка ( $MAE$ ), в качестве оптимизатора наибольшую эффективность показал *Adamax* [7].

Для проверки предсказательной способности полученной модели было проведено сравнение коэффициента нелинейных искажений (КНИ) сигнала напряжения на измерительной обмотке во время проведения измерений в диапазоне амплитуд напряженности магнитного поля  $H_m = 25 \dots 200$  А/м. Без синусоизации КНИ принимает значения от 2,5 до 15,5 % соответственно для нижней и верхней границ. Сравнение эффективности цифровой итерационной и нейросетевой синусоизации приведены на рис. 1. Граница допустимых значений КНИ (1 %) обозначена штриховой линией.

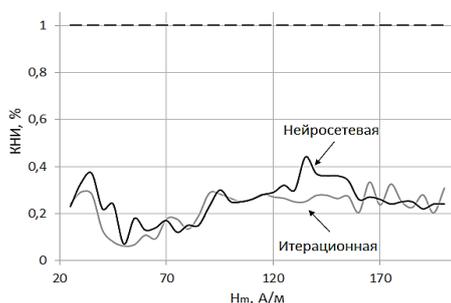


Рисунок 1 – Результаты применения итерационной (серый) и нейросетевой (черный) синусоизации

Как видно из приведенного графика, использование созданной нейросетевой модели для синусоизации магнитного потока имеет ту же степень эффективности, что и применение итерационной синусоизации, используемой для обучения модели. Это позволяет использовать синусоизацию, основанную на методах глубокого обучения,

при проведении измерений магнитных характеристик магнитомягких материалов.

Таким образом, представленная модель позволяет проводить синусоизацию с такой же результативностью, как и метод, на котором она основана. Вместе с этим нейросетевая синусоизация лишена таких побочных эффектов цифровых итерационных методов, как нестабильность и немонокотность намагничивающего процесса, которые влияют на магнитную историю испытуемого образца, что способно негативным образом отражаться на точности и повторяемости результатов измерений его параметров.

### Литература

- ГОСТ 12119.4-98 Сталь электротехническая. Методы определения магнитных и электрических свойств. Метод измерения удельных магнитных потерь и действующего значения напряженности магнитного поля. Мн.: Издательство стандартов, 1999 г.
- Способ формирования синусоидальной индукции в ферромагнитном образце: пат. 10958 Республика Беларусь, МПК G 01R 33/12. / Брановицкий И.И., Путьрский М.Н.; заявитель и патентообладатель Институт прикладной физики НАН Беларуси. – № 20060894; заявлено 12.09.2006; опубликовано 30.04.2008. – 3 с.
- Keras: The Python Deep Learning library. URL: <https://keras.io/>.
- TensorFlow. An open source machine learning library for research and production. URL: <https://www.tensorflow.org/>.
- Кифер, И.И. Испытания ферромагнитных материалов. – М.: Энергия, 1969 г.
- Ф. Шолле. Глубокое обучение на Python – СПб.: Питер – 2018
- К. Diederik, В. Jimmy. Adam: A Method for Stochastic Optimization / International Conference on Learning Representations – 2014 г.

УДК 621.396.96

## КОНТРОЛЬ ОБМОТОК АСИНХРОННЫХ ЭЛЕКТРОДВИГАТЕЛЕЙ КВАЗИПЕРИОДИЧЕСКИМИ НАПРЯЖЕНИЯМИ

Зеленко В.В., Суходолов Ю.В.

Белорусский национальный технический университет  
Минск, Республика Беларусь

Одними из основных потребителей электроэнергии, примерно 40% всей производимой электростанциями, являются асинхронные электродвигатели [1], что определяет необходимость повышения их качества. В процессе эксплуатации могут возникать повреждения элементов электродвигателя, что в свою очередь приводит к преждевременному выходу его из строя. До 90 % всех отказов асинхронных электродвигателей со вращающимися обмотками приходится на витковые замыкания [2], другие дефекты являются следствием их развития.

Испытание обмоток асинхронных электродвигателей на витковые замыкания состоит из

двух задач: создание между витками необходимого испытательного напряжения и обнаружение дефектов, приведших к пробое изоляции.

На распределение напряжения вдоль обмотки, контролируемой на витковое замыкание, влияет фронт испытательного сигнала. Контроль импульсами низкого напряжения не обеспечивает полную достоверность при испытаниях, так как при низких напряжениях не пробиваются воздушные промежутки любой толщины, следовательно, дефекты не будут выявлены даже в случаях, когда витковая изоляция полностью разрушена и витки разделяются только воздушным зазором.