

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

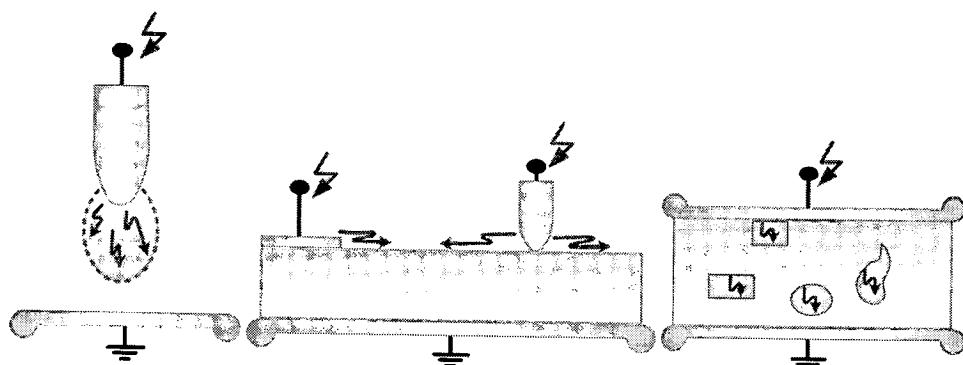
#### 2.1 ทฤษฎีที่เกี่ยวข้อง

ดี沙าร์จบางส่วน (Partial discharge, PD) หมายถึงการดี沙าร์จทางไฟฟ้าที่ไม่เชื่อมโยงกันอย่างสมบูรณ์ระหว่างอิเล็กโทรด [1, 2] ซึ่งอาจเกิดขึ้นในอัตราภายนอก จำนวนมาก หรืออัตราขึ้น เมื่อเกิด PD ขึ้นจะทำให้เกิดปรากฏการณ์ทางพิสิกส์ตามมาคือ แสงเสียงกระแสพลังไฟฟ้ากำลังสูงเสียได้อิเล็กตริกคลื่นแม่เหล็กไฟฟ้าย่านความถี่สูงปฏิกิริยาเคมี และความร้อน [3, 4]

##### 2.1.1 ประเภทของการเกิด PD

PD โดยทั่วไปแบ่งตามลักษณะที่เกิดได้เป็น 3 แบบคือ โคโรนาดี沙าร์จ (Corona discharge) ดี沙าร์จตามผิว (Surface discharge) และ ดี沙าร์จภายใน (Internal partial discharge) ดังภาพที่ 2.1

- 1) โคโรนาดี沙าร์จเกิดขึ้นในสนามไฟฟ้าไม่สม่ำเสมอสูงที่บริเวณอิเล็กโทรดปลายแหลมหรือขอบคมในก้าช หรือในของเหลวดังภาพที่ 2.1 (ก)
- 2) ดี沙าร์จตามผิว เกิดขึ้นเมื่อมีความเครียดสนามไฟฟ้า สูงตามแนวขวางกับผิวของไดอิเล็กตริก ดังภาพที่ 2.1 (ข)
- 3) ดี沙าร์จภายใน เกิดขึ้นในโครงสร้างห้องที่มีค่าความคงทนไดอิเล็กตริกต่ำภายในเนื้ออัตรา แข็ง หรืออัตราเหลว ดังภาพที่ 2.1 (ค)



(ก) โคโรนาดี沙าร์จ

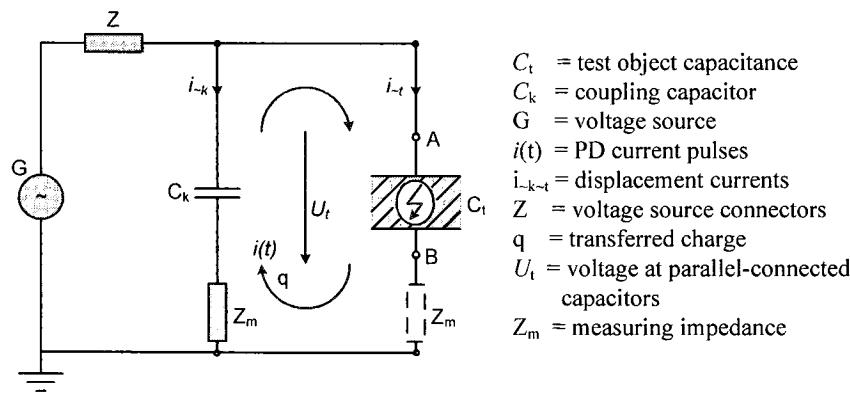
(ข) ดี沙าร์จตามผิว

(ค) ดี沙าร์จภายใน

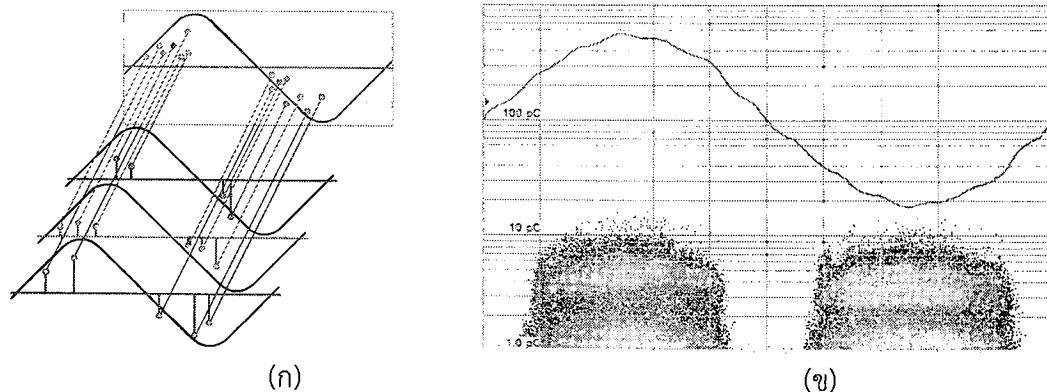
ภาพที่ 2.1 รูปแบบการเกิดของ PD

### 2.1.3 วงจรพื้นฐานการวัด PD

เทคนิคการตรวจวัด PD ตามมาตรฐาน IEC 60270 วงจรสังภาพที่ 2.2 ประกอบด้วยแหล่งจ่ายแรงดันสูง G, วัสดุทดสอบ  $C_t$ , ตัวเก็บประจุควบคุม  $C_k$  และอิมพีเดนซ์วัด  $Z_m$  โดยใช้หลักการตรวจจับกระแสฟลั๊ร์ส ความถี่สูง  $i(t)$  ที่เกิดขึ้นที่วัสดุทดสอบและในระหว่าง  $C_k$  และ  $C_t$  ทำการตรวจจับ  $i(t)$  ที่เหลือผ่าน  $Z_m$  ซึ่ง  $Z_m$  สามารถต่อได้ทั้งอนุกรมกับตัวเก็บประจุควบคุม  $C_k$  หรืออนุกรมกับวัสดุทดสอบ  $C_t$  ระบบวัดมีทั้ง wide-band และ narrow-band [5] สัญญาณที่วัดได้ต้องย่างดังดังภาพที่ 2.3 คือ ประจุที่ปราศจาก  $q$  ตำแหน่งมุมเฟส  $\Phi$  และ อัตราการเกิดช้าๆ ของวัตถุ [6]



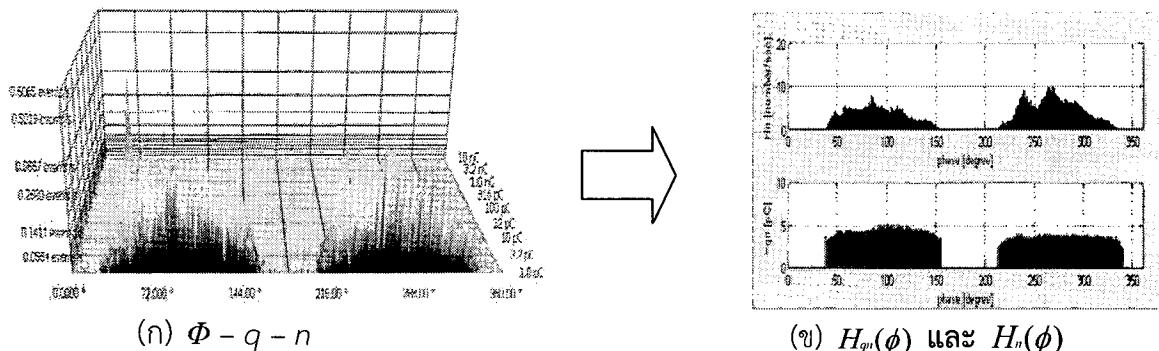
ภาพที่ 2.2 วงจรการตรวจวัดPD



ภาพที่ 2.3 ตัวอย่างสัญญาณPD

#### 2.1.4 การวิเคราะห์คุณลักษณะเด่นของสัญญาณ PD

การตรวจวัด PD ด้วยวิธีดังเดิมแบบ PRPDA (Phase Resolving Partial Discharge Analyzer) แสดงผลการวัด PD ในรูปแบบการกระจาย 3 มิติ  $\Phi - q - n$  เมื่อ  $\Phi$  คือมุมเฟสของแรงดัน,  $q$  คือขนาดประจุ, และ  $n$  คือจำนวนครั้งการเกิด PD ซึ่งสามารถแสดงรูปแบบการกระจายขนาดประจุเฉลี่ยตามมุมเฟส  $H_{qn}(\phi)$  และการกระจายจำนวนครั้งการเกิด PD ซึ่งตามมุมเฟส  $H_n(\phi)$  ดังภาพที่ 2.4 ซึ่งนำไปใช้วิเคราะห์คุณลักษณะเด่นทางสถิติได้โดยใช้สมการตั้งตารางที่ 2.1 [7, 8]



ภาพที่ 2.4 ตัวอย่างรูปแบบของสัญญาณ PD

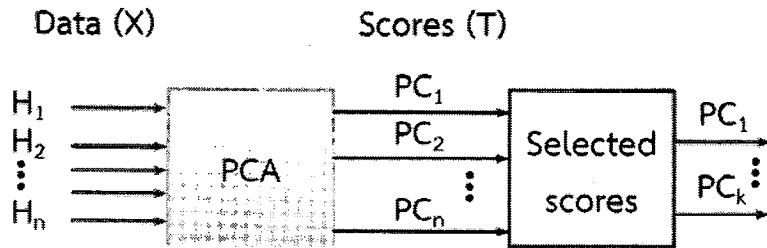
ตารางที่ 2.1 ตัวดำเนินการทางสถิติ

Skewness	$Sk = \frac{E(q-\mu)^3}{\sigma^3}$
Kurtosis	$Ku = \frac{E(q-\mu)^4}{\sigma^4}$
Discharge asymmetry	$Q = (Q_s/N)/(Q_s^+/N^+)$
Cross correlation factor	$cc = \frac{\sum x_i y_i - \sum x_i \sum y_i / n}{\sqrt{[\sum x_i^2 - (\sum x_i)^2 / n][\sum y_i^2 - (\sum y_i)^2 / n]}}$
Modified cross-correlation factor	$mcc = Q \times cc$

โดยที่  $q$  คือ ขนาดประจุตัวอย่าง ,  $\mu$  คือ ค่าเฉลี่ยของการกระจายประจุตัวอย่าง ,  $E$  คือ ตัวดำเนินการค่าคาดหวัง ,  $\sigma$  คือ ส่วนเบี่ยงเบนมาตรฐาน ,  $Q_s$  และ  $Q_s^+$  คือ ผลกระทบของการกระจายประจุ  $H_{qn}(\phi^+), H_{qn}(\phi^-)$ ,  $N^+$  และ  $N^-$  คือ จำนวนของการกระจายประจุ  $H_{qn}(\phi^+), H_{qn}(\phi^-)$ ,  $x_i$  คือ ขนาดประจุในแต่ละเฟสทางด้านรูปคลื่นแรงดันบวก ,  $y_i$  คือ ขนาดประจุในแต่ละเฟสทางด้านรูปคลื่นแรงดันลบ, ก็คือ จำนวนของมุมเฟสต่อครั้งรูปคลื่น

### 2.1.5 การวิเคราะห์ตัวประกอบหลัก

การวิเคราะห์ตัวประกอบหลัก (Principal Component Analysis, PCA) คือเทคนิคการลดจำนวนตัวแปร โดยสร้างตัวแปรใหม่จะเป็นพังก์ชันเชิงเส้นของตัวแปรเดิม และตัวแปรใหม่จะมีรายละเอียดหรือข้อมูลของตัวแปรเดิม จำนวนตัวแปรใหม่จะไม่เกินจำนวนตัวแปรเดิม [9,10,11] การแปลงข้อมูลจากเซตของตัวแปรเดิมไปเซตของตัวแปรใหม่ดังภาพที่ 2.5 และสมการที่ 2.1



ภาพที่ 2.5 ໂດຍແກ່ມາການແປ່ງຂໍ້ມູນໂດຍໃຫ້ເທົນີກ PCA

$$\mathbf{T}_{m \times k} = \mathbf{X}_{m \times n} \mathbf{P}_{n \times k} \quad (2.1)$$

เมื่อ  $T$  คือ เมตริกซ์ของตัวแปรใหม่เรียกว่า score,  $X$  คือ เมตริกซ์ของตัวแปรเดิม,  $P$  คือเมตริกซ์ที่ใช้ในการແປ່ງຂໍ້ມູນเรียกว่าเมตริกซ์ loading,  $m$  คือ จำนวนค่าสังเกต,  $n$  คือ จำนวนตัวแปรเดิม,  $k$  คือ จำนวนตัวแปรใหม่

### 2.1.6 โมเดลโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Neural Networks, NN) คือ ระบบการคำนวณที่เลียนแบบการทำงานของสมองมนุษย์ โดยมีการถ่ายทอดส่งผ่านข้อมูลอินพุตเข้าสู่หน่วยประมวลผลของระบบ ผลลัพธ์ที่ได้จากการทำงานของระบบคือข้อมูลเอาท์พุตโดยที่หน่วยประมวลผลนี้จะเรียกว่านิวรอน การทำงานของโครงข่ายประสาทเทียมจะขึ้นกับลักษณะการเชื่อมต่อระหว่างนิวรอน (Neural, Node) และค่าน้ำหนัก (Weight) ต่าง ๆ [12, 13]

### 2.1.7 โมเดลโครงข่ายประสาทเทียมแบบต่างๆ

- ตารางที่ 2.1 แสดงรูปแบบโครงข่ายประสาทเทียมแบบต่างๆ ซึ่งมีสถาปัตยกรรมและลักษณะของนิวรอนที่แตกต่างกัน อัลกอริธึมสำหรับการเรียนรู้ก็มีความแตกต่างกัน เช่น บางชนิดเรียนรู้แบบ Supervised Learning บางชนิดเป็น Unsupervised Learning และสำหรับการประยุกต์ใช้งานก็มีความแตกต่างกันไป เช่น Pattern Classification, Regression, Function Approximation, Interpolation, clustering เป็นต้น

ตารางที่ 2.2 รูปแบบโครงข่ายประสาทเทียมแบบต่างๆ [12, 13]

รูปแบบ	สถาปัตยกรรม/ ลักษณะเฉพาะของโครงสร้าง	ลักษณะวิธีการคำนวณ เรียนรู้	การประยุกต์ใช้งาน
Perceptron	Single-Node, Feedforward/ Binary- Threshold	Supervised, Error- correction	Pattern Classification
Adaline	Single-Node, Feedforward/ Linear	Supervised, Gradient Descent	Regression
Multilayer Perceptron	Multilayered Feedforward/ Nonlinear Sigmoid	Supervised, Gradient Descent	Function Approximation, Pattern Classification, Control Systems, etc.
Reinforcement Learning	Multilayered/ Binary- Threshold	Supervised reward- punishment	Robot Control
Support Vector Machines	Multilayered kernel based/ Binary-threshold	Supervised Quadratic Optimization	Classification, Regression
Radial Basis Function	Multilayered Distance based/ Linear	Supervised Gradient Descent	Interpolation, Regression, Classification
Hopfield Network	Single Layer, Feedback/ Binary- threshold/ Linear	Outer product correlation	Optimization
Boltzmann Machine	Two layered, feedback/ Binary threshold	Stochastic Gradient Descent	Optimization
Bidirectional Associative Memory	Two layered, feedback/ Binary threshold	Outer product correlation	Associative Memory
Adaptive Resonance Theory	Two layered/ Binary, faster-than-linear	Unsupervised competitive	Clustering, Classification
Vector Quantization	Single layered, feedback/ Faster than linear	Supervised- Unsupervised competitive	Quantization, Clustering, Classification
Mexican hat net	Single Layer, Feedback/ Linear Threshold	None, Fixed weights	Activity Clustering
Kohonen Self Organizing Feature Map	Single Layer, Linear Threshold	Unsupervised, Soft-Competitive	Clustering, Topological Mapping, Classification
Pulsed Neuron models	Single/Multilayer, Pulsed/IF Neuron	None	Coincidence detection, Temporal Processing

## 2.2 งานวิจัยที่เกี่ยวข้อง

Kreuger และ Gulski [14] ได้ศึกษาการตรวจวัด PD ในระบบอัตโนมัติ โดยใช้ระบบ digital computer สามารถวิเคราะห์ค่าพารามิเตอร์ของ PD และอพกติกรรมที่แตกต่างของ PD ได้ ในปี 1992 ได้พัฒนาการเรียนรู้จำและการจำแนกประเภทของ PD จากแหล่งกำเนิดที่ต่างกัน โดยสร้าง fingerprint เพื่อเปรียบเทียบและช่วยในการจำแนกประเภท PD ที่เกิดขึ้น และต่อมาระดับพัฒนาการเรียนรู้จำรูปแบบ PD ที่ไม่ทราบสาเหตุการเกิดมาก่อน โดยใช้ค่าพารามิเตอร์ทางสถิติที่ได้วิเคราะห์จากเครื่องตรวจวัด PD และจำแนกรูปแบบการเกิด PD โดยใช้วิธี contour score procedure และใช้ neural network มาช่วยในการจดจำรูปแบบ PD

เกรวิน วิเศษจินดาวัฒน์ และคณะ [15] ได้นำเสนอโปรแกรมวิเคราะห์ PD เรียนรู้และจดจำรูปแบบของ การเกิด PD ในอุปกรณ์ไฟฟ้าแรงสูง โดยหาค่าทางสถิติจากความสัมพันธ์ของ  $\phi - q - n$  เมื่อ  $\phi$  คือมุมไฟส่อง แรงดัน,  $q$  คือขนาดประจุ,  $n$  คือจำนวนครั้งการเกิด PD ซึ่งที่ได้จากการตรวจวัด PD ซึ่งมีตัวแปรวิเคราะห์ทั้งหมด 11 ตัวและใช้วิธีเฟรกต์ลจะได้ตัวแปรทั้งหมด 13 ตัว และใช้โมเดลโครงข่ายประสาทเทียมร่วมกับเจน เนติกอัลกอริทึม เพื่อรู้จำรูปแบบของการเกิด PD ในอุปกรณ์ไฟฟ้าแรงสูงได้ 3 ประเภทคือ โคโรนาดีสชาร์จ, ดีสชาร์จภายใน และดีสชาร์จตามผิว

ดร.วุฒิชัย ชาติพัฒนานันท์ และคณะ [16-22] ได้นำเสนอวิธีการทางสถิติหลายวิธีมาช่วยในการจำแนกกลุ่ม PD คือการจำแนกกลุ่มโดยใช้ Cluster Analysis, Quick Unbiased and Efficient Statistical Tree, QUEST, การวิเคราะห์ตัวประกอบหลัก (Principal Component Analysis, PCA) และการจำแนกกลุ่ม (Linear Discriminant Analysis), Chi-squared Automatic Interaction Detector (CHAID), Classification and Regression Tree, K-Means ซึ่งจะสามารถจำแนกกลุ่มการเกิด PD ได้โดยใช้ข้อมูลทางสถิติที่ได้จากข้อมูลคุณลักษณะเด่นของ PD แต่ยังไม่ได้พัฒนาในส่วนการเรียนรู้จำรูปแบบการเกิด PD

รัชกร ปานหอทองและคณะ [23] ได้นำเสนอเทคนิคทางสถิติ Kolmogorov-Smirnov One-Sample Test มาวิเคราะห์รูปแบบการเกิด PD และหาคุณลักษณะเฉพาะของรูปแบบการเกิด PD เสมือนเป็นลายนิ้วมือ (fingerprint) และวิเคราะห์สาเหตุการเกิด PD จากผลต่างของรูปเสมือนลายนิ้วมือ ซึ่งใช้รูปแบบรูป เสมือนลายนิ้วมือทั้งหมด 15 รูปแบบหรือตัวแปร 15 ตัว มาใช้ในการวิเคราะห์จำแนกประเภทของการ PD

การจำลองรูปแบบการเกิด PD ที่ผ่านมาของนักวิจัยต่างๆ จะเป็นการจำลองการเกิด PD ที่เกิดขึ้นใน อาการหรือล้อมรอบด้วยอัตราการเปลี่ยนแปลง แต่ในงานวิจัยที่นำเสนอนี้จะมีจุดเด่นตรงที่มีการขยาย การศึกษาการเกิด PD ในน้ำมันสนานซึ่งถือเป็นอัตราการเปลี่ยนแปลงไฟฟ้า ดังนั้นจะมีประโยชน์เป็นอย่างมากต่ออุตสาหกรรมมือแปลงและต่อเสถียรภาพของระบบไฟฟ้า กำลังซึ่งมีมือแปลงเป็นองค์ประกอบ