

# การปรับปรุงอัลกอริทึมดีเอฟทีเอฟสำหรับการประมวลผลแบบทันเวลา

## Development of DFTF algorithm for real-time processing

ณัฐพงษ์ จันทร์แดง

สถาบันนวัตกรรมมหานคร คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีมหานคร

Email: jnattapo@mutacth.com

และ สุทธิภัทร ศรีสุข

สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยนครพนม

Email: srisuk.s@gmail.com

Manuscript Received December 2, 2023

Revised December 9, 2023

Accepted December 17, 2023

### บทคัดย่อ

บทความฉบับนี้ได้ทำการพัฒนาความเร็วในการค้นหาทิศทางการหมุนของวัตถุภายในภาพโดยมีพื้นฐานมาจากระบบการสะสมพีเจอร์จากภาพเทรซทรานฟอร์มสำหรับพยากรณ์ทิศทางการหมุนของวัตถุ (Discriminant Feature Trace Transform : DFTF) [1] ซึ่งมีหลักการคือการนำแมชชีนเลิร์นนิ่งมาพิจารณาข้อมูล DFTF เพื่อพยากรณ์ทิศทางการหมุนของวัตถุ โดยสังเกตว่าเมื่อพิจารณาระยะเวลาซึ่งจะได้มาซึ่งผลลัพธ์ดีเอฟทีเอฟแล้วนั้น จะต้องผ่านขั้นตอนการประมวลผลหลายขั้นตอนและมีความซับซ้อน ดังนั้นแนวทางพัฒนาที่ถูกรับรองภายใต้บทความจะเป็นการมุ่งเน้นที่จะลดความซับซ้อนของขั้นตอนการทำงาน และเพิ่มความเร็วในการหาคำตอบ โดยขั้นตอนแรกคือการลดขนาดของข้อมูลภาพเพื่อลดปริมาณของข้อมูลที่จะถูกนำมาพิจารณาลง จากนั้นทำการลดขั้นตอนของการสร้างข้อมูลในรูปแบบเทรซทรานฟอร์มโดเมนและแทนที่ด้วยการนำแมชชีนเลิร์นนิ่งเพื่อการแปลงข้อมูลภาพให้อยู่ในรูปแบบ DFTF แล้วจึงนำไปเข้าสู่กระบวนการปกติในการพิจารณาการหมุนของวัตถุตามลำดับ โดยทั้งนี้ภายในบทความได้ทำการทดสอบด้วยฐานข้อมูล Caltech-256 ซึ่งสามารถวัดค่าความผิดพลาดของข้อมูลด้วย MSE และ RMSE โดยวิธีการที่นำเสนอโดยมีค่าความ

ผิดพลาดของข้อมูลที่ 4.09, และ 2.2 ตามลำดับ ที่ความเร็วในการทำงานต่อหนึ่งภาพดีที่สุดในที่ 0.12 วินาที โดยมีความแม่นยำเฉลี่ยที่ 98.7%

คำสำคัญ: แมชชีนเลิร์นนิ่ง ดีเอฟทีเอฟ การหมุนของวัตถุ

### ABSTRACT

This paper presents an advancement in the acceleration of object rotation direction detection through the implementation of a feature accumulation system derived from the Discriminant Feature Trace Transform (DFTF). DFTF data will be utilized in conjunction with machine learning to forecast the rotational direction of an object via the DFTF algorithm. It was discovered that in relation to the time required to obtain DFTF results, the procedure is intricate and involves multiple processing steps. As a result, the objective of the development guidelines that are outlined in this article is to accelerate the quest for solutions and streamline the work process. Adjusting the dimensions of the image data is the initial step in reducing the quantity of information that must be computed. Following this, the procedure for producing data in the trace transform domain was eradicated and substituted with machine learning in order to convert the image data to DFTF format. It is then incorporated into the standard procedure for calculating the rotation

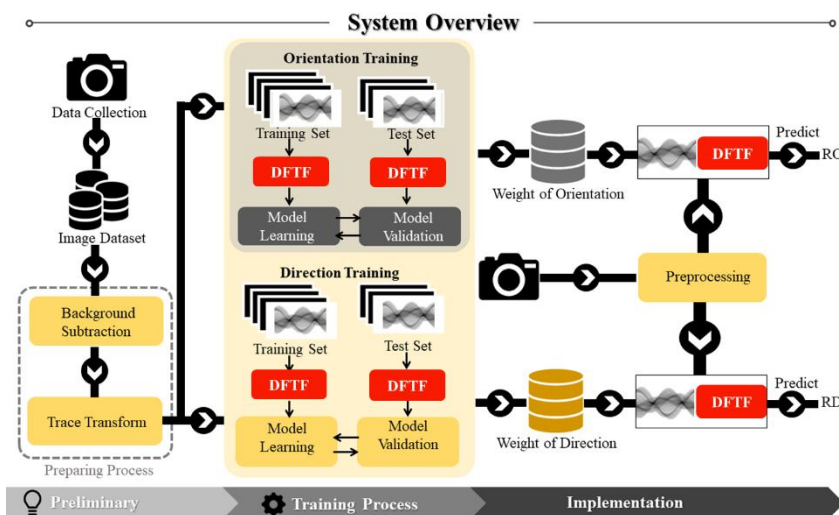
of an object. The outcomes of experiments conducted in this paper utilizing on Caltech-256 database. The suggested method allows for the measurement of data error using Mean Squared Error (MSE) and Root Mean Squared Error (RMSE), with data errors of 4.09 and 2.2, respectively. The optimal running speed per image in this experiment is 0.12 seconds, yielding an average accuracy of 98.7%.

**Keywords:** Machine learning, DFTF, Object rotation

### 1. บทนำ

ณ ปัจจุบันวิวัฒนาการแนวคิดสำหรับการประมวลผลภาพได้เกิดขึ้นมาอย่างมากมาย และเป็นที่ยอมรับจนนำไปสู่การใช้งานสำหรับบุคคลทั่วไป แนวคิดที่ทำให้เกิดนวัตกรรมด้านเทคโนโลยีของการประมวลผลภาพนี้ ได้มีการพัฒนาไปร่วมกันทั้งอุปกรณ์ด้านฮาร์ดแวร์ และซอฟต์แวร์ ซึ่งส่งผลให้วิธีการคำนวณสำหรับประมวลผลภาพที่ซับซ้อนมีการทำงานที่รวดเร็วมากยิ่งขึ้น แม้กระทั่งอัลกอริทึมที่มีความซับซ้อนในอดีตก็สามารถนำกลับมาพัฒนาต่อได้ ในปัจจุบัน อัลกอริทึมเทรซทรานฟอร์มก็เป็นอีกหนึ่งอัลกอริทึมที่ได้รับความนิยมในอดีตเช่นเดียวกัน โดยแนวทางของเทรซทรานฟอร์มมีจุดเด่นในด้านการรู้จำภาพได้อย่างมีประสิทธิภาพโดยอาศัยการแปลงภาพให้อยู่ในอีกลักษณะหนึ่งที่มีคุณสมบัติที่โดดเด่นสำหรับนำไปใช้รู้จำวัตถุ ถึงแม้ว่าวัตถุนั้นจะมีขนาด หรือการวางตัวของวัตถุที่

แตกต่างกันออกไป สำหรับงานรู้จำที่มักจะถูกนำไปใช้งานเช่นการรู้จำภาพจากลักษณะพื้นผิว [2] การรู้จำใบหน้าของมนุษย์ [3] เป็นต้น แต่ปัญหาหนึ่งที่สำคัญนั่นคือความซับซ้อนของการแปลงภาพที่เกิดมาจากความซับซ้อนของสมการในการคำนวณ และขนาดของภาพข้อมูล ยังคงส่งผลให้ไม่สามารถนำมาใช้งานจริงแบบทันเวลาได้ ถึงแม้จะมีความพยายามลดการคำนวณของสมการลงเพื่อให้ทำงานได้รวดเร็วมากขึ้น [4] ที่นำอัลกอริทึมการเรียนรู้แบบมีผู้สอนมาใช้งานร่วมกับการพยากรณ์คำตอบของการคำนวณแต่ละเส้นข้อมูล แต่ก็ยังเป็นเพียงแค่การลดเวลาในการคำนวณบางส่วนเท่านั้น ในขณะที่เมื่อสังเกตภาพรวมของการทำงาน เวลาที่ใช้ในการคำนวณยังมีความเร็วที่ยังไม่เป็นที่น่าพอใจ ดังนั้นจึงต้องหาแนวทางใหม่เพื่อนำมาพัฒนาให้อัลกอริทึมเทรซทรานฟอร์มสามารถทำงานได้อย่างรวดเร็วมากขึ้น แมชชีนเลิร์นนิงถูกนำมาใช้งานเพื่อการพยากรณ์คำตอบในสองลักษณะเป็นหลักนั่นคือ การพยากรณ์คำตอบแบบถดถอย [5] และการพยากรณ์คำตอบแบบจัดหมวดหมู่ [6] โดยทั้งสองรูปแบบนั้นสามารถที่นำมาทดแทนกันได้โดยขึ้นอยู่กับผู้ใช้งานว่าจะมีมุมมองการพยากรณ์คำตอบเป็นแบบใด ยกตัวอย่างเช่น [7] ได้นำเสนออัลกอริทึม Gaussian Process Regression (GPR) เป็นต้น ภายในแมชชีนเลิร์นนิงยังมีอัลกอริทึมที่เป็นที่นิยมสำหรับนำมาใช้งานสำหรับข้อมูลภาพอีกหลายชนิดอย่างที่ไดกล่าวไว้ อาทิเช่น



รูปที่ 1 ระบบ DFTF ต้นฉบับ

Multiple Regression (MR), Logistic Regression (LG), Decision Tree (DT), Random Forest (RF), K-Nearest Neighbors (k-NN), Naïve Bayes (NB), และ Support Vector Machine (SVM) เป็นต้น ผลลัพธ์จากการเลือกใช้แมชชีนเลิร์นนิงสำหรับการประมวลผลภาพนั้นก็มีรูปแบบการนำไปใช้งานที่ต่างกันไป ทั้งนี้การนำไปใช้งานจะขึ้นอยู่กับลักษณะข้อมูลของภาพที่นำมาประมวลผล หรือขึ้นอยู่กับผลลัพธ์ที่ต้องการคำตอบจากการพยากรณ์ ตัวอย่างเช่น [8] ได้ทำการนำเสนอวิธีการจากแมชชีนเลิร์นนิงเพื่อการพิจารณาภาพถ่ายจากคลื่นไฟฟ้าเครื่องกล และเป็นการนำไปสร้างภาพลักษณะใหม่ในลักษณะ 3 มิติ ที่เกิดจากภาพสองมิติ การนำแมชชีนเลิร์นนิงมาช่วยวิเคราะห์ภาพในทางการแพทย์ [9] – [13] ซึ่งเป็นการพิจารณาภาพทางเภสัชกรรมก็อีกหนึ่งลักษณะงานที่นำแมชชีนเลิร์นนิงไปใช้งาน เป็นต้น

หลักการทำการใช้งานแมชชีนเลิร์นนิงที่กล่าวมาทั้งหมดนั้นมีความจำเป็นที่เหมือนกันอยู่หนึ่งลักษณะ นั่นคือการเลือกใช้ข้อมูลในอดีตที่เคยเกิดขึ้นมาก่อน หรือการเตรียมข้อมูลพร้อมคำตอบเพื่อนำมาใช้เป็นตัวอย่างในการพิจารณาสำหรับสร้างการเรียนรู้ให้กับระบบ ซึ่งการนำเสนออัลกอริทึมในบทความฉบับนี้ก็เช่นเดียวกันที่กล่าวคือมีการใช้อัลกอริทึมแมชชีนเลิร์นนิงแบบเรียนรู้แบบมีผู้สอนมาช่วยในการประมวลผล ดังนั้นการสร้างข้อมูลฝึกสอนจะอาศัยข้อมูลจากการประมวลผลจากเทรซทรานฟอร์ม และ DFTF สำหรับอ้างอิงเพื่อถูกใช้สำหรับสร้างโมเดลสำหรับการพยากรณ์คำตอบ อีกทั้งสำหรับการเพิ่มศักยภาพทางด้านความเร็วในการประมวลผลให้กับอัลกอริทึมที่นำเสนอ นั้นมีความจำเป็นที่ต้องมีการพิจารณาถึงจำนวนข้อมูล ที่จะถูกนำมาใช้งาน เพื่อให้ได้คำตอบที่ดีที่สุด และส่งผลต่อความสูญเสียข้อมูลที่สำคัญในการพยากรณ์คำตอบให้น้อยที่สุดเช่นเดียวกัน โดยทั้งหมดนี้เมื่อสามารถลดจำนวนข้อมูลลงได้ และสามารถนำอัลกอริทึมที่ได้คำตอบในรูปแบบ DFTF ได้โดยสามารถข้ามขั้นตอนบางส่วนไป จึงมีความเป็นไปได้ที่จะสามารถใช้งานระบบที่นำเสนอในรูปแบบทันเวลาได้ อัลกอริทึมลักษณะนี้จะเป็นแนวทางในการส่งเสริมให้สามารถนำไปประยุกต์ใช้ในงานลักษณะคล้ายกันได้เช่นเดียวกัน ทั้งนี้วิธีการต่างๆที่ถูกนำมาใช้ในบทความฉบับนี้ จะถูกกล่าวถึง และอธิบายการทำงานในลำดับถัดไป โดยจะมีการเปรียบเทียบให้เห็นถึงระบบต้นฉบับ และระบบใหม่ที่น่าเสนอ

## 2. แนวคิดและทฤษฎี


### 2.1 การสะสมพีเจอร์จากภาพเทรซทรานฟอร์มสำหรับพยากรณ์ทิศทางการหมุนของวัตถุแบบต้นฉบับ

การสะสมพีเจอร์จากภาพเทรซทรานฟอร์มสำหรับพยากรณ์ทิศทางการหมุนของวัตถุ (Discriminant Feature Trace Transform : DFTF) จะแบ่งการทำงานออกเป็นสามขั้นตอนดังรูปที่ 1 คือจัดการข้อมูลขั้นต้น (Preliminary) เป็นการเตรียมความพร้อมของข้อมูลสำหรับการนำไปสร้างโมเดลในขั้นตอนของการเรียนรู้ข้อมูล (Training Process) การนำอัลกอริทึมของแมชชีนเลิร์นนิงมาใช้งานเพื่อเรียนรู้ข้อมูลทีผ่านขั้นตอนการจัดการภาพก่อนหน้า และการนำมาปรับปรุงใช้ (Implementation) คือการนำโมเดลที่ได้รับมาจากขั้นตอนที่สอง มาพยากรณ์ทิศทางการหมุนของวัตถุจากข้อมูลจริง หลักการทำงานของการทำงานจะอาศัยอัลกอริทึมของแมชชีนเลิร์นนิงเพื่อสร้างโมเดลในแต่ละส่วน โดยจะประกอบไปด้วยการอัลกอริทึมสองแบบเพื่อการพยากรณ์ทิศทางการหมุน (Result of Orientation : RO<sub>r</sub>) และเพื่อยืนยันทิศทางการควอดแรนธ์ (Result Of Direction : RD<sub>i</sub>) จากภาพรวมของการพิจารณาคำตอบด้วย DFTF แบบต้นฉบับนั้นพบว่า มีขั้นตอนของการประมวลผลภาพหลายขั้นตอน ส่งผลให้มีระยะเวลาการประมวลผลเป็นระยะเวลานานซึ่งเป็นจุดด้อยของการนำไปใช้งาน โดยเมื่อสังเกตผลของการทำงานภายในระบบ DFTF ต้นฉบับนั้นพบว่า สิ่งที่จะส่งผลต่อระยะเวลาในระบบจะประกอบด้วยระยะเวลาของการประมวลผลภาพขั้นต้น ขนาดข้อมูลภาพที่เลือกมาใช้งาน ฟังก์ชันการคำนวณในแต่ละเส้นข้อมูลของเทรซทรานฟอร์ม และอัลกอริทึมของแมชชีนเลิร์นนิงที่เลือกมาใช้ในการพิจารณาคำตอบ ซึ่งในบทความฉบับนี้ได้นำเสนอแนวทางสำหรับการปรับปรุงระบบ DFTF ต้นฉบับโดยจะมีการอธิบายดังหัวข้อถัดไป

### 2.2 การลดขนาดของภาพ

การลดขนาดของข้อมูลก่อนนำเข้าสู่ระบบ ในขั้นตอนนี้สามารถใช้อัลกอริทึมที่มีความเรียบง่ายอย่างการลดขนาดของความกว้างและความสูงของภาพตามอัตราส่วนมาใช้งานได้ตามปกติดังรูปที่ 2 โดยวิธีนี้จะเกิดประโยชน์ต่อการนำข้อมูลภาพไปใช้งานภายใต้เงื่อนไขสำหรับการค้นหาทิศทางหมุน เนื่องจากเมื่อภาพมีขนาดที่เล็กลง นั้นหมายถึงจำนวนของข้อมูลที้นำไปผ่านการคำนวณจาก

โมเดลของแมชชีนเลิร์นนิงเพื่อสร้างค่าน้ำหนักสำหรับการพยากรณ์คำตอบ จะมีจำนวนลดลงไปด้วย ทั้งนี้ยังลดขนาดภาพลงได้เท่าไรก็ได้ยังได้ความเร็วที่เพิ่มขึ้นเช่นเดียวกัน แต่การลดขนาดของภาพจะมีข้อดีคือการสูญเสียข้อมูลบางอย่างที่อาจจะทำให้เกิดผลเสียต่อการนำไปใช้งานในบางประเภทเช่นการรู้จำภาพ แต่เนื่องจากภายในบทความต้องการในการค้นหาทิศทางการหมุนของวัตถุ ดังนั้นแม้ข้อมูลภาพจะมีการสูญเสียไปแต่จะไม่ส่งผลกระทบต่อการค้นหาข้อมูลดังกล่าว ในการประมวลผลภาพลำดับต่อไป เป็นการนำข้อมูลภาพที่ลดปริมาณลงไปตามขั้นตอนจากอัลกอริทึมแมชชีนเลิร์นนิงเพื่อสร้างข้อมูลแบบ DFTF ซึ่งจะอธิบายได้ดังหัวข้อที่ 2.3



รูปที่ 2 การลดขนาดของภาพ


การลดขนาดของภาพสามารถแทนได้ดังสมการที่ 1 เมื่อ  $I$  แทนภาพต้นฉบับ และ  $s$  แทนขนาดการปรับขนาดของภาพซึ่งคิดเป็นเปอร์เซ็นต์ และ  $X$  คือผลลัพธ์จากการลดขนาดภาพ โดยทั้งนี้การปรับขนาดภาพจะส่งผลกระทบต่อความเร็วในระบบเช่นกัน

$$X = \text{resize}(I, s) \tag{1}$$

### 2.3 การสร้างข้อมูล DFTF ด้วยแมชชีนเลิร์นนิง

การสร้างข้อมูลในรูปแบบ DFTF [1] สำหรับนำไปพิจารณาการหมุนของวัตถุด้วยแมชชีนเลิร์นนิงเป็นการพัฒนาที่มีพื้นฐานอยู่บนอัลกอริทึมเทรซทรานฟอร์ม ด้วยการลดขั้นตอนของการสร้างข้อมูลจากเทรซทรานฟอร์มด้วยแมชชีนเลิร์นนิง โดยทั้งนี้ในขั้นตอนของการฝึกสอนยังคงมีความจำเป็นสำหรับความต้องการในการสร้างข้อมูลจากอัลกอริทึมต้นฉบับ เนื่องจากการที่จะได้รับข้อมูลในรูปแบบ DFTF สำหรับฝึกสอนนั้นจะต้องทำการเตรียมข้อมูลชุดฝึกในรูปแบบเดียวกันไว้ ดังนั้นเมื่อทำการทดลองต่อเนื่องจากจากอัลกอริทึมต้นฉบับ จะสังเกตลักษณะข้อมูลของ DFTF ได้ว่ามี

ตำแหน่งข้อมูลลำดับตั้งแต่ 0 ถึง 359 ซึ่งจะเกิดจากทิศทางที่ทำการหมุนและคำนวณปกติจากอัลกอริทึมเทรซทรานฟอร์มดังรูปที่ 3 (ก) ซึ่งเป็นรูปแบบเส้นข้อมูล และสามารถแทนเป็นตำแหน่งอาเรย์ได้ดังรูปที่ 3 (ข)



(ก) ตัวอย่างข้อมูล DFTF ในรูปแบบข้อมูลภาพ

$DFTF_0$	$DFTF_1$	$DFTF_2$	...	$DFTF_{359}$
----------	----------	----------	-----	--------------

(ข) ตัวอย่างข้อมูล DFTF ในรูปแบบอาเรย์

### รูปที่ 3 ลักษณะเส้นข้อมูล DFTF

ซึ่งสังเกตได้ว่าตำแหน่งของข้อมูลในเส้นข้อมูลแต่ละตำแหน่งจะมีผลลัพธ์ที่แตกต่างกันออกไปแต่ข้อมูลภาพที่นำมาพยากรณ์ค่า DFTF สำหรับภาพจะไม่มีการเปลี่ยนแปลง ดังนั้นเพื่อให้เกิดผลลัพธ์ที่มีความแตกต่างกันในตำแหน่ง 0 ถึง 359 จึงต้องมีการสร้างค่าน้ำหนักแยกสำหรับพยากรณ์กันในแต่ละตำแหน่งเช่นเดียวกัน ซึ่งการสร้างค่าน้ำหนักแยกไว้ในแต่ละตำแหน่งแสดงได้ดังรูปที่ 4 เป็นการแทนที่การเก็บตารางค่าน้ำหนักที่ได้ในแต่ละตำแหน่งสำหรับนำมาพยากรณ์ค่า DFTF เมื่อ  $Weight_{DFTF_0}$  แทนข้อมูลค่าน้ำหนักสำหรับพยากรณ์ DFTF ลำดับที่ 0  $Weight_{DFTF_1}$  แทนข้อมูลค่าน้ำหนักสำหรับพยากรณ์ DFTF ลำดับที่ 1 และ  $Weight_{DFTF_{359}}$  แทนข้อมูลค่าน้ำหนัก DFTF ลำดับที่ 359

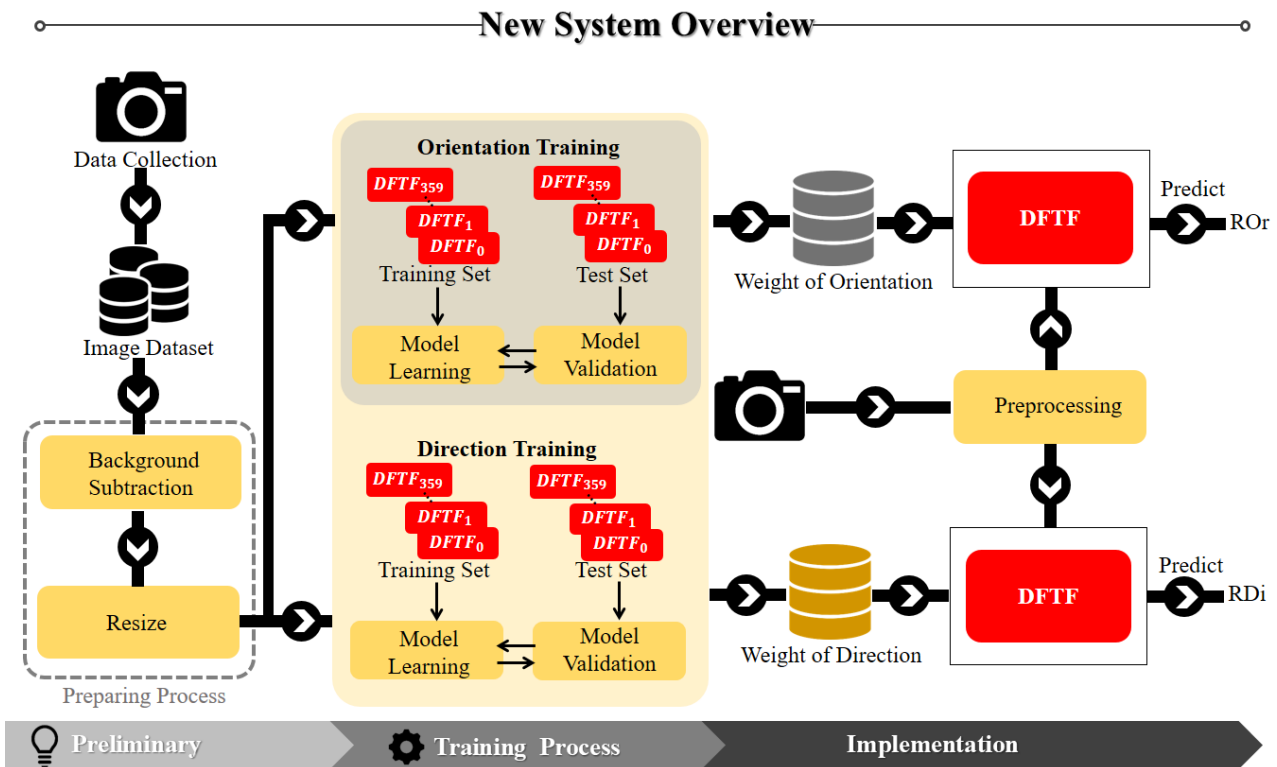
ดังนั้นตัวอย่างสำหรับการฝึกสอนข้อมูลเพื่อสร้างค่าน้ำหนัก DFTF ลำดับที่  $i$  จะแทนได้ดังตารางที่ 1 โดยที่  $i$  มีค่าตั้งแต่ 0 ถึง 359

$Weight_{DFTF_0}$	$Weight_{DFTF_1}$	...	$Weight_{DFTF_{359}}$
-------------------	-------------------	-----	-----------------------

รูปที่ 4 ลักษณะเส้นข้อมูล DFTF

ตารางที่ 1 ตารางข้อมูลฝึกสอนสำหรับค่าน้ำหนัก DFTF ตำแหน่งที่  $i$

$X_1$	$X_2$	$X_3$	...	$X_n$	DFTF
$x_{1,1}$	$x_{2,1}$	$x_{3,1}$	...	$x_{n,1}$	$DFTF_i$
$x_{1,2}$	$x_{2,2}$	$x_{3,2}$	...	$x_{n,2}$	$DFTF_i$
$\vdots$	$\vdots$	$\vdots$	...	$\vdots$	$\vdots$
$x_{n,m}$	$x_{2,m}$	$x_{3,m}$	...	$x_{n,m}$	$DFTF_i$



รูปที่ 5 ระบบ DFTF แบบปรับปรุง

## 2.4 การสะสมพีเจอร์จากภาพเทรซทรานฟอร์มสำหรับพยากรณ์ทิศทางการหมุนของวัตถุแบบปรับปรุง

จากแนวทางที่นำเสนอจะสามารถนำมาอธิบายระบบใหม่ได้ดังรูปที่ 5 เป็นรูปแบบระบบ DFTF แบบปรับปรุง สิ่งที่เปลี่ยนไปจากแบบดั้งเดิมคือการประมวลผลภาพด้วยเทรซทรานฟอร์มนั้นถูกตัดออกไป และนำการฝึกสอนข้อมูลจากภาพที่ถูกลดขนาดมาแปลงภาพผ่านค่าน้ำหนักของ DFTF เพื่อสร้างภาพในรูปแบบ DFTF ได้ทันที ดังนั้นความซับซ้อนในการนำไปใช้งานจริงจะลดลงเนื่องจากเมื่อสังเกตส่วนของการนำไปใช้ ผู้ใช้งานเพียงจัดการข้อมูลภาพเบื้องต้นและลดขนาดภาพตามขนาดที่เหมาะสมกับค่าน้ำหนักของ DFTF จากนั้นภายในระบบจะสามารถสร้างข้อมูลที่ใช้ทำงานต่อในส่วนของการทิศทางการหมุน (ROr) และทิศทางการควอแดรนต์ (RDl) ในลำดับต่อไปได้ทันที

หัวใจหลักของการเปลี่ยนแปลงในการปรับปรุงครั้งนี้คือการสร้างกลุ่มค่าน้ำหนัก DFTF สำหรับแปลงข้อมูลภาพให้กลายเป็นข้อมูล DFTF เนื่องจากขั้นตอนนี้เป็นการลดภาระของการคำนวณด้วย

เทรซทรานฟอร์มออกจากระบบดั้งเดิม ดังนั้นจึงควรให้ความสำคัญต่อการสร้างค่าน้ำหนักกลุ่มนี้มากที่สุด เพื่อให้สามารถนำไปพยากรณ์ทิศทางการหมุนด้วยค่า ROr และ RDl ได้ในขั้นตอนต่อไป โดยวิธีการสร้างกลุ่มค่าน้ำหนักสำหรับ DFTF นั้นจะอยู่ในขั้นตอนการฝึกขึ้น ซึ่งจะเป็นการใช้ค่า DFTF ที่ถูกจัดเตรียมไว้สำหรับพยากรณ์ค่าในทุกตำแหน่งตั้งแต่อาเรย์ของข้อมูลตำแหน่งที่ 0 ถึงตำแหน่งที่ 359 ดังนั้นในการสร้างค่าน้ำหนักสำหรับพยากรณ์ค่า DFTF ในส่วนนี้ จะได้รับเป็นค่าน้ำหนักทั้งหมด 360 ค่า เพื่อพยากรณ์ค่าน้ำหนักสำหรับ DFTF ในแต่ละตำแหน่ง โดยการเลือกใช้อัลกอริทึมสำหรับทำแมชชีนเลิร์นนิงจะขึ้นอยู่กับความเหมาะสมกับข้อมูลภาพที่นำมาใช้งาน

โดยทั้งนี้สามารถเขียนแผนการทำงานสำหรับการฝึกสอนข้อมูลเพื่อสร้างค่าน้ำหนัก ROr และ RDl ได้ดังตารางที่ 2 และสามารถเขียนแผนงานสำหรับการนำไปใช้งานได้ดังตารางที่ 3

**ตารางที่ 2 การสร้างค่าน้ำหนัก ROr และ RDl**

1. รับภาพ
2. อ่านข้อมูลภาพ
3. ลบพื้นหลังของวัตถุ
4. ลดขนาดของภาพ
5. สร้าง DFTF จาก ข้อมูลในตารางที่ 1 ด้วยแมชชีนเลิร์นนิง
6. สร้างข้อมูล DFTF
7. สร้างค่าน้ำหนักสำหรับ Orientation และ Direction จาก DFTF

**ตารางที่ 3 การใช้งานค่าน้ำหนัก DFTF ROr และ RDl**

1. รับภาพ
2. อ่านข้อมูลภาพ
3. ลบพื้นหลังของวัตถุ
4. ลดขนาดของภาพตามที่กำหนดจากส่วนฝึกสอน
5. สร้างข้อมูล DFTF ด้วยค่าน้ำหนัก
6. นำค่าน้ำหนักมาพยากรณ์คำตอบ ROr และ RDl

**3. ผลการทดลอง**



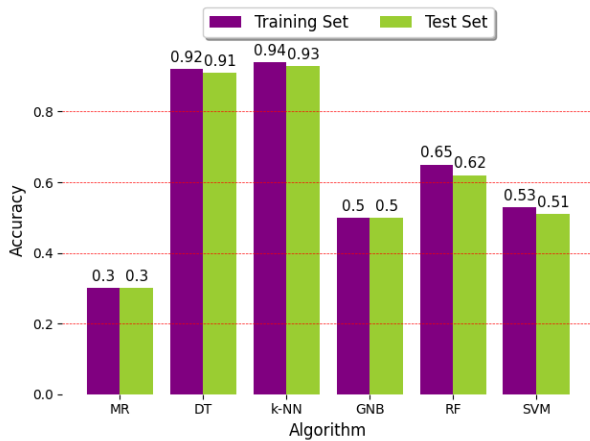
**รูปที่ 6 ตัวอย่างข้อมูลภาพจากฐานข้อมูล Caltech-256**

บทความฉบับนี้ได้ดำเนินการทดลองอยู่บนพื้นฐานภาษาไพธอน เวอร์ชัน 3.7 ด้วยคอมพิวเตอร์ที่ทำการติดตั้งระบบปฏิบัติการ Windows 10 64-bit ประมวลผลด้วย CPU intel core i7-6700 3.40 GHz และมีขนาดแรมอยู่ที่ 16 GB สำหรับอัลกอริทึมด้าน machine learning ที่นำมาเปรียบเทียบมาจากพื้นฐานไลบรารี Scikit-learn และการทดลองทั้งหมด ได้ทำการทดลองอยู่บน


ฐานข้อมูล Caltech-256 (256 object classes and an additional clutter class) [14] และทำการสุ่มเลือกกลุ่มของข้อมูล มาทดสอบทั้งสิ้น 5 กลุ่มดังรูปที่ 6 เพื่อหาค่าเฉลี่ยของความเร็ว ความผิดพลาดของข้อมูล และผลความแม่นยำเมื่อนำไปใช้งาน สำหรับการพยากรณ์ทิศทางการหมุนของวัตถุ โดยการทดลองนั้นได้ ทำการกำหนดขนาดภาพไว้ที่ 633x633 590x590 360x360 180x180 90x90 และ 45x45 พิกเซล

การแสดงข้อมูลกลุ่มแรกเป็นการเลือกใช้การเรียนรู้จาก อัลกอริทึมแมชชีนเลิร์นนิงที่มีความเหมาะสมกับข้อมูลโดยจะต้องมี ค่าการเรียนรู้ที่แม่นยำโดยจากการทดลองพบว่า อัลกอริทึม Decision Tree (DT) และอัลกอริทึม k-Nearest Neighbors (k-NN) ให้ค่าความแม่นยำเฉลี่ยในกลุ่มของข้อมูลการเรียนรู้ และข้อมูล การทดสอบสำหรับการสร้างกลุ่มค่าน้ำหนักสำหรับ DFTF มากที่สุด โดยทั้งสองอัลกอริทึมมีค่าความแม่นยำมากกว่า 90 เปอร์เซ็นต์สำหรับ กลุ่มข้อมูลการฝึกสอน และมีความแม่นยำมากกว่า 85 เปอร์เซ็นต์ สำหรับกลุ่มข้อมูลการทดสอบซึ่งแสดงได้ดังรูปที่ 7 จากข้อมูลเหล่านี้ จะพิจารณาในขั้นต้นได้ว่า อัลกอริทึม DT และ k-NN มีความเป็นไปได้ สำหรับการนำมาสร้างกลุ่มค่าน้ำหนักสำหรับ DFTF มากที่สุด

ลำดับการทดลองต่อมาเป็นการทดสอบผลของการลดขนาดของ ข้อมูลภาพเพื่อตรวจสอบการมีผลต่อการประมวลผลด้วย อัลกอริทึม DFTF ต้นฉบับ จากการผลลัพธ์การทดลอง [15] ได้ทำ การทดสอบความเร็วของการคำนวณด้วยเทรซทรานฟอร์มต่อหนึ่ง ภาพต่อหนึ่งฟังก์ชันดังรูปที่ 8 พบว่าขนาดภาพและฟังก์ชันมีผลต่อ การประมวลผลด้วยเทรซทรานฟอร์มโดยจากการทดลอง เมื่อลด ขนาดภาพที่ขนาด 45x45 พิกเซล ผลการประมวลผลด้วยเทรซทราน ฟอรมจะใช้เวลาน้อยที่สุดรวมถึงการใช้อัลกอริทึมแมชชีนเลิร์นนิง ด้วยเช่นเดียวกัน โดยทุกอัลกอริทึมมีความเร็วที่ต่ำกว่า 2 วินาที และ เมื่อปรับขนาดภาพขึ้นไปทีขนาด 90x90 พิกเซล จะสังเกตถึงแนวโน้ม ของการใช้เวลาในการประมวลผลด้วยแมชชีนเลิร์นนิงที่เพิ่มขึ้น แต่ ผลจากเทรซทรานฟอร์มยังมีความเร็วในการประมวลผลใกล้เคียง ผลลัพธ์เดิม และเมื่อเพิ่มขนาดมาที่ 180x180 พิกเซล เริ่มเห็น แนวโน้มของการประมวลผลภาพด้วยฟังก์ชันที่ 1 ถึง 8 ที่เพิ่มมากขึ้น และที่ขนาด 360x360 ฟังก์ชันและทุกอัลกอริทึมที่นำมาทดสอบมี การประมวลผลต่อหนึ่งภาพมากกว่า 1 วินาที โดยพบว่าอัลกอริทึม k-NN ใช้ระยะเวลาในการประมวลผลที่มากที่สุดที่มากกว่า 18 วินาที ในขณะที่ฟังก์ชันลำดับที่ 1 ของเทรซทรานฟอร์มใช้เวลาที่น้อยที่สุด



รูปที่ 7 ความแม่นยำจากการฝึกสอน และทดสอบสำหรับค่าน้ำหนัก DFTF



รูปที่ 8 ความเร็วในการประมวลผลภาพ

จากการทดลอง เมื่อทำการการวัดประสิทธิภาพของผลลัพธ์ที่ได้ในแต่ละขนาดนั้นด้วยการลดขนาดภาพที่ขนาดต่างๆในระบบ DFTF นั้นพบว่า ที่ขนาดภาพ 633x633 และ 590x590 พิกเซลนั้นในระบบ DFTF แบบปรับปรุง และแบบต้นฉบับไม่สามารถทำการทดสอบได้เนื่องจากข้อจำกัดของการจัดสรรทรัพยากรภายในอุปกรณ์ทดสอบ ดังนั้นจึงเริ่มพิจารณาที่ขนาดภาพ 360x360 ถึง 45x45 พิกเซล ซึ่งพบว่า DFTF แบบปรับปรุง และแบบต้นฉบับมีค่าเท่ากัน ดังแสดงในตารางที่ 4

ตารางที่ 4 ผลการวัดผลค่าความผิดพลาดของข้อมูล

Method	Image size	MSE	RMSE
DFTF แบบปรับปรุง	633x633	x	x
	590x590	x	x
	360x360	2.10	1.44
	300x300	2.10	1.44
	180x180	4.10	2.02
	90x90	4.10	2.02
	45x45	4.09	2.02
DFTF แบบต้นฉบับ	633x633	x	x
	590x590	x	x
	360x360	2.10	1.44
	300x300	2.10	1.44
	180x180	4.10	2.02
	90x90	4.10	2.02
	45x45	4.09	2.02

ตารางที่ 5 ผลการวัดผลความเร็วในการประมวลผลทั้งระบบ

Method	Image size	Best (s)	Worst (s)
DFTF แบบปรับปรุง	633x633	7.32	9.11
	590x590	6.02	8.60
	360x360	5.01	7.64
	300x300	4.03	6.58
	180x180	2.55	4.56
	90x90	1.05	2.12
	45x45	0.12	0.75
DFTF แบบต้นฉบับ	633x633	11.52	77.02
	590x590	10.15	59.44
	360x360	2.13	39.27
	300x300	2.04	20.82
	180x180	2.00	12.78
	90x90	1.57	6.14
	45x45	1.36	2.98

การทดสอบความเร็วของการประมวลผลจากอัลกอริทึมแบบปรับปรุงและแบบต้นฉบับจะแสดงดังตารางที่ 5 ซึ่งเป็นการทดลอง

ประมวลผลภาพที่ขนาดต่าง ๆ โดยเริ่มทำการทดสอบด้วยภาพขนาดใหญ่ที่สุดคือ 633x633 พิกเซล และทำการลดขนาดลงมาเล็กที่สุดคือ 45x45 พิกเซล จากนั้นทำการวัดระยะเวลาของการประมวลผลทั้งระบบโดยที่ DFTF แบบต้นฉบับยังคงใช้การคำนวณด้วยทรซฟังก์ชัน และ DFTF แบบปรับปรุงใช้อัลกอริทึมแมชชีนเลิร์นนิ่งทดแทน โดยในการทดสอบเนื่องจากผลความแม่นยำในการหาคำตอบของข้อมูลภาพขนาด 633x633 พิกเซลนั้นมีประสิทธิภาพที่ต่ำเป็น ในการทดลองนี้จึงเป็นเพียงการพยายามสร้างค่าน้ำหนักขึ้นมาเพื่อทดสอบความเร็วในการประมวลผลเท่านั้น ซึ่งพบว่าระบบ DFTF แบบปรับปรุงใช้เวลาได้เร็วกว่า DFTF แบบต้นฉบับโดยที่ขนาดภาพ 633x633 พิกเซล DFTF แบบปรับปรุงใช้เวลาเร็วที่สุดใน การประมวลผลอยู่ที่ 7.32 วินาที และช้าที่สุดอยู่ที่ 9.11 วินาที ในขณะที่ DFTF แบบต้นฉบับใช้เวลาเร็วที่สุดอยู่ที่ 11.52 วินาที และช้าที่สุดอยู่ที่ 77.02 วินาที และสำหรับการลดขนาดภาพที่เล็กที่สุดของทั้งสองระบบพบว่า DFTF แบบปรับปรุงใช้เวลาเร็วที่สุดอยู่ที่ 0.12 วินาที ในขณะที่ DFTF แบบต้นฉบับใช้เวลาเร็วที่สุดอยู่ที่ 1.36 วินาที ผลลัพธ์จากความเร็วในการประมวลผลนี้แสดงให้เห็นถึงแนวทางในการพัฒนาการประมวลผลภาพด้วยระบบ DFTF ที่มีความเป็นไปได้มากขึ้น

ตารางที่ 6 ความแม่นยำจากฐานข้อมูล Caltech-256 ทั้ง 5 คลาส

	ice-cream	blimp	Eiffel	cactus	bowling-pin	Avg
0°	99.9	99.8	99.5	99.8	99.8	99.76
45°	99.9	96.9	96.7	96.7	96.7	97.38
90°	99.9	99.8	99.8	99.8	99.9	99.84
135°	92.8	95.3	99.8	97.3	96.8	96.4
180°	99.9	99.9	99.8	99.8	99.8	99.84
225°	99.9	99.8	96.7	96.7	99.9	98.6
270°	99.9	99.9	99.8	99.8	99.8	99.84
315°	96.2	99.8	95.5	99.8	98.5	97.96
Avg	98.55	98.9	98.45	98.71	98.9	

การทดลองส่วนสุดท้ายคือการนำระบบ DFTF แบบปรับปรุงมาทดสอบวัดผลความแม่นยำจากการพยากรณ์ทิศทางอารมณ์ของวัตถุ โดยการทดลองนี้กระทำบนฐานข้อมูล Caltech-256 ซึ่งเป็นฐานข้อมูลมาตรฐานที่เปิดเป็นสาธารณะสำหรับการนำมาทดสอบ

ด้วยหัวข้อปัญหาต่าง ๆ ซึ่งการทดลองในบทความฉบับนี้ มุ่งเน้นไปที่การค้นหาทิศทางอารมณ์ของวัตถุ ดังนั้นในการทดลองจึงแบ่งกลุ่มอารมณ์ของวัตถุที่ทิศทางต่าง ๆ ในแต่ละกลุ่มของข้อมูลทำการเลือกมาทดสอบซึ่งประกอบไปด้วยข้อมูล ice-cream, blimp, Eiffel, cactus และ bowling-pin โดยมีทิศทางอารมณ์ของข้อมูลทุกกลุ่มอยู่ที่ 0 องศา ถึง 315 องศา ซึ่งเป็นการเลื่อนไปทุก ๆ 45 องศาในการทดสอบ จากผลการทดลองในตารางที่ 6 พบว่ากลุ่มข้อมูล ice-cream มีความแม่นยำเฉลี่ยที่ 98.55 เปอร์เซ็นต์ กลุ่มข้อมูล blimp มีความแม่นยำเฉลี่ยที่ 98.9 เปอร์เซ็นต์ กลุ่มข้อมูล Eiffel มีความแม่นยำเฉลี่ยที่ 98.45 เปอร์เซ็นต์ กลุ่มข้อมูล cactus มีความแม่นยำเฉลี่ยที่ 98.71 เปอร์เซ็นต์ กลุ่มข้อมูล bowling-pin มีความแม่นยำเฉลี่ยที่ 98.9 เปอร์เซ็นต์ และในแต่ ละทิศทางอารมณ์ของวัตถุที่นำมาทดสอบพบว่าที่อารมณ์ 0 องศา จากข้อมูลทุกคลาสมีความแม่นยำเฉลี่ยอยู่ที่ 99.76 เปอร์เซ็นต์ ที่อารมณ์ 45 องศา จากข้อมูลทุกคลาสมีความแม่นยำเฉลี่ยอยู่ที่ 97.38 เปอร์เซ็นต์ ที่อารมณ์ 90 องศา จากข้อมูลทุกคลาสมีความแม่นยำเฉลี่ยอยู่ที่ 99.84 เปอร์เซ็นต์ ที่อารมณ์ 135 องศา จากข้อมูลทุกคลาสมีความแม่นยำเฉลี่ยอยู่ที่ 96.4 เปอร์เซ็นต์ ที่อารมณ์ 180 องศา จากข้อมูลทุกคลาสมีความแม่นยำเฉลี่ยอยู่ที่ 99.84 เปอร์เซ็นต์ ที่อารมณ์ 225 องศา จากข้อมูลทุกคลาสมีความแม่นยำเฉลี่ยอยู่ที่ 98.6 เปอร์เซ็นต์ ที่อารมณ์ 270 องศา จากข้อมูลทุกคลาสมีความแม่นยำเฉลี่ยอยู่ที่ 99.84 เปอร์เซ็นต์ และที่อารมณ์ 315 องศา จากข้อมูลทุกคลาสมีความแม่นยำเฉลี่ยอยู่ที่ 97.96 เปอร์เซ็นต์ โดยสรุปตารางของข้อมูลแล้วพบว่าทิศทางอารมณ์ที่ได้ผลลัพธ์ที่ดีที่สุดในการพยากรณ์คำตอบอยู่ที่ทิศทาง 90 180 และ 270 องศา ซึ่งมีความแม่นยำที่ 99.84 เปอร์เซ็นต์เท่ากัน และทิศทางอารมณ์ที่ได้ผลลัพธ์ที่ความแม่นยำต่ำที่สุดในการพยากรณ์คำตอบอยู่ที่ทิศทาง 135 องศาที่ความแม่นยำ 96.4 เปอร์เซ็นต์

4. สรุป

งานวิจัยฉบับนี้ได้นำเสนอวิธีการปรับปรุงอัลกอริทึม Discriminant Feature Trace Transform (DFTF) ที่ถูกนำมาใช้ในการพิจารณาภาพสำหรับการพยากรณ์ทิศทางอารมณ์ของวัตถุ โดยมีเป้าหมายเพื่อลดระยะเวลาการทำงานสำหรับการนำไปใช้ในแบบทันทีซึ่งจากการสังเกตพบว่าระบบ DFTF เดิมนั้นจะใช้เวลาในการประมวลผลในส่วนของการสร้างทรซทรานฟอร์มโดเมนที่จะกิน




ระยะเวลาสั้น ทำให้ส่วนของการพิจารณาค่า DFTF จะสามารถพยากรณ์คำตอบจากแมชชีนเลิร์นนิงได้เร็ว แต่จะติดปัญหาตรงส่วนของการสร้างข้อมูลเริ่มต้น ดังนั้นแนวทางที่นำเสนอสำหรับการแก้ไขปัญหาคือการนำแมชชีนเลิร์นนิงมาพิจารณาค่า DFTF ทดแทนการสร้างด้วยเทรซทรานฟอร์ม โดยจากการทดลองแล้วพบว่ามีความแม่นยำในการสร้าง DFTF มากกว่า 90 เปอร์เซ็นต์ด้วยอัลกอริทึม DT และ k-NN ซึ่งสามารถตรวจสอบค่าความผิดพลาด MSE และ RMSE มีค่าความผิดพลาดต่ำสุดอยู่ที่ 4.09 และ 2.02 ตามลำดับ โดยเมื่อนำมาทดสอบในด้านของความเร็วในการประมวลผลทั้งระบบ DFTF แบบปรับปรุงใช้เวลาเร็วที่สุดที่ 0.12 วินาที ในขณะที่ DFTF แบบดั้งเดิมใช้เวลาเร็วที่สุดอยู่ที่ 1.36 วินาที โดยทดสอบที่ขนาดภาพ 45x45 พิกเซล และมีความแม่นยำในทุกทิศทางทดสอบอยู่ที่ 98.7 เปอร์เซ็นต์

### เอกสารอ้างอิง

- [1] Nattapong Jundang and Suchada Sitjongsatoporn, "Discriminant Feature Trace Transform for Predictive Object Rotation", International Journal of Intelligent Engineering and Systems, vol. 16, No. 1, pp. 419-434, 2023.
- [2] X. Zhang and J. Saniie, "Material Texture Recognition using Ultrasonic Images with Transformer Neural Networks," 2021 IEEE International Conference on Electro Information Technology (EIT), Mt. Pleasant, MI, USA, pp. 1-5 2021.
- [3] A. Kumari Sirivarshitha, K. Sravani, K. S. Priya and V. Bhavani, "An approach for Face Detection and Face Recognition using OpenCV and Face Recognition Libraries in Python," 2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS), Coimbatore, India, pp. 1274-1278, 2023.
- [4] N. Jundang, "Development of Trace Transform using Machine Learning for reducing the tracing line calculation," 2022 International Electrical Engineering Congress (iEECON), Khon Kaen, Thailand, pp. 1-4, 2022.
- [5] Y. Huang and W. Liu, "Regression Analysis Model Based on Data Processing and MATLAB Numerical Simulation," 2022 IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers (IPEC), Dalian, China, pp. 1115-1118, 2022.
- [6] H. A. Sayyed, S. Rushikesh Sugave, S. Paygude and B. N. Jazdale, "Study and Analysis of Emotion Classification on Textual Data," 2021 6th International Conference on Communication and Electronics Systems (ICCES), Coimbatore, India, pp. 1128-1132, 2021.
- [7] X. Chang, "Soft Measurement Modeling of Turbidity in Flocculation Process of Drinking Water Treatment Using Gaussian Process Regression," 2021 40th Chinese Control Conference (CCC), Shanghai, China, pp. 6196-6200, 2021.
- [8] L. Melki, M. Tourni and E. E. Konofagou, "Electromechanical Wave Imaging With Machine Learning for Automated Isochrone Generation," in IEEE Transactions on Medical Imaging, vol. 40, no. 9, pp. 2258-2271, Sept. 2021.
- [9] B. M. Rashed and N. Popescu, "Machine Learning Techniques for Medical Image Processing," 2021 International Conference on e-Health and Bioengineering (EHB), Iasi, Romania, pp. 1-4, 2021.
- [10] M. Sabouri et al., "Cardiac Pattern Recognition from SPECT

Images Using Machine Learning Algorithms," 2021 IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC), Piscataway, NJ, USA, pp. 1-3, 2021.

- [11] N. Jan, A. Makhdoomi, P. Handa and N. Goel, "Machine learning approaches in medical image analysis of PCOS," 2022 International Conference on Machine Learning, Computer Systems and Security (MLCSS), Bhubaneswar, India, pp. 48-52, 2022.
- [12] A. Sivasangari, Sivakumar, S. Helen, S. Deepa, Vignesh and Suja, "Detection of Abnormalities in Brain using Machine Learning in Medical Image Analysis," 2022 International Conference on Sustainable Computing and Data Communication Systems (ICSCDS), Erode, India, pp. 102-107, 2022.
- [13] A. Makhdoomi, N. Jan, P. Palak and N. Goel, "Machine learning techniques for medical images in PCOS," 2022 4th International Conference on Artificial Intelligence and Speech Technology (AIST), Delhi, India, pp. 1-6, 2022.
- [14] G. Griffin, A. Holub, and P. Perona, "Caltech256 Object Category Dataset", Technical Report 7694, 2007.
- [15] Nattapong Jundang and Suchada Sitjongsatoporn, "Coordinated-axis Weight for Real-Time Trace Transform", in Proc. IEEE International Electrical Engineering Congress (iEECON), Krabi, Thailand, pp. 184-187, 2023.



**ผู้ช่วยศาสตราจารย์ ดร.ณัฐพงษ์ จันทรแดง** จบการศึกษาวิศวกรรมศาสตรบัณฑิต (วิศวกรรมคอมพิวเตอร์) วิศวกรรมศาสตรมหาบัณฑิต (วิศวกรรมไฟฟ้า สาขาย่อย คอมพิวเตอร์) และ วิศวกรรมศาสตรดุษฎีบัณฑิต (วิศวกรรมไฟฟ้า สาขาย่อย คอมพิวเตอร์) มหาวิทยาลัยเทคโนโลยีมหานคร ปัจจุบันเป็นอาจารย์ประจำภาควิชาวิศวกรรมคอมพิวเตอร์และปัญญาประดิษฐ์ สถาบันนวัตกรรมมหานคร โดยดำรงตำแหน่งเป็นหัวหน้าภาควิชา มีหัวข้องานวิจัยที่สนใจได้แก่ การประมวลผลสัญญาณและภาพดิจิทัล (Signal and image processing) การรู้จำแบบ (Pattern recognition) การรู้จำภาพ (Image recognition) และปัญญาประดิษฐ์ (Artificial intelligence)



**รองศาสตราจารย์ ดร.สุทธิภัทร ศรีสุข** ปัจจุบันดำรงตำแหน่ง คณบดีคณะวิศวกรรมศาสตร์ มหาวิทยาลัยนครพนม จบการศึกษาระดับปริญญาเอกจาก มหาวิทยาลัยเทคโนโลยีมหานคร (พ.ศ. 2546) และเป็นนักวิจัย ณ มหาวิทยาลัยเออร์เรย์ ระหว่างศึกษาปริญญาเอก มีความสนใจและเชี่ยวชาญด้านไบโอเมทริก (การรู้จำภาพใบหน้า/ม่านตา/ลายนิ้วมือ)

การประมวลผลภาพ การรู้จำภาพ และคอมพิวเตอร์วิชั่น มีผลงานวิจัยตีพิมพ์ในระดับนานาชาติและระดับชาติมากกว่า 80 บทความ มีหนังสือ 3 เล่ม ได้รับรางวัลบทความดีเด่นจำนวน 4 บทความ ได้รับรางวัลค่าความผิดพลาดต่ำสุดในการแข่งขันการรู้จำภาพใบหน้า ณ ประเทศอังกฤษ เป็นผู้ประเมินบทความให้กับวารสารนานาชาติ เช่น Journal of Digital Signal Processing, IEEE

Transactions on System, Man and Cybernetics เป็น TPC Chair ในการประชุมวิชาการ IWAIT, ACTIS มีผลงานวิจัยที่เชื่อมโยงกับภาคอุตสาหกรรม โดยมีการนำไปใช้จริงในเชิงพาณิชย์ เช่นระบบ Video Analytics, ระบบ Traffic Analysis, ระบบ Bio Cloud