



การจำแนกเด็กที่มีภาวะออทิสติกโดยประยุกต์การวิเคราะห์ภาพวาดด้วยการเรียนรู้เชิงลึก

## Classification of Children with Autism using Deep Learning Image Analysis

สุดารัตน์ ภูทอง และชัยพร เขมะภาคะพันธ์\*

*Sudarat Phuthong and Chaiyaporn Khemapatpapan\**

สาขาวิศวกรรมคอมพิวเตอร์ วิทยาลัยวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยธุรกิจบัณฑิตย์

*Computer Engineering Program, College of Engineering and Technology, Dhurakij Pundit University*

Received: June 24, 2025; Revised: July 1, 2025; Accepted: August 5, 2025; Published: December 27, 2025

**ABSTRACT** – Currently, the diagnosis of autism in children still relies on behavioral observation and psychological tests, which may have limitations in terms of accuracy and speed. This research therefore applies machine learning techniques, especially convolutional neural networks (CNN) with the ResNet50 model, to analyze and classify drawings of children with and without autism. This helps to quickly screen for autism and reduce the impact of personal perspectives. This study will divide the samples into age groups of 5–8 and 9–12 years old, and the results were evaluated with Accuracy, Recall, Specificity, F1-Score, and Confusion Matrix. The experimental results showed that the model could classify drawings accurately, with an Accuracy of 81.9% and 89.5%, and an F1-Score of 0.83 and 0.91 for the 5–8 and 9–12 age groups, respectively. After using Data Augmentation, the accuracy increased to 87.7% and 91.1%, with an F1-Score of 0.89 and 0.93. However, the research still has limitations in terms of the size and variety of data, which should be expanded in the future to increase the accuracy of the model.

**KEY WORDS** -- Deep Learning, Convolutional Neural Networks, Autism, Drawing Analysis, Machine Learning, ResNet50

บทคัดย่อ -- ปัจจุบันการวินิจฉัยภาวะออทิสติกในเด็กยังอาศัยการสังเกตพฤติกรรมและแบบทดสอบทางจิตวิทยา ซึ่งอาจมีข้อจำกัดด้านความแม่นยำและความรวดเร็ว งานวิจัยนี้จึงประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง โดยเฉพาะโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ด้วยโมเดล ResNet50 เพื่อวิเคราะห์และจำแนกภาพวาดของเด็กที่มีและไม่มีภาวะออทิสติก ช่วยคัดกรองภาวะออทิสติกเบื้องต้นได้อย่างรวดเร็ว ลดผลกระทบที่เกิดจากมุมมองส่วนบุคคล การศึกษานี้จะแบ่งกลุ่มตัวอย่างตามช่วงอายุ 5–8 ปี และ 9–12 ปี และประเมินผลด้วยค่า Accuracy, Recall, Specificity, F1-Score และ Confusion Matrix ผลการทดลองพบว่าโมเดลสามารถจำแนกภาพวาดได้อย่างแม่นยำ โดย Accuracy อยู่ที่ 81.9% และ 89.5% และ F1-Score เท่ากับ 0.83 และ 0.91 สำหรับกลุ่มอายุ 5–8 ปี และ 9–12 ปี ตามลำดับ หลังจากใช้ Data Augmentation ความแม่นยำเพิ่มขึ้นเป็น 87.7% และ 91.1% พร้อมค่า F1-Score ที่เพิ่มเป็น 0.89 และ 0.93 อย่างไรก็ตาม งานวิจัยยังมีข้อจำกัดด้านขนาดและความหลากหลายของข้อมูล ซึ่งควรขยายในอนาคตเพื่อเพิ่มความแม่นยำของโมเดล

คำสำคัญ -- การเรียนรู้เชิงลึก, โครงข่ายประสาทเทียมแบบสังวัตนาการ, ออทิสติก, การวิเคราะห์ภาพวาด, เทคนิคการเรียนรู้ของเครื่อง, โครงข่ายเรสเน็ต 50

## 1. บทนำ

ในการวินิจฉัยภาวะออทิสติกในเด็กนั้นปกติแล้วจะต้องดำเนินการโดยแพทย์ผู้เชี่ยวชาญเฉพาะทาง ซึ่งจะทำการตรวจประเมินรวมทั้งการประเมินผ่านชุดทดสอบต่างๆ ทำให้พ่อแม่หรือผู้ปกครองกังวลว่าบุตรหลานของตนมีแนวโน้มเป็นออทิสติกค่อนข้างช้า ดังนั้นการวิจัยนี้จึงมุ่งเน้นการพัฒนาวิธีการในการวินิจฉัยและประเมินพฤติกรรมของเด็กที่มีภาวะออทิสติกโดยใช้การวิเคราะห์ภาพวาด ร่วมกับเทคโนโลยีการเรียนรู้เชิงลึก (Deep Learning) เพื่อเป็นแนวทางในการสร้างเครื่องมือเพื่อวินิจฉัยได้อย่างง่ายต่อไป ปกติแล้วภาพวาดของเด็กสามารถถูกใช้เป็นเครื่องมือช่วยให้แพทย์ผู้เชี่ยวชาญใช้ประเมินพฤติกรรมและพัฒนาการของเด็กได้อยู่แล้ว รวมทั้งยังสามารถช่วยลดข้อผิดพลาดที่อาจเกิดขึ้นจากการประเมินด้วยแบบทดสอบที่เน้นการอ่าน ส่งผลให้การประเมินเป็นระบบและแม่นยำมากขึ้น นอกจากนี้ยังมีความสำคัญในการพัฒนามาตรฐานการวินิจฉัยและการดูแลเด็กที่มีภาวะออทิสติกอย่างมีประสิทธิภาพมากยิ่งขึ้น

### 1.1 วัตถุประสงค์ของการวิจัย

เพื่อประยุกต์การวิเคราะห์ภาพวาดด้วยเทคนิค Convolutional Neural Networks (CNN) เพื่อประเมินภาวะออทิสติกของเด็กที่มีภาวะออทิสติก

### 1.2 ขอบเขตการวิจัย

- 1.2.1 เด็กที่มีกลุ่มอายุ: 5–8 ปี และ 9–12 ปี ทั้งที่มีและไม่มีภาวะออทิสติกซึ่งได้รับการยืนยันแล้วจากแพทย์
- 1.2.2 หัวข้อภาพวาด: แมวน้ำ, ปลาฉลาม, เต่าทะเล และปลา
- 1.2.3 เทคนิคที่ใช้: ResNet50 และ Data Augmentation

### 1.3 ประโยชน์ที่คาดว่าจะได้รับ

- 1.3.1 ได้แนวทางการวินิจฉัยภาวะออทิสติกแบบรวดเร็ว
- 1.3.2 ได้กระบวนการวินิจฉัยภาวะออทิสติกด้วยการวิเคราะห์ภาพวาด

### 1.4 จริยธรรมการใช้ข้อมูลภาพวาดของเด็ก

งานวิจัยนี้ไม่มีการจัดเก็บข้อมูลส่วนบุคคลของเด็กในทุกระดับขั้นตอนของการวิจัย ข้อมูลที่นำมาใช้ในการศึกษามีเพียงภาพวาดของเด็ก ระยะเวลาที่ไว้วาด อายุ และสถานะทางออทิสติกของเด็กที่วาดภาพนั้นๆ อย่างไรก็ตามข้อมูลทั้งหมด

ได้รับการดูแลรักษาความลับตามแนวทางของจริยธรรมการวิจัยในมนุษย์

## 2. แนวคิด

### 2.1 แนวคิด

งานวิจัยนี้มุ่งใช้การเรียนรู้ของเครื่อง (Machine Learning) หรือ ML โดยเฉพาะอย่างยิ่งการเรียนรู้เชิงลึก (Deep Learning) หรือ DL เพื่อวิเคราะห์ภาพวาดของเด็กที่มีภาวะออทิสติก หรือ Autism spectrum disorder (ASD) โดยอาศัยความแตกต่างเฉพาะตัวในลักษณะภาพวาดที่สะท้อนพฤติกรรมและความคิดของเด็กกลุ่ม การนำเทคนิค Deep Learning เช่น CNN มาช่วยจำแนกลักษณะภาพวาดจึงช่วยเพิ่มความแม่นยำในการตรวจจับ ASD ซึ่งอาจเป็นเครื่องมือเสริมที่มีประโยชน์ทั้งในการวินิจฉัยและพัฒนาการสอนที่เหมาะสม เพื่อส่งเสริมการศึกษาและดูแลเด็กที่มีภาวะออทิสติกอย่างมีประสิทธิภาพมากขึ้น

### 2.2 ทฤษฎีและหลักการที่เกี่ยวข้อง

#### 2.2.1 ภาวะออทิสติก (Autism Spectrum Disorder)

ภาวะออทิสติกเป็นความผิดปกติทางพัฒนาการที่ส่งผลกระทบต่อสื่อสาร การเข้าสังคม และพฤติกรรมซ้ำซาก โดยมีสาเหตุจากทั้งพันธุกรรม เช่น ความผิดปกติของยีน และสิ่งแวดล้อม เช่น สารเคมีหรือภาวะแทรกซ้อนขณะตั้งครรภ์ เด็กออทิสติกเป็นต้น ทำให้เด็กที่มีภาวะออทิสติกมักมีปัญหาด้านการควบคุมอารมณ์ การเข้าสังคม และแสดงพฤติกรรมซ้ำๆ ทั้งนี้ภาวะออทิสติกแบ่งออกได้หลายประเภท เช่น Autistic Disorder, Asperger Syndrome และ Rett Syndrome อีกทั้งยังมีการจำแนกเป็นออทิสติกแท้ซึ่งเกิดจากสมองและพันธุกรรม และออทิสติกเทียมที่เกิดจากปัจจัยภายนอกและสภาพแวดล้อมที่เด็กเติบโตซึ่งอาจรักษาให้ดีขึ้นได้ [1]

#### 2.2.2 ออทิสติกและการวาดภาพ

ภาวะออทิสติกจะส่งผลกระทบต่อสื่อสารและพฤติกรรมของเด็ก ทั้งนี้โดยปกติเด็กมักชอบที่จะวาดหรือระบายสีภาพอยู่แล้ว อย่างไรก็ตามเด็กที่มีภาวะออทิสติกมักวาดภาพที่มีการสื่อสารที่ไม่สามารถควบคุมอารมณ์และการใช้ความคิดที่แตกต่างชัดเจนกว่าเด็กที่ไม่มีภาวะออทิสติก โดยภาพจะมีลักษณะเฉพาะ เช่น เส้นและรูปร่างแข็งทื่อหรือซ้ำซาก ลายเส้นและสีไม่เป็นรูปแบบ การใช้สีผิดธรรมชาติ และการจัดวางองค์ประกอบภาพที่ไม่ปกติ [2]

### 2.2.3 การเรียนรู้เชิงลึก

การเรียนรู้ของเครื่องหรือ ML นั้นสามารถนำไปประยุกต์ใช้งานได้มากมาย [3] ซึ่งทำงานโดยอาศัยโครงข่ายประสาทเทียม (Neural Networks) อย่างไรก็ตามยังต้องมีกระบวนการเตรียมข้อมูลนำเข้าหรือการสร้างคุณลักษณะการเรียนรู้ เช่น feature engineering เป็นต้น [4] ดังนั้นเทคนิคการเรียนรู้เชิงลึก DL เช่น CNN เป็นต้น จึงถูกพัฒนาขึ้นโดยสามารถเรียนรู้จากข้อมูลขนาดใหญ่ และมีโครงสร้างเป็นโครงข่ายประสาทเทียมจำนวนหลายๆ ชั้น เหมาะกับการนำไปใช้วิเคราะห์ข้อมูลที่มีมิติเดียวทั้งหลาย เช่น ภาพ หรือเสียง เป็นต้น เนื่องจากสามารถกลั่นลักษณะเด่นของภาพ เช่น ขอบ รูปทรง รูปแบบ และพื้นผิว เป็นต้น โดยลดขั้นตอนการเตรียมข้อมูลนำเข้า โดยในงานวิจัยนี้ได้เลือกใช้ ResNet-50 ซึ่งเป็นโมเดล CNN ที่มีจำนวนชั้นลึกถึง 50 ชั้นและใช้เทคนิค Residual Learning เพื่อหลีกเลี่ยงปัญหา Vanishing Gradient ช่วยให้การฝึกโมเดลแม่นยำยิ่งขึ้น รวมทั้งใช้วิธี Transfer Learning จากโมเดลที่ฝึกด้วย ImageNet เพื่อปรับให้เหมาะสมกับข้อมูลภาพวาดของเด็ก นอกจากนี้ยังมีการใช้ Data Augmentation เพื่อเพิ่มความหลากหลายของข้อมูลภาพวาด ด้วยการปรับหมุน ขยาย กลับด้าน หรือปรับสีของภาพ ซึ่งช่วยลด Overfitting และเพิ่มประสิทธิภาพของโมเดลในการเรียนรู้จากข้อมูลที่มีจำนวนจำกัด

### 2.2.4 ทฤษฎีเกี่ยวกับการวิเคราะห์ภาพวาดทางจิตวิทยา

การวาดภาพสามารถสะท้อนความคิดและอารมณ์ของเด็กได้ โดยเฉพาะในเด็กที่มีภาวะออทิสติกซึ่งมักแสดงลักษณะการวาดที่แตกต่างจากเด็กทั่วไป โดย Luquet [5] กล่าวถึงพัฒนาการของการวาดภาพเป็นลำดับขั้น และ แบบทดสอบวาดภาพ ที่ใช้ประเมินพัฒนาการทางสติปัญญา ซึ่งเด็กที่มีภาวะออทิสติกอาจแสดงลักษณะผิดปกติ เช่น ภาพไม่สมบูรณ์หรือขาดองค์ประกอบ ดังนั้นการนำภาพวาดมาวิเคราะห์เชิงจิตวิทยา จึงมีศักยภาพและเป็นเครื่องมือที่สำคัญของแพทย์ในการช่วยวินิจฉัยภาวะออทิสติกได้อย่างแม่นยำยิ่งขึ้น

## 2.3 งานวิจัยที่เกี่ยวข้อง

Ms. B. Kamala และคณะ [6] ศึกษาโมเดลของการเรียนรู้ของเครื่องเพื่อคัดกรองผู้ป่วยที่เป็น ASD โดยเปรียบเทียบหลายอัลกอริทึม พบว่า CNN และ Random Forest มีประสิทธิภาพดีที่สุด อย่างไรก็ตามงานวิจัยนี้ได้ใช้แบบสอบถาม AQ-10 เป็น

เครื่องมือหลัก ซึ่งได้ผลสรุปว่า การเรียนรู้ของเครื่องสามารถใช้ช่วยให้วินิจฉัย ASD ได้เร็วและแม่นยำขึ้น

Jingsheng Deng และคณะ [7] ใช้ Ensemble 3D-CNN วิเคราะห์ภาพสแกนสมอง fMRI (Functional Magnetic Resonance Imaging) เพื่อวินิจฉัย ASD จากฐานข้อมูล ABIDE I ซึ่งผลการศึกษพบว่ามีความแม่นยำ 74.53% โดยได้แนะนำให้ใช้เทคนิค Transfer Learning มาพัฒนาวิจัยต่อไปในอนาคต

Md. Fazle Rabbi และคณะ [8] ใช้ CNN วิเคราะห์ภาพใบหน้าเด็กจากแพลตฟอร์ม Kaggle เพื่อคัดกรอง ASD ตั้งแต่ระยะแรก ได้ความแม่นยำสูงสุด 92.31% เหนือกว่าโมเดลอื่น แสดงให้เห็นว่า CNN สามารถใช้เป็นเครื่องมือคัดกรอง ASD ระยะแรกได้ อย่างไรก็ตามงานวิจัยนี้สัมพันธ์ต่อการละเมิดความเป็นส่วนตัวส่วนตัวของเจ้าของข้อมูลอย่างชัดเจน

R. Patankar และคณะ [9] พัฒนา AntiScan ด้วย Neural Networks เพื่อคัดกรองภาวะ ASD ของเด็กในประเทศอินเดีย โดยใช้ข้อมูลพฤติกรรม สังคม และพันธุกรรมหรือ DNA ให้ความแม่นยำสูงสุด 89.7% ช่วยลดภาวะแพทย์และเพิ่มโอกาสดูแลผู้ป่วย ASD

V. Kavitha และ R. Siva [10] พัฒนาโมเดล PSO-CNN เพื่อจำแนก ASD ใน 4 ช่วงวัย โดยใช้ชุดข้อมูล UCI มาทำการวิเคราะห์ ซึ่งผลลัพธ์ที่ได้ชี้ว่า PSO-CNN ช่วยเลือกคุณลักษณะที่เหมาะสม ลด Overfitting และเพิ่มความแม่นยำของโมเดล CNN

Jungpil Shin และคณะ [11] ใช้ ML วิเคราะห์ลายมือเด็กออทิสติก เพื่อวินิจฉัย ADHD พบว่าวิธีการ Random Forest ได้ความแม่นยำสูงสุด 93.10% โดยมีข้อจำกัดคือกลุ่มตัวอย่างน้อยและเสนอแนะให้ใช้ Deep Learning ในอนาคต

Maedeh Mosharraf และ Faezeh Banabazi [12] ใช้ ML วิเคราะห์ภาพวาดเด็กอายุ 7-9 ปี เพื่อทำนายบุคลิกภาพ พบว่า Random Forest มีความแม่นยำดีที่สุด 64% โดยมีข้อจำกัดคือมีจำนวนตัวอย่างน้อยและแนะนำให้เพิ่มขนาดข้อมูลและใช้ Deep Learning

Aura-Loredana Popescu และ Nirvana Popescu [13] พัฒนาแอปพลิเคชัน PandaSays ร่วมกับการใช้ MobileNet เพื่อวิเคราะห์อารมณ์ของเด็กที่มีภาวะออทิสติกและกำลังภาพวาดเพื่อเข้าใจอารมณ์ของเด็กที่ทดสอบ โดยใช้ Data Augmentation และทดสอบร่วมกับหุ่นยนต์เพื่อส่งเสริมพฤติกรรมทางบวก ผลการทดสอบได้ความแม่นยำ 84.58%

Amna Hendr, Umar Ozgunalp และ Meryem Erbilek Kaya [14] ใช้โมเดล CNN ร่วมกับ Transfer Learning วิเคราะห์ลายมือเด็ก ASD และเด็กปกติ พบว่าโมเดลปรับแต่ง GoogleNet ให้ความแม่นยำสูงสุด 90.48% โดยมีความจำเพาะ 100% แสดงศักยภาพในการใช้วินิจฉัย ASD จากลายมือ

## 2.4 การประยุกต์ใช้ Machine Learning วิเคราะห์ภาพ

Machine Learning ได้รับการพิสูจน์แล้วว่ามีประสิทธิภาพสามารถใช้วิเคราะห์และจำแนกภาพในหลากหลายมิติ เช่น ด้านการแพทย์ การศึกษา และการประมวลผลภาพทั่วไป เป็นต้น โดย CNN มีความสามารถในการเรียนรู้คุณลักษณะจากภาพโดยไม่ต้องพึ่งพาการออกแบบฟีเจอร์ล่วงหน้า จึงมีความเหมาะสมอย่างยิ่งต่อการวิเคราะห์ภาพของเด็กที่มีภาวะออทิสติก ซึ่งมักมีลักษณะซับซ้อนและแตกต่างกันไปตามพฤติกรรมและพัฒนาการ ทั้งนี้สามารถนำผลการวิเคราะห์ไปใช้ประกอบการประเมินพฤติกรรมของเด็กได้อย่างมีประสิทธิภาพและแม่นยำ

โครงข่าย CNN ได้รับการออกแบบมาโดยเฉพาะสำหรับการประมวลผลข้อมูลภาพ โดยประกอบด้วยชั้นสำคัญต่าง ๆ ได้แก่

1. Convolutional Layer สำหรับการสกัดฟีเจอร์จากภาพ
2. Activation Function (เช่น ReLU) สำหรับเพิ่มความไม่เชิงเส้นให้กับโมเดล
3. Pooling Layer สำหรับลดขนาดของข้อมูลเชิงพื้นที่
4. Fully Connected Layer และ Output Layer สำหรับการจัดประเภทภาพ

ในการศึกษาวิจัยนี้ ได้นำโมเดล ResNet-50 ซึ่งเป็นโครงข่ายแบบลึก (deep network) ที่มีการออกแบบให้มี Residual Blocks มาใช้งาน โดย Residual Blocks มีบทบาทสำคัญในการลดปัญหา Gradient Vanishing และ Overfitting โดยเฉพาะเมื่อมีข้อมูลฝึกจำนวนจำกัด ทั้งนี้ได้ประยุกต์ใช้เทคนิค Transfer Learning โดยการโหลดน้ำหนักจากโมเดลที่ผ่านการฝึกบนชุดข้อมูล ImageNet ซึ่งเป็นชุดข้อมูลภาพขนาดใหญ่ แล้วนำมาปรับแต่ง (fine-tuning) ให้เหมาะสมกับลักษณะเฉพาะของข้อมูลภาพของเด็กที่มีภาวะออทิสติกและเด็กทั่วไป ซึ่งช่วยให้โมเดลสามารถดึงคุณลักษณะที่สำคัญจากภาพได้อย่างมีประสิทธิภาพและเพิ่มความแม่นยำในการจำแนกประเภทภาพ

## 3. ระเบียบวิธีวิจัย

### 3.1 แนวทางการวิจัย

การวิจัยนี้ประยุกต์ใช้วิธีการ Machine Learning (ML) ในการวิเคราะห์และจำแนกภาพวาดของเด็กที่มีภาวะออทิสติกและเด็กทั่วไป โดยเลือกใช้โมเดล CNN เนื่องจากมีประสิทธิภาพสูงในการวิเคราะห์ข้อมูลภาพ และสามารถเรียนรู้คุณลักษณะเฉพาะที่ซับซ้อนได้อย่างลึกซึ้ง การดำเนินการวิจัยประกอบด้วยขั้นตอนสำคัญ ได้แก่ การเก็บรวบรวมข้อมูล การเตรียมข้อมูล การวิเคราะห์และประมวลผลภาพ การฝึกอบรมโมเดล และการประเมินผลการจำแนกภาพด้วยโมเดล

### 3.2 ประชากรและกลุ่มตัวอย่าง

ประชากรที่ใช้ในการวิจัยประกอบด้วยเด็กอายุระหว่าง 5–12 ปี ซึ่งจำแนกออกเป็น 2 กลุ่มหลัก ได้แก่

3.2.1 กลุ่มเด็กที่ได้รับการวินิจฉัยว่ามีภาวะออทิสติกจำนวน 50 คน โดยแบ่งเป็น

- กลุ่มอายุ 5–8 ปี จำนวน 16 คน

- กลุ่มอายุ 9–12 ปี จำนวน 34 คน

3.2.2 กลุ่มเด็กทั่วไปที่ไม่มีภาวะออทิสติกจำนวน 55 คน โดยแบ่งเป็น

- กลุ่มอายุ 5–8 ปี จำนวน 13 คน

- กลุ่มอายุ 9–12 ปี จำนวน 42 คน

ทั้งนี้กลุ่มตัวอย่างมาจาก โรงเรียนและศูนย์พัฒนาเด็กพิเศษในเขตพื้นที่วิจัย โดยใช้เกณฑ์การคัดเลือกที่ได้รับการยืนยันจากแพทย์ผู้เชี่ยวชาญด้านพัฒนาการเด็ก เพื่อให้ได้กลุ่มตัวอย่างที่มีความถูกต้องและน่าเชื่อถือสำหรับการวิเคราะห์เชิงโมเดล

### 3.3 เครื่องมือที่ใช้ในการวิจัย

เครื่องมือหลักในการรวบรวมและวิเคราะห์ข้อมูล ดังนี้

3.3.1 แบบฟอร์มเก็บข้อมูลภาพวาด ใช้สำหรับให้เด็กวาดรูป บันทึกข้อมูลภาวะออทิสติกและอายุของผู้เข้าร่วมการวิจัย รวมถึงการจัดเก็บและระบุรายละเอียดของภาพวาดแต่ละภาพอย่างเป็นระบบ

3.3.2 การเตรียมข้อมูลภาพก่อนนำเข้าสู่กระบวนการฝึกโมเดล โดยมีการปรับขนาดภาพให้สอดคล้องกับข้อกำหนดของโมเดล การทำ Normalization เพื่อปรับค่าพิกเซลให้อยู่ในช่วงที่เหมาะสม รวมทั้งใช้เทคนิค Data Augmentation เพื่อเพิ่มความหลากหลายของข้อมูล เช่น การหมุนภาพ การกลับ

ด้าน และการปรับแต่ง เพื่อช่วยลด Overfitting และเพิ่มประสิทธิภาพของโมเดล

3.3.3 โมเดล CNN ในการวิจัยนี้เลือกใช้ ResNet-50 ซึ่งเป็นโมเดลแบบ Deep Neural Network ที่ผ่านการฝึกบนชุดข้อมูล ImageNet และใช้วิธี Transfer Learning โดยใช้เป็นตัวดึงคุณลักษณะ (Feature Extractor) มีการเพิ่มชั้น GlobalAverage Pooling2D Dense และ Dropout เพื่อปรับปรุงประสิทธิภาพในการจำแนกภาพ พัฒนาโดยภาษา Python พร้อมไลบรารี TensorFlow และ Keras

### 3.4 การเก็บรวบรวมข้อมูล

ภาพวาดจากเด็กที่มีภาวะออทิสติกและเด็กปกติ มีรวมทั้งหมด 420 ภาพ โดยได้รับความยินยอมจากผู้ปกครองและหน่วยงานที่เกี่ยวข้องอย่างถูกต้อง ข้อมูลทั้งหมดถูกเก็บรักษาเป็นความลับเพื่อรักษาสิทธิส่วนบุคคลของผู้เข้าร่วม กิจกรรมวาดภาพจัดขึ้นในห้องเรียนภายใต้การควบคุมของคุณครู ซึ่งดูแลให้บรรยากาศผ่อนคลายและเป็นมิตร เด็กแต่ละคนได้รับอุปกรณ์เหมือนกัน ประกอบด้วย

3.4.1 กระดาษวาดภาพขนาด A4 2 แผ่น โดยกำหนดให้ช่องสำหรับวาดภาพขนาด 6.45 x 7.14 CM จำนวน 4 ช่อง และมีตัวอย่างภาพ แมวน้ำ, ปลาฉลาม, เต่าทะเล และปลา ในกระดาษ

3.4.2 ดินสอสี 2B

3.4.3 ชุดสีไม้ 24 สี

3.4.4 ยางลบ

คำชี้แจงที่เด็กได้รับคือ ให้วาดภาพตามแบบตัวอย่างลงในช่องสี่เหลี่ยมที่กำหนดไว้ ทั้งนี้เด็กแต่ละคนมีเวลา 3 ชั่วโมง ในการวาดทั้งหมด 4 ภาพ โดยสามารถสอบถามคุณครูได้ในกรณีที่มีปัญหาเกี่ยวกับอุปกรณ์หรือการใช้งาน

ภาพวาดทั้งหมดจะถูกสแกนเป็นไฟล์ดิจิทัล เพื่อนำเข้าสู่กระบวนการวิเคราะห์ด้วยระบบคอมพิวเตอร์ต่อไป

### 3.5 การเตรียมข้อมูล

3.5.1 Data Augmentation ถูกนำมาใช้เพื่อเพิ่มชุดข้อมูลภาพสำหรับการฝึกและทดสอบ โดยใช้เทคนิค ดังนี้

- การหมุนภาพ (Rotation)

ทำการหมุนภาพต้นฉบับไปทางซ้ายหรือขวาในมุมต่าง ๆ ได้แก่ หมุนซ้าย 45 องศา, หมุนซ้าย 90 องศา, หมุนขวา 45 องศา และหมุนขวา 90 องศา เพื่อให้โมเดลสามารถเรียนรู้ภาพในมุมมองที่หลากหลาย

- การพลิกภาพ (Flip/Mirroring)

พลิกภาพในแนวนอนและแนวตั้ง 180 องศาในแต่ละแนว เพื่อเพิ่มความหลากหลายของทิศทางของวัตถุในภาพ

- การครอบภาพ (Cropping)

ตัดส่วนของภาพบางส่วนออก ที่ไม่ใช่องค์ประกอบหลักของภาพ เพื่อให้โมเดลสามารถเรียนรู้จากภาพที่มีขนาดหรือบริบทที่แตกต่างกัน

เทคนิคเหล่านี้ช่วยเพิ่มความหลากหลายของชุดข้อมูลโดยไม่ต้องจัดเก็บข้อมูลเพิ่มเติม และยังคงผลดีต่อการเรียนรู้ของโมเดลในสภาพแวดล้อมจริงที่มีความหลากหลายของข้อมูลภาพ

3.5.2 การแบ่งชุดข้อมูลและเทคนิคการตรวจสอบโมเดล

จะใช้ ImageDataGenerator จาก TensorFlow แบ่งข้อมูลออกเป็น 2 ชุด โดยกำหนดพารามิเตอร์ validation\_split เท่ากับ 0.4 เพื่อแยกข้อมูลออกเป็น:

- ชุดข้อมูลสำหรับฝึกโมเดล (Training set) 60 %

- ชุดข้อมูลสำหรับตรวจสอบโมเดล (Validation set) 40 %

ภายหลังการแบ่งชุดข้อมูลเบื้องต้น จะใช้เทคนิค K-Fold Cross-Validation จำนวน 5-Fold เพื่อสร้างชุดข้อมูลย่อยในกระบวนการฝึกและประเมินโมเดล เพื่อให้การประเมินผลมีความครอบคลุมและเชื่อถือได้มากยิ่งขึ้น โดยในแต่ละรอบของการ Cross-Validation จะมีการสลับชุดข้อมูลสำหรับฝึกและตรวจสอบใหม่ ช่วยลดอคติ (bias) ที่อาจเกิดจากการแบ่งข้อมูลเพียงครั้งเดียว และเพิ่มความมั่นใจในประสิทธิภาพและความเสถียรของโมเดลที่พัฒนา

### 3.6 การวิเคราะห์ข้อมูล

การปรับแต่งพารามิเตอร์ (Parameter Tuning) ของโมเดล CNN ที่ใช้ในการวิจัยถือเป็นขั้นตอนที่มีความสำคัญอย่างยิ่ง เนื่องจากส่งผลโดยตรงต่อประสิทธิภาพของโมเดล ทั้งในด้านความแม่นยำ ความสามารถในการเรียนรู้ของโมเดล และการลดความเสี่ยงของปัญหา Overfitting ที่อาจเกิดขึ้น

การทดสอบเพื่อหาค่าพารามิเตอร์ที่เหมาะสมที่สุด จะสามารถให้ผลลัพธ์ที่ดีที่สุดในการจำแนกภาพ โดยมีข้อกำหนดของพารามิเตอร์ที่ใช้ ดังนี้:

3.6.1 Learning Rate : ทดสอบค่าที่ 0.01, 0.001 และ 0.0001 เพื่อหาค่าที่ให้ความแม่นยำสูงสุด

3.6.2 Batch Size : ทดลองใช้ขนาด 16, 32 และ 64 เพื่อประเมินผลต่อความเร็วและประสิทธิภาพ

3.6.3 Number of Epochs : กำหนดไว้ที่ 20 รอบการฝึก

3.6.4 Optimizer : ใช้อัลกอริทึม Adam เนื่องจากมีความเสถียรและประสิทธิภาพในการเรียนรู้สูง

### 3.7 การประเมินผล

โดยปกติการเรียนรู้ของเครื่องจะถูกประเมินด้วยตัวชี้วัดที่สำคัญ ดังนี้

#### 3.7.1 ค่าความถูกต้อง (Accuracy)

คืออัตราส่วนของจำนวนการจำแนกที่ถูกต้องทั้งหมด ทั้งกรณีเด็กที่มีภาวะออทิสติกและเด็กปกติต่อจำนวนตัวอย่างทั้งหมด ซึ่งสามารถคำนวณได้จากสมการ (1) ดังนี้

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

โดยที่ TP (True Positive) คือจำนวนตัวอย่างที่จำแนกว่าเป็นออทิสติก และเป็นออทิสติกจริง

TN (True Negative) คือจำนวนตัวอย่างที่จำแนกว่าไม่เป็นออทิสติก และไม่เป็นออทิสติกจริง

FP (False Positive) คือจำนวนตัวอย่างที่จำแนกว่าเป็นออทิสติก แต่จริง ๆ ไม่เป็น

FN (False Negative) คือจำนวนตัวอย่างที่จำแนกว่าไม่เป็นออทิสติก แต่จริง ๆ เป็น

#### 3.7.2 ความไว (Sensitivity หรือ Recall)

คือความสามารถของโมเดลในการตรวจจับเด็กออทิสติกได้ดีหรือไม่ โดยมีข้อกำหนด ดังนี้

$$Sensitivity = \frac{TP}{TP+FN} \quad (2)$$

#### 3.7.3 ความจำเพาะ (Specificity)

คือความเชื่อมั่นของโมเดลที่จะไม่ระบุเด็กปกติผิดเป็นเด็กที่มีภาวะออทิสติก โดยมีข้อกำหนดดังสมการที่ (3) ดังนี้

$$Specificity = \frac{TN}{TN+FP} \quad (3)$$

#### 3.7.3 ความแม่นยำ (Precision)

คือความเชื่อมั่นในการจำแนกเด็กที่มีภาวะออทิสติกว่าเป็นออทิสติกจริงได้อย่างถูกต้อง โดยคำนวณจากอัตราส่วนของจำนวนเด็กที่มีภาวะออทิสติกและโมเดลทำนายว่าเป็นออทิสติกจริง จากจำนวนที่โมเดลทำนายว่าเป็นออทิสติกทั้งหมด ดังนี้

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

#### 3.7.5 F1-Score

เป็นค่าเฉลี่ยแบบฮาร์มอนิก (Harmonic Mean) ระหว่าง Precision และ Recall เพื่อวัดประสิทธิภาพของโมเดลในกรณีที่มีความไม่สมดุลของข้อมูล มีข้อกำหนดดังสมการที่ (5) ดังนี้

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

#### 3.7.6 Confusion Matrix

Confusion Matrix เป็นเครื่องมือสำคัญที่ใช้วิเคราะห์ประสิทธิภาพโดยรวมและข้อผิดพลาดในการทำนายของโมเดล

## 4. ผลการวิจัย

### 4.1 ผลการทดลอง

4.1.1 ผลการทดลอง กลุ่มอายุ 5–8 ปี (ก่อนทำ Data Augmentation)

ผลการฝึกและประเมินโมเดล ResNet50 ด้วย 5-Fold Cross Validation ในกลุ่มนี้มีรายละเอียดดังนี้

- ค่า Accuracy เฉลี่ยอยู่ที่ 81.9%
- โมเดลสามารถจำแนกภาพ ASD และ Non-ASD ได้ดี
- โมเดลมีการทำนายผิดในกลุ่ม ASD และ Non-ASD

เนื่องจากภาพข้อมูลในกลุ่มนี้มีความคลุมเครือพอสมควร

4.1.2 ผลการทดลอง กลุ่มอายุ 9–12 ปี (ก่อนทำ Data Augmentation)

ผลการทดลองในกลุ่มนี้มีความแตกต่างจากกลุ่มแรกเล็กน้อย โดยความถูกต้องเฉลี่ยจะสูงกว่ากลุ่มอายุ 5–8 ปี ดังนี้

- ค่า Accuracy เฉลี่ยอยู่ที่ 89.5%
- ประสิทธิภาพสูงขึ้น เนื่องจากข้อมูลในกลุ่มนี้มีความชัดเจนหรือมีความแตกต่างของภาพระหว่าง 2 กลุ่มชัดเจนขึ้น
- โมเดลมีอัตราการทำนายผิดในกลุ่ม ASD และ Non-ASD เล็กน้อย

#### 4.1.3 ผลการทดลอง กลุ่มอายุ 5–8 ปี (หลังทำ Data Augmentation)

หลังจากเพิ่มชุดข้อมูลด้วยเทคนิค Data Augmentation เพื่อเพิ่มความหลากหลายของชุดข้อมูลในกลุ่ม 5–8 ปี พบว่าประสิทธิภาพโมเดลดีขึ้น ดังนี้

- ค่า Accuracy เฉลี่ยหลัง Augmentation เพิ่มขึ้นเป็นประมาณ 87.7%

- โมเดลมีความสามารถ generalize ดีขึ้น เนื่องจากมีชุดข้อมูลที่หลากหลายมากขึ้น

- ค่าการจำแนกผิดในชุด validation ลดลงอย่างชัดเจน

#### 4.1.4 ผลการทดลอง กลุ่มอายุ 9–12 ปี (หลังทำ Data Augmentation)

หลังจากเพิ่มข้อมูลด้วยเทคนิค Data Augmentation เพื่อเพิ่มความหลากหลายของชุดข้อมูลในกลุ่มอายุ 9–12 ปี พบว่าโมเดลมีประสิทธิภาพเพิ่มขึ้นอย่างชัดเจน ดังนี้

- ค่า Accuracy เฉลี่ยหลัง Augmentation เพิ่มขึ้นเป็น 91.1% แสดงถึงความแม่นยำที่สูงในการจำแนกภาพวาดของเด็กออทิสติกและเด็กทั่วไป

- ค่า Precision และ Recall อยู่ที่ประมาณ 0.91–0.92 ซึ่งบ่งชี้ว่าโมเดลสามารถทำนายได้ทั้งแม่นยำและครอบคลุม

- ค่า F1-score อยู่ในระดับสูงทุก Fold โดยเฉพาะใน Fold ที่ 3 ซึ่งได้ค่าสูงสุดที่ 0.92

## 4.2 การประเมินผลโมเดล

ผลการประเมินโมเดล ResNet50 แสดงให้เห็นว่าการทำ Data Augmentation ช่วยเพิ่มประสิทธิภาพการจำแนกภาพวาดของเด็กในหลายด้าน โดย Accuracy สูงขึ้นทั้งในกลุ่มอายุ 5–8 ปี (จาก 81.9% เป็น 87.7%) และ 9–12 ปี (จาก 89.5% เป็น 91.1%) สะท้อนว่าโมเดลสามารถทำนายได้แม่นยำมากขึ้น โดยรวม F1-Score ซึ่งแสดงถึงสมดุลระหว่าง Precision และ Recall ก็เพิ่มขึ้นในกลุ่ม 5–8 ปี (จาก 79.2% เป็น 89.0%) และยังคงสูงในกลุ่ม 9–12 ปี แสดงว่าโมเดลสามารถจำแนกทั้งสองคลาสได้อย่างมีประสิทธิภาพแม้ในกรณีข้อมูลไม่สมดุล ในด้าน Sensitivity (Recall) ซึ่งวัดความสามารถในการตรวจจับเด็กที่มีภาวะออทิสติก พบว่าดีขึ้นอย่างชัดเจนในกลุ่ม 5–8 ปี (จาก 76.9% เป็น 90.4%) แสดงถึงการพัฒนาความแม่นยำของโมเดลในกลุ่มนี้ โดยเฉพาะสำหรับ Specificity ที่สะท้อนการ

จำแนกเด็กที่ไม่มีภาวะออทิสติก พบว่ากลุ่ม 9–12 ปีมีค่าพุ่งสูง (จาก 89.0% เป็น 95.0%) หลัง Augmentation แสดงว่าโมเดลแยกแยะเด็กที่ไม่มีภาวะออทิสติกได้แม่นยำมากขึ้น สุดท้าย Precision หรือความแม่นยำเชิงบวก ก็ดีขึ้นในทุกกลุ่ม โดยเฉพาะกลุ่ม 9–12 ปีที่มีค่าเพิ่มจาก 91.0% เป็น 93.4% แสดงถึงความมั่นใจของโมเดลในการทำนายเด็กออทิสติกได้อย่างถูกต้อง โดยสรุป การทำ Data Augmentation ส่งผลดีต่อทุกตัวชี้วัดหลัก ทำให้โมเดลมีความแม่นยำและเสถียรมากขึ้นเหมาะสำหรับการใช้งานในบริบทการวิเคราะห์ภาพวาดเพื่อคัดกรองเด็กที่มีภาวะออทิสติก

ในกรณีของการทำนายภาพวาดของเด็กที่มีภาวะออทิสติก และเด็กที่ไม่มีภาวะ ผลการทำนายของโมเดล ResNet50 จากการทำ Cross-Validation ทั้ง 5 Fold ถูกสรุปรวมออกมาในรูปแบบของ Overall Confusion Matrix ดังแสดงในตารางด้านล่าง

#### 4.2.1. ผลการจำแนกภาพวาด (ก่อนทำ Data Augmentation)

จากข้อมูลในตารางที่ 1 โมเดลสามารถจำแนกเด็กที่มีภาวะออทิสติกในกลุ่มอายุ 5–8 ปี ได้ถูกต้อง 40 ครั้ง (TP) และกลุ่ม 9–12 ปี ได้ 151 ครั้ง ขณะที่เกิดการทำนายผิดว่าเป็นเด็กทั่วไป (FN) จำนวน 12 และ 17 ครั้งตามลำดับ สำหรับการจำแนกเด็กทั่วไปได้ถูกต้อง (TN) พบ 55 และ 121 ครั้ง และการทำนายผิดว่าเป็นเด็กออทิสติก (FP) พบ 9 และ 15 ครั้ง ส่งผลให้โมเดลมี Accuracy เท่ากับ 81.9% ในกลุ่มอายุ 5–8 ปี และ 89.5% ในกลุ่มอายุ 9–12 ปี ปัจจัยที่อาจมีผลต่อความแม่นยำที่แตกต่างกันระหว่างกลุ่มอายุ อาจมาจากลักษณะเฉพาะของภาพวาดที่ชัดเจนและแตกต่างกันมากขึ้นตามพัฒนาการของเด็ก ทำให้โมเดลสามารถเรียนรู้รูปแบบของกลุ่มอายุที่มากกว่าได้ดีกว่า นอกจากนี้ ความหลากหลายและความซับซ้อนของลายเส้นในเด็กโตอาจส่งผลให้ข้อมูลมีความจำแนกได้มากขึ้น ส่งเสริมให้โมเดลมีประสิทธิภาพในการทำนายที่สูงขึ้นในกลุ่มอายุ 9–12 ปี

ตารางที่ 1. ผลการจำแนกภาพเด็กออทิสติกและไม่เป็นออทิสติกตามช่วงอายุ

กลุ่มอายุ	TP	FN	FP	TN	Accuracy
5–8 ปี	40	12	9	55	81.9%
9–12 ปี	151	17	15	121	89.5%

#### 4.2.2. ผลการจำแนกภาพวาด (หลังทำ Data Augmentation)

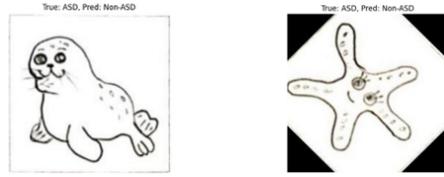
จากตารางที่ 2 พบว่าโมเดลสามารถจำแนกภาพของเด็กที่มีภาวะออทิสติกได้ดี อย่างไรก็ตามยังมีข้อผิดพลาดบางส่วนที่อาจเกิดจากความคล้ายคลึงกันของลักษณะภาพวาดระหว่างเด็กสองกลุ่ม จากข้อมูลในตาราง หลังการดำเนินการเพิ่มข้อมูล (Data Augmentation) พบว่าโมเดลสามารถจำแนกเด็กที่มีภาวะออทิสติกในกลุ่มอายุ 5-8 ปี ได้ถูกต้อง (TP) จำนวน 312 ครั้ง และในกลุ่มอายุ 9-12 ปี จำนวน 638 ครั้ง ขณะที่มีการทำนายผิดว่าเป็นเด็กทั่วไป (FN) จำนวน 33 และ 96 ครั้งตามลำดับ สำหรับการจำแนกเด็กทั่วไปได้ถูกต้อง (TN) อยู่ที่ 237 และ 862 ครั้ง และการทำนายผิดว่าเป็นเด็กออทิสติก (FP) อยู่ที่ 44 และ 45 ครั้ง ส่งผลให้ค่า Accuracy ในกลุ่มอายุ 5-8 ปี และ 9-12 ปี อยู่ที่ 87.7% และ 91.1% ตามลำดับ ผลลัพธ์ดังกล่าวสะท้อนว่าโมเดลสามารถรักษาประสิทธิภาพในการจำแนกได้ดีแม้หลังจากการเพิ่มข้อมูล โดยเฉพาะในกลุ่มอายุ 9-12 ปี ซึ่งมีแนวโน้มการทำนายที่แม่นยำกว่ากลุ่มอายุที่น้อยกว่าเล็กน้อย ปัจจัยที่อาจส่งผลให้โมเดลมีความสามารถในการจำแนกกลุ่มอายุ 9-12 ปี ได้ดีกว่า ได้แก่ ลักษณะเฉพาะของลายเส้นและรายละเอียดในภาพวาดของเด็กโตที่มีความซับซ้อนและชัดเจนมากขึ้น ส่งผลให้โมเดลสามารถเรียนรู้และแยกแยะรูปแบบได้อย่างมีประสิทธิภาพ อย่างไรก็ตาม ยังพบข้อผิดพลาดบางกรณีซึ่งอาจเกิดจากความคล้ายคลึงกันของลักษณะภาพวาดระหว่างเด็กที่มีภาวะออทิสติกและเด็กทั่วไป โดยเฉพาะในกลุ่มเด็กเล็กที่รูปแบบภาพวาดอาจยังไม่แสดงลักษณะเฉพาะที่ชัดเจนเพียงพอสำหรับการจำแนกของโมเดล

ตารางที่ 2. ผลการจำแนกภาพเด็กออทิสติกและไม่มีเป็นออทิสติกตามช่วงอายุ

กลุ่มอายุ	TP	FN	FP	TN	Accuracy
5-8 ปี	312	33	44	237	87.7%
9-12 ปี	638	96	45	862	91.1%

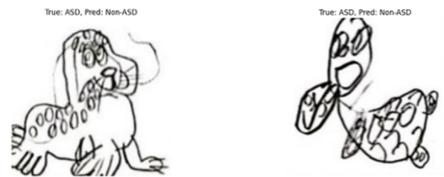
#### 4.2.3 ตัวอย่างภาพวาดในการจำแนกกลุ่มเด็กที่มีภาวะออทิสติกและไม่มีภาวะ

โดยในแต่ละภาพจะมีคำอธิบายว่า True: หมายถึงค่าความจริงจากข้อมูล (Label จริงว่าเป็น ASD) ส่วน Pred: หมายถึงค่าที่โมเดลทำนายออกมา



รูปที่ 1. ตัวอย่างรูปภาพที่เกิด False Negative ซึ่งวาดและระบายสีโดยเด็กที่มีภาวะออทิสติกช่วงอายุ 5-8 ปี

จากการวิเคราะห์การทำงานของโมเดลที่ผิดพลาดกรณี False Negative นั้นสามารถสังเกตได้จากรูปที่ 1 ซึ่งจะเห็นว่ารูปมีลักษณะของเมฆน้ำและปลาตัวชัดเจนมีองค์ประกอบครบถ้วน ส่งผลให้โมเดลจำแนกผิดว่าเป็นภาพของเด็กที่ไม่มีภาวะ (Non-ASD) ทั้งที่เป็นภาพจากเด็กออทิสติก แสดงถึงข้อจำกัดของโมเดลในการแยกแยะลักษณะเฉพาะบางอย่างในงานวาดของเด็กช่วงอายุ 5-8 ปี



รูปที่ 2. แสดงตัวอย่างรูปภาพที่เกิด False Negative ซึ่งวาดและระบายสีโดยเด็กที่มีภาวะออทิสติกช่วงอายุ 9-12 ปี

จากการวิเคราะห์การทำงานของโมเดลที่ผิดพลาดกรณี False Negative นั้นสามารถสังเกตได้จากรูปที่ 2 ซึ่งจะเห็นว่ารูปเมฆน้ำยังมีเค้าโครงลักษณะชัดเจนและมีองค์ประกอบครบถ้วน ส่งผลให้โมเดลจำแนกผิดว่าเป็นภาพของเด็กที่ไม่มีภาวะ (Non-ASD) ทั้งที่เป็นภาพจากเด็กออทิสติก แสดงถึงข้อจำกัดของโมเดลในการแยกแยะลักษณะเฉพาะบางอย่างในงานวาดของเด็กช่วงอายุ 9-12 ปี



รูปที่ 3. ตัวอย่างรูปภาพที่เกิด False Positive ซึ่งวาดและระบายสีโดยเด็กที่ไม่มีภาวะออทิสติกช่วงอายุ 5-8 ปี

จากการวิเคราะห์การทำงานของโมเดลที่ผิดพลาดกรณี False Positive นั้นสามารถสังเกตได้จากรูปที่ 3 จะเห็นว่ารูปแมวที่มีลักษณะการวาดที่ไม่เป็นระเบียบหรือมีรูปแบบเฉพาะ ทำให้โมเดลจำแนกผิดว่าเป็นภาพของเด็กที่มีภาวะออทิสติก (ASD) แสดงถึงข้อจำกัดข้อจำกัดของโมเดล ในการแยกแยะลักษณะเฉพาะบางอย่างในงานวาดของเด็กช่วงอายุ 5-8 ปี



รูปที่ 4. ตัวอย่างรูปภาพที่เกิด False Positive ซึ่งวาดและระบายสีโดยเด็กที่ไม่มีภาวะออทิสติกช่วงอายุ 9-12 ปี

จากการวิเคราะห์การทำงานของโมเดลที่ผิดพลาดกรณี False Positive นั้นสามารถสังเกตได้จากรูปที่ 4 จะเห็นว่ารูปแมวที่มีลักษณะการวาดที่ไม่เป็นระเบียบหรือมีรูปแบบเฉพาะที่เติมแต่งเพิ่มเข้าไปในภาพ ทำให้โมเดลจำแนกผิดว่าเป็นภาพของเด็กที่มีภาวะออทิสติก (ASD) แสดงถึงข้อจำกัดข้อจำกัดของโมเดลในการแยกแยะลักษณะเฉพาะบางอย่างในงานวาดของเด็กช่วงอายุ 9-12 ปี

จากการตรวจสอบผลการทำนายของโมเดล ResNet50 ในแต่ละ Fold พบว่ามีบางภาพที่โมเดลไม่สามารถทำนายผลได้อย่างถูกต้อง กล่าวคือ ภาพที่มีว่าเป็นเด็กที่มีภาวะออทิสติก (True: ASD) กลับถูกทำนายว่าเป็น Non-ASD (Pred: NonASD) และในทางกลับกัน ภาพที่เป็นของเด็กที่ไม่มีภาวะออทิสติก (True: NonASD) กลับถูกทำนายว่าเป็น ASD (Pred: ASD) ซึ่งถือเป็นข้อผิดพลาดในการจำแนกประเภท โดยเฉพาะอย่างยิ่งในกรณีที่โมเดลทำนายผิด แสดงให้เห็นถึงข้อจำกัดของโมเดล ในการประมวลผลลักษณะเฉพาะของภาพวาด สาเหตุหนึ่งที่เป็นไปได้คือ ลักษณะของภาพวาดที่คล้ายคลึงกับภาพของเด็กอีกกลุ่ม เช่น ในกรณีของภาพเด็กที่มีภาวะออทิสติกที่วาดภาพได้เป็นระเบียบและใกล้เคียงกับเด็กที่ไม่มีภาวะ หรือในทางกลับกัน ภาพของเด็กที่ไม่มีภาวะออทิสติกที่มีลักษณะขีดเขียนซ้ำ ๆ หรือมีโครงสร้างที่ไม่ชัดเจนอาจทำให้โมเดลเกิดความสับสน ตัวอย่างเช่น จากการวิเคราะห์กรณี False Negative สามารถสังเกตได้จาก รูปที่ 1 และรูปที่ 2 ซึ่งเป็นภาพวาดของเด็กที่มีภาวะออทิสติกที่มีการจัดองค์ประกอบอย่างมีแบบแผนคล้ายกับเด็กที่ไม่มีภาวะออทิสติก ส่งผลให้โมเดล

เข้าใจผิดและทำนายว่าเป็น Non-ASD ในทำนองเดียวกัน กรณี False Positive พบในรูปที่ 3 และรูปที่ 4 ซึ่งเป็นภาพของเด็กที่ไม่มีภาวะออทิสติกที่มีการขีดเขียนไม่เป็นระเบียบ ไม่มีรูปแบบหรือโครงสร้างชัดเจน ส่งผลให้โมเดลเข้าใจว่าเป็นลักษณะของเด็กที่มีภาวะออทิสติก ทั้งนี้ ความไม่เด่นชัดของภาพ เช่น ลายเส้นน้อย หรือพื้นที่ว่างมากเกินไป ก็เป็นอีกปัจจัยที่อาจส่งผลกระทบต่อความแม่นยำของโมเดลนอกจากนี้ ความหลากหลายของลักษณะในกลุ่มเด็กที่มีภาวะออทิสติกเอง ซึ่งอาจมีพฤติกรรมวาดภาพแตกต่างกันมาก ทำให้การใช้เพียงภาพวาดในการวินิจฉัยอาจยังไม่ครอบคลุมเพียงพอ จำเป็นต้องพิจารณาร่วมกับข้อมูลอื่น ๆ ทั้งในเชิงพฤติกรรม การสื่อสาร และบริบททางพัฒนาการของเด็ก

#### 4.3 การวิเคราะห์การทำงานของโมเดล

จากผลการทดสอบ พบว่าปัจจัยที่มีผลต่อความแม่นยำของโมเดล ได้แก่

4.3.1 การเลือกพารามิเตอร์ของโมเดล – ค่า Learning Rate ที่เหมาะสมช่วยให้โมเดลเรียนรู้ได้อย่างมีประสิทธิภาพ

4.3.2 การจำแนกภาพวาดของเด็กที่มีภาวะออทิสติกและเด็กที่ไม่มีภาวะ ในแต่ละ fold การใช้ k-fold cross-validation ช่วยให้เห็นประสิทธิภาพของโมเดลได้อย่างยุติธรรม โดยไม่เกิดการ overfitting และสามารถทำให้โมเดลมีการเรียนรู้ที่ดีจากข้อมูลทุกชุด

4.3.3 การทำ Data Augmentation ช่วยสร้างชุดข้อมูลที่มีความหลากหลายและลดปัญหา Overfitting ที่เกิดกับโมเดลได้

4.3.4 ความแตกต่างของลักษณะภาพวาด ภาพวาดของเด็กที่มีภาวะออทิสติกและเด็กที่ไม่มีภาวะออทิสติกมีลักษณะเฉพาะที่แตกต่างกัน ซึ่งส่งผลให้โมเดลสามารถเรียนรู้ได้ดีในบางกรณี แต่ยังมีข้อผิดพลาดบางส่วนที่ต้องปรับปรุง

4.3.5 โมเดลมีความแม่นยำและ F1-score สูงทั้งสองคลาส สะท้อนว่าโมเดลสามารถแยกแยะภาพวาดของเด็กที่มีภาวะออทิสติกและเด็กที่ไม่มีภาวะได้ดี

4.3.6 ค่าความสมดุลระหว่าง Precision และ Recall แสดงให้เห็นว่าโมเดลสามารถทำนายได้อย่างเหมาะสมทั้งสองคลาส

#### 4.4 การวิเคราะห์ข้อผิดพลาด

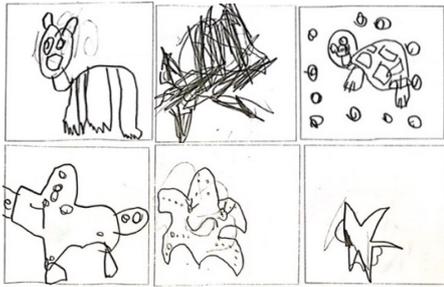
ข้อผิดพลาดที่เกิดขึ้นในการทำนายสามารถเกิดได้จากหลายปัจจัย จากการวิเคราะห์การทำงานของโมเดลที่ผิดพลาดในกรณี False Negative นั้นสามารถสังเกตได้จากรูปที่ 1 และรูปที่ 3 โดยเฉพาะความคล้ายคลึงของภาพวาดระหว่างเด็กที่มีภาวะ

ออทิสติกและเด็กที่ไม่มีภาวะออทิสติก ซึ่งในบางกรณี โมเดล อาจทำนายผิดเพราะภาพวาดบางภาพมีลักษณะคล้ายกันเกินไป เช่น การวาดเส้นที่ไม่ชัดเจน หรือการขาดรายละเอียดที่สำคัญ อีกทั้งยังมีปัจจัยจากภาพที่มีลักษณะผิดปกติ เช่น การบิดเบี้ยว หรือเบลอลงของภาพที่ทำให้โมเดลไม่สามารถจับลักษณะเฉพาะได้อย่างถูกต้อง

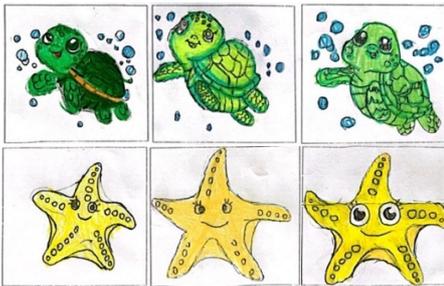
#### 4.5 การวิเคราะห์ลักษณะจากภาพและการประมวลผล

##### 4.5.1 การเลือกใช้สี

การวิเคราะห์การเลือกใช้สีจากรูปที่ 5 ภาพวาดแต่ละทะเลและ ปลาควา แสดงลักษณะการขีดเขียนซ้ำซ้อนด้วยเส้นสีดำจำนวนมาก บ่งบอกถึงการใช้สีอย่างจำกัดและการควบคุมกล้ามเนื้อเล็กที่ยังไม่พัฒนาเต็มที่ ซึ่งเป็นลักษณะที่พบได้ในเด็กที่มีภาวะออทิสติกที่มักแสดงพฤติกรรมซ้ำ ๆ และอาจมีข้อจำกัดในการแสดงออกทางอารมณ์ผ่านงานศิลปะ



รูปที่ 5. ตัวอย่างรูปภาพของเด็กที่มีภาวะออทิสติก



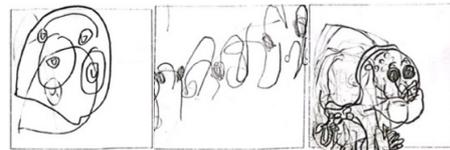
รูปที่ 6. ตัวอย่างรูปภาพของเด็กที่ไม่มีภาวะออทิสติก

การวิเคราะห์การเลือกใช้สีจากรูปที่ 6 ภาพวาดแต่ละทะเลและ ปลาควา แสดงถึงการเลือกใช้สีที่เหมาะสมและมีความสมดุล โดยใช้โทนสีเขียว น้ำฟ้า และสีเหลืองที่สื่อถึงธรรมชาติอย่างชัดเจน บ่งบอกถึงพัฒนาการทางอารมณ์และการรับรู้ที่เป็นระบบ รวมทั้งการควบคุมกล้ามเนื้อเล็กได้ดี ซึ่งเป็นลักษณะทั่วไปของเด็กที่ไม่มีภาวะออทิสติก

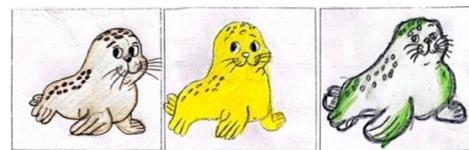
จากการเปรียบเทียบภาพวาด พบว่ามีลักษณะเด่นที่สะท้อน พฤติกรรมและพัฒนาการที่แตกต่างกันอย่างชัดเจน โดยรูปที่ 5 เป็นภาพที่ไม่มีมีการระบายสี ประกอบด้วยเส้นขีดเขียนซ้ำ ๆ ก่อนข้าง ไร้รูปแบบ สอดคล้องกับบุคลิกของเด็ก ASD ที่มักแสดงพฤติกรรมซ้ำ ๆ และอาจมีข้อจำกัดในการแสดงออกทางอารมณ์ผ่านงานศิลปะ การไม่เลือกใช้สี หรือการใช้สีอย่างจำกัด อาจสะท้อนถึงความยากลำบากในการรับรู้หรือแสดงออกทางอารมณ์ รวมถึงปัญหาในการควบคุมทักษะการเคลื่อนไหวละเอียดและการวางแผนการเคลื่อนไหวในทางตรงกันข้ามรูปที่ 6 ภาพวาดของเด็กที่ไม่มีภาวะออทิสติกแสดงถึงลักษณะที่สามารถแสดงออกทางอารมณ์และความคิดสร้างสรรค์ได้อย่างชัดเจน ใช้สีหลากหลาย ครอบคลุมทุกส่วนของภาพ ทั้งยังสามารถถ่ายทอดลักษณะของตัวการ์ตูนได้อย่างสมจริง มีการเลือกใช้สีที่เหมาะสมกับองค์ประกอบต่าง ๆ เช่น เปลือกเต่าสีเขียวเข้ม ตาโตแสดงความรู้สึกลึก และฟองอากาศรอบตัวที่ช่วยเสริมให้ภาพดูมีชีวิตชีวา การวาดภาพลักษณะนี้บ่งบอกถึงพัฒนาการด้านการรับรู้ การประมวลผลข้อมูลจากสิ่งแวดล้อมและความสามารถในการเชื่อมโยงจินตนาการกับทักษะการเคลื่อนไหว

##### 4.5.2 รูปทรง

การวิเคราะห์รูปทรงจากรูปที่ 7 ภาพวาดแมวน้ำแสดงถึงลักษณะการขีดเขียนที่ไม่เป็นระเบียบ ไร้ทิศทาง และขาดรูปทรงที่ชัดเจน สะท้อนถึงการรับรู้ภาพและการวางแผนเคลื่อนไหวที่ยังไม่พัฒนาเต็มที่ เด็กออทิสติกมักหลีกเลี่ยงรายละเอียดหรือความซับซ้อนในงานวาด และแสดงออกผ่านการใช้เส้นที่ซ้ำซ้อนหรือกระจาย



รูปที่ 7. ตัวอย่างรูปภาพของเด็กที่มีออทิสติก



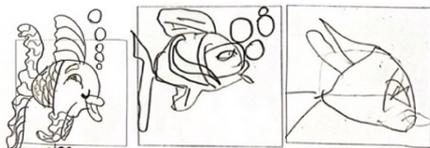
รูปที่ 8. ตัวอย่างรูปภาพของเด็กที่ไม่มีภาวะออทิสติก

การวิเคราะห์รูปทรงจากรูปที่ 8 ภาพวาดแมวน้ำแสดงถึงลักษณะการรับรู้รูปทรงที่เรียบง่ายแต่มีโครงสร้างชัดเจน เช่น การวาดตัวแมวน้ำที่มีลักษณะครบถ้วน มีดวงตา ใบหน้า ลำตัว และอวัยวะที่สัมพันธ์กันอย่างสมดุล สะท้อนถึงกระบวนการรับรู้ที่แม่นยำ การวางแผนล่วงหน้า

หากเปรียบเทียบกันแล้วพบว่าภาพวาดของเด็กที่มีภาวะออทิสติกในรูปที่ 7 แสดงให้เห็นถึงลักษณะการขีดเขียนที่ไม่เป็นระเบียบ ไร้ทิศทาง และขาดรูปทรงที่ชัดเจน สะท้อนถึงการรับรู้ภาพและการวางแผนเคลื่อนไหวที่ยังไม่พัฒนาเต็มที่ เด็กออทิสติกมักหลีกเลี่ยงรายละเอียดหรือความซับซ้อนในงานวาด และแสดงออกผ่านการใช้เส้นที่ซ้ำซ้อนหรือกระจายโดยไม่มีจุดมุ่งหมายที่แน่นอน ในขณะที่รูปที่ 8 ภาพวาดของเด็กที่ไม่มีภาวะออทิสติก แสดงให้เห็นถึงการรับรู้รูปทรงที่เรียบง่ายแต่มีโครงสร้างชัดเจน เช่น การวาดตัวแมวน้ำที่มีลักษณะครบถ้วน มีดวงตา ใบหน้า ลำตัว และอวัยวะที่สัมพันธ์กันอย่างสมดุล สะท้อนถึงกระบวนการรับรู้ที่แม่นยำ การวางแผนล่วงหน้า ความแตกต่างนี้ชี้ให้เห็นถึงความสามารถในการควบคุมการเคลื่อนไหว ความเข้าใจในโครงสร้างวัตถุ และระดับพัฒนาการด้านการสื่อสารผ่านภาพที่แตกต่างกันระหว่างเด็กออทิสติกกับเด็กทั่วไป

#### 4.5.3 การจัดเรียงองค์ประกอบ

การวิเคราะห์การจัดเรียงองค์ประกอบจากรูปที่ 9 ภาพวาดปลาแสดงถึงลักษณะการจัดวางองค์ประกอบมีลักษณะที่ไม่สมดุล เส้นขีดเขียนกระจายตัวอย่างไม่เป็นระเบียบ ไม่มีจุดโฟกัสหลัก และไม่มีการแบ่งพื้นที่ภาพอย่างชัดเจน ลักษณะเช่นนี้สะท้อนถึงความยากลำบากในการวางแผน การควบคุมกล้ามเนื้อมือ และการรับรู้ด้านมิติและพื้นที่



รูปที่ 9. ตัวอย่างรูปภาพของเด็กที่มีภาวะออทิสติก



รูปที่ 10. ตัวอย่างรูปภาพของเด็กที่ไม่มีภาวะออทิสติก

การวิเคราะห์การจัดเรียงองค์ประกอบจากรูปที่ 10 ภาพวาดปลาแสดงถึงลักษณะการจัดองค์ประกอบที่ชัดเจนและสมดุล ปลาถูกวางไว้บริเวณกึ่งกลางภาพ มีการเว้นระยะรอบข้างอย่างเหมาะสม และมีองค์ประกอบเสริม เช่น ฟองอากาศ ที่กระจายตัวอย่างสมดุลและเป็นธรรมชาติ การวางตำแหน่งองค์ประกอบอย่างมีแบบแผนนี้สะท้อนถึงความสามารถในการคิดวางแผนล่วงหน้าการมองเห็นภาพรวมของงาน

จากการเปรียบเทียบภาพวาดพบความแตกต่างที่ชัดเจนในเรื่องของการจัดวางองค์ประกอบภายในภาพ โดยในรูปที่ 9 ภาพวาดของเด็กที่มีภาวะออทิสติก พบว่าการจัดวางองค์ประกอบมีลักษณะที่ไม่สมดุล เส้นขีดเขียนกระจายตัวอย่างไม่เป็นระเบียบ ไม่มีจุดโฟกัสหลัก และไม่มีการแบ่งพื้นที่ภาพอย่างชัดเจน ลักษณะเช่นนี้สะท้อนถึงความยากลำบากในการวางแผน การควบคุมกล้ามเนื้อมือ และการรับรู้ด้านมิติและพื้นที่ ซึ่งเป็นลักษณะพฤติกรรมที่พบได้ในเด็กกลุ่มออทิสติก โดยเฉพาะในด้านของการจัดการพื้นที่ ในขณะที่รูปที่ 10 ภาพวาดของเด็กที่ไม่มีภาวะออทิสติกแสดงให้เห็นถึงการจัดองค์ประกอบที่ชัดเจนและสมดุล ตัวปลาถูกวางไว้บริเวณกึ่งกลางภาพ มีการเว้นระยะรอบข้างอย่างเหมาะสม และมีองค์ประกอบเสริม เช่น ฟองอากาศ ที่กระจายตัวอย่างสมดุลและเป็นธรรมชาติ การวางตำแหน่งองค์ประกอบอย่างมีแบบแผนนี้สะท้อนถึงความสามารถในการคิดวางแผนล่วงหน้าการมองเห็นภาพรวมของงาน และทักษะในการใช้พื้นที่อย่างมีประสิทธิภาพ ซึ่งส่วนนี้เป็นองค์ประกอบของพัฒนาการด้านความคิดและการรับรู้ที่เหมาะสมตามวัย

#### 4.6 สรุปผลการวิจัย

จากผลการวิจัยพบว่าการพัฒนาและประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกโดยใช้สถาปัตยกรรม ResNet50 สำหรับจำแนกภาพวาดของเด็กที่มีภาวะออทิสติก (ASD) และเด็กที่ไม่มีภาวะออทิสติก (NonASD) โดยใช้เทคนิค Cross-validation แบบ 5 Fold เพื่อความเสถียรของผลลัพธ์ ผลการทดลองแสดงให้เห็นว่าโมเดลมีค่า โดย Accuracy สูงขึ้นทั้งในกลุ่มอายุ 5-8 ปี (จาก 81.9% เป็น 87.7%) และ 9-12 ปี (จาก 89.5% เป็น 91.1%) ในกลุ่มเด็กอายุ 9-12 ปี โมเดลมีค่า Precision สูง สะท้อนว่าโมเดลสามารถจำแนกลักษณะเฉพาะของเด็กออทิสติกได้ดี อย่างไรก็ตาม ค่า Recall ที่ลดลงอาจเกิดจากความซับซ้อนของภาพวาดในเด็กโต ซึ่งบางภาพอาจเบี่ยงเบนจากรูปแบบที่โมเดลเรียนรู้มา นอกจากนี้ เด็กบางราย

อาจมีลักษณะของภาวะออทิสติกเทียม ซึ่งมีพัฒนาการดีกว่า และภาวะวาดกิลส์เคียงกับเด็กทั่วไป ทำให้โมเดลจำแนกผิดพลาดและส่งผลกระทบต่อความสามารถในการตรวจจับภาพกลุ่มออทิสติกได้อย่างครบถ้วน ในส่วนการวิเคราะห์การทำงานของโมเดลที่ผิดพลาดในกรณี False Negative นั้นสามารถสังเกตได้จากรูปที่ 1 และรูปที่ 3 โดยเฉพาะความคล้ายคลึงของภาพวาดระหว่างเด็กที่มีภาวะออทิสติกและเด็กที่ไม่มีภาวะออทิสติก ซึ่งในบางกรณีโมเดลอาจทำนายผิดเพราะภาพวาดบางภาพมีลักษณะคล้ายกันเกินไป สรุปได้ว่าโมเดล ResNet50 ที่พัฒนาขึ้นสามารถนำไปประยุกต์ใช้เป็นเครื่องมือช่วยคัดกรองเบื้องต้นจากลักษณะภาพวาดของเด็กในด้านการศึกษาและสุขภาพจิตได้อย่างมีประสิทธิภาพ

## 5. สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

### 5.1 สรุปผลการวิจัย

งานวิจัยนี้ใช้ชุดข้อมูลภาพวาดของเด็กที่มีภาวะออทิสติกและเด็กที่ไม่มีภาวะออทิสติกจำนวน 420 ภาพ แบ่งตามช่วงอายุเป็น 2 กลุ่ม ได้แก่ 5–8 ปี และ 9–12 ปี โดยใช้ ImageDataGenerator ของ TensorFlow แบ่งข้อมูลออกเป็นชุดฝึก (60%) และชุดตรวจสอบ (40%) พร้อมใช้เทคนิค Data Augmentation เพื่อเพิ่มจำนวนภาพรวมเป็น 3,780 ภาพ

โมเดลที่ใช้คือ ResNet50 ซึ่งเป็น CNN ที่มีประสิทธิภาพในการวิเคราะห์ภาพ โดยตั้งค่าการฝึกด้วย Adam optimizer, ReLU activation, จำนวนรอบฝึก 20 epochs, batch size 32 และ learning rate 0.001

ผลการศึกษาพบว่า การทำ Data Augmentation ส่งผลให้ประสิทธิภาพของโมเดล ResNet50 ดีขึ้นอย่างมีนัยสำคัญในทุกตัวชี้วัด โดยเฉพาะค่าความถูกต้อง (Accuracy) ที่เพิ่มขึ้นในทั้งสองกลุ่มอายุ โดยกลุ่ม 5–8 ปี เพิ่มขึ้นจาก 81.9% เป็น 87.7% และกลุ่ม 9–12 ปี เพิ่มขึ้นจาก 89.5% เป็น 91.1% นอกจากนี้ค่าความไว (Sensitivity) ของกลุ่ม 5–8 ปี ดีขึ้นอย่างมาก แสดงถึงความสามารถในการตรวจจับเด็กออทิสติกที่ดีขึ้น และค่าความจำเพาะ (Specificity) ของกลุ่ม 9–12 ปีก็เพิ่มขึ้น แสดงถึงความสามารถในการจำแนกเด็กทั่วไปได้แม่นยำขึ้น เช่นเดียวกับค่า F1-score ที่สูงขึ้นในกลุ่ม 5–8 ปี และอยู่ในระดับสูงในกลุ่ม 9–12 ปี ทั้งนี้ Confusion Matrix ยังยืนยันว่าโมเดลสามารถจำแนกทั้งเด็กออทิสติกและเด็กทั่วไปได้อย่างถูกต้องมากขึ้น โดยรวมแล้ว การทำ Data Augmentation มีบทบาท

สำคัญในการเพิ่มความแม่นยำและเสถียรภาพของโมเดล ทำให้เหมาะสมต่อการนำไปใช้ในการวิเคราะห์ภาพวาดของเด็กเพื่อช่วยสนับสนุนการวินิจฉัยภาวะออทิสติก

### 5.2 อภิปรายผลการวิจัย

จากผลการวิจัยพบว่าโมเดล ResNet50 มีประสิทธิภาพสูงในการจำแนกภาพวาดของเด็กที่มีภาวะออทิสติกและเด็กที่ไม่มีภาวะ โดยเฉพาะในกลุ่มอายุ 9–12 ปี ที่ให้ผลแม่นยำกว่าเล็กน้อย อันเนื่องมาจากการที่ชุดเงินของเด็กในช่วงวัยนี้ การใช้เทคนิค Cross-validation แบบ 5 Fold ช่วยประเมินความสามารถของโมเดลอย่างรอบด้าน อย่างไรก็ตาม ยังมีปัจจัยที่ส่งผลต่อผลลัพธ์ ได้แก่ คุณภาพข้อมูลภาพวาด, การตั้งค่าพารามิเตอร์ของโมเดล, ความหลากหลายของภาพวาด, และข้อผิดพลาดจากการทำนาย โดยเฉพาะกรณี False Negative นั้นสามารถสังเกตได้จากรูปที่ 1 และรูปที่ 3 ที่ลักษณะของภาพวาดมีความใกล้เคียงกัน ทั้งนี้ การวิเคราะห์ลักษณะของภาพวาดพบว่า เด็กที่มีออทิสติกมักใช้สีน้อย วาดซ้ำ วางองค์ประกอบไม่สมดุล และมีรูปทรงไม่ชัดเจน ดังรูปภาพตัวอย่างในรูปที่ 5 ถึงรูปที่ 10 จะตรงข้ามกับเด็กที่ไม่มีภาวะออทิสติก ซึ่งโมเดล ResNet50 สามารถแยกแยะความแตกต่างเหล่านี้ได้อย่างแม่นยำด้วยค่าความไวและความจำเพาะในระดับสูง แสดงให้เห็นถึงศักยภาพในการประยุกต์ใช้โมเดลกับงานลักษณะนี้ได้อย่างมีประสิทธิภาพ

### 5.3 ข้อจำกัดของการวิจัย

#### 5.3.1 ขนาดของชุดข้อมูล

แม้ว่าจะมีการใช้ Augmentation แต่จำนวนภาพต้นฉบับที่ใช้ยังมีขนาดจำกัด การเพิ่มความหลากหลายเชิงวัฒนธรรมก็สำคัญ เพราะเด็กในต่างพื้นที่อาจมีลักษณะการวาดภาพที่แตกต่างตามบริบทสังคม หากสามารถรวบรวมข้อมูลได้มากขึ้น อาจช่วยให้โมเดลเรียนรู้ได้ดีขึ้น

#### 5.3.2 การตีความผลลัพธ์

โมเดลสามารถจำแนกภาพวาดได้ในระดับหนึ่ง แต่ยังไม่สามารถให้เหตุผลหรืออธิบายถึงลักษณะเฉพาะของภาพที่เป็นปัจจัยในการจำแนกได้อย่างชัดเจน

#### 5.3.3 ข้อจำกัดทางด้านเทคนิค

การใช้โมเดล CNN จำเป็นต้องมีทรัพยากรด้านการประมวลผลสูง เช่น GPU ที่มีประสิทธิภาพสูง โดยเฉพาะเมื่อชุดข้อมูลจำนวนมากขึ้น

### 5.3.4 ปัจจัยทางด้านมนุษย์

พฤติกรรมและสภาพแวดล้อมของเด็กมีผลต่อสภาพแวดล้อมของพวกเขา ซึ่งเป็นปัจจัยที่โมเดลไม่สามารถนำมาพิจารณาได้โดยตรง

## 5.4 ข้อเสนอแนะ

5.4.1 แนวทางการนำไปใช้งานจริง ได้แก่ การพัฒนาเป็นเครื่องมือช่วยวินิจฉัยสำหรับแพทย์หรือนักจิตวิทยา โดยสามารถใช้ร่วมกับการวิเคราะห์พฤติกรรมเด็ก เช่น การสังเกตท่าทางขณะวาดภาพ เพื่อเสริมการประเมินความเสี่ยงของภาวะออทิสติกในเบื้องต้น นอกจากนี้ ยังสามารถพัฒนาเป็นแอปพลิเคชันบนอุปกรณ์แท็บเล็ตหรือ iPad ซึ่งเด็กสามารถวาดภาพและรับผลการวิเคราะห์เบื้องต้นได้แบบเรียลไทม์ เพื่ออำนวยความสะดวกในการคัดกรองในสถานศึกษา ศูนย์พัฒนาเด็กหรือคลินิกเฉพาะทาง ทั้งนี้ ควรมีการปรับปรุงโมเดลให้สามารถรองรับข้อมูลที่หลากหลายและซับซ้อนยิ่งขึ้น เพื่อเพิ่มความแม่นยำและความครอบคลุมในการประเมิน

5.4.2 แนวทางการวิจัยในอนาคต ควรเพิ่มขนาดและความหลากหลายแหล่งของชุดข้อมูล เพื่อเพิ่มความแม่นยำในการจำแนก ทดลองเปรียบเทียบกับโมเดลอื่น เช่น โมเดลที่ใช้ Transformer หรือ Generative AI และประยุกต์ใช้ Machine Learning ในการวิเคราะห์พฤติกรรมของเด็กแบบเรียลไทม์

## 5.5 สรุปภาพรวมของงานวิจัย

จากการดำเนินการวิจัยทั้งหมด พบว่าโมเดล CNN ที่ใช้ ResNet50 นี้สามารถจำแนกภาพวาดของเด็กที่มีภาวะออทิสติกและเด็กที่ไม่มีภาวะได้อย่างมีประสิทธิภาพ โดยมีค่า Accuracy เฉลี่ยเพิ่มขึ้นจาก 81.9% เป็น 87.7% หลังการทำ Data Augmentation โดยเฉพาะในกลุ่มอายุ 5–8 ปีที่มีการพัฒนาอย่างชัดเจน ขณะที่กลุ่มอายุ 9–12 ปียังคงรักษาค่าความแม่นยำได้อย่างดี จาก 89.5% เป็น 91.1% ส่วนข้อผิดพลาดจากการทำนาย โดยเฉพาะกรณี False Negative นั้นสามารถสังเกตได้จากรูปที่ 1 และรูปที่ 3 ที่ลักษณะของภาพวาดมีความใกล้เคียงกัน ทั้งนี้ การวิเคราะห์ลักษณะของภาพวาดพบว่า เด็กที่มีออทิสติกมักใช้สีน้อย วาดซ้ำ วางองค์ประกอบไม่สมดุล และมีรูปทรงไม่ชัดเจน ดังรูปภาพตัวอย่างในรูปที่ 5 - รูปที่ 10 นอกจากนี้โมเดลยังให้ผลลัพธ์ที่ดีในด้านตัวชี้วัดอื่น ๆ และไม่พบปัญหา overfitting อย่างมีนัยสำคัญ แสดงให้เห็นถึงความสามารถของโมเดลในการเรียนรู้ลักษณะเฉพาะจากภาพวาดของเด็กที่มีภาวะออทิสติก ซึ่งสามารถนำไปประยุกต์ใช้เพื่อช่วยในการ

วินิจฉัยเบื้องต้นในพื้นที่ที่ขาดแคลนผู้เชี่ยวชาญ ทั้งนี้ควรมีการพัฒนาต่อยอดโดยเพิ่มความหลากหลายของข้อมูล และทดลองใช้โมเดลหรือเทคนิคอื่น ๆ เพื่อเพิ่มความแม่นยำและความน่าเชื่อถือของระบบ

## เอกสารอ้างอิง

- [1] MedPark Hospital, “Autism Spectrum Disorder (ASD),” MedPark Hospital, Available: <https://www.medparkhospital.com/disease-and-treatment/autism-spectrum-disorder>. [Accessed: Dec. 24, 2024].
- [2] Art Therapy Resources, “The Power of Art Therapy for Children with Autism,” Art Therapy Resources [Online]. Available: [https://arttherapyresources-comau.translate.google.com/children-autism/?\\_x\\_tr\\_sl=en&\\_x\\_tr\\_tl=th&\\_x\\_tr\\_hl=th&\\_x\\_tr\\_pto=tc](https://arttherapyresources-comau.translate.google.com/children-autism/?_x_tr_sl=en&_x_tr_tl=th&_x_tr_hl=th&_x_tr_pto=tc). [Accessed: Dec. 24, 2024].
- [3] T. Thepsena, C. Khemapatapan, and D. Rakrattanatrai, “Reservoir release forecasting by artificial neural network at Pa Sak Jolasid Dam,” 2022 7th International STEM Education Conference (iSTEM-Ed). IEEE, pp. 1–6, July 06, 2022. doi: 10.1109/istem-ed55321.2022.9920896.
- [4] A. Jeamaon and C. Khemapatapan, “Development Cyber Risk Assessment for Intrusion Detection Using Enhanced Random Forest,” ECTI-CIT Transactions, vol. 18, no. 4, pp. 429–442, Sept. 2024, doi: 10.37936/ecti-cit.2024184.256185.
- [5] R. Quaglia, C. Longobardi, N. O. Iotti, and L. E. Prino, “A new theory on children’s drawings: Analyzing the role of emotion and movement in graphical development,” Infant Behavior and Development, vol. 39, pp. 81–91, May 2015, doi: 10.1016/j.infbeh.2015.02.009.
- [6] B. Kamala, K. S. Mahanaga Pooja, S. Varsha, and K. Sivapriya, “ML Based Approach to Detect Autism Spectrum Disorder (ASD),” The 4th International Conference on Computing and Communications Technologies (ICCCCT), pp. 313–318, Dec. 16, 2021. doi: 10.1109/iccct53315.2021.9711826. J. Deng, M. Rakibul Hasan, M. Mahmud, M. Mahbub Hasan, K. Asif Ahmed,

- [7] and M. Zakir Hossain, “Diagnosing Autism Spectrum Disorder Using Ensemble 3D-CNN: A Preliminary Study,” The IEEE International Conference on Image Processing (ICIP), pp. 3480–3484, Oct. 16, 2022. doi: 10.1109/icip46576.2022.9897628.
- [8] Md. F. Rabbi, S. M. M. Hasan, A. I. Champa, and Md. A. Zaman, “A Convolutional Neural Network Model for Early-Stage Detection of Autism Spectrum Disorder,” 2021 International Conference on Information and Communication Technology for Sustainable Development (ICICT4SD), pp. 110–114, Feb. 27, 2021. doi: 10.1109/icict4sd50815.2021.9397020.
- [9] R. Patankar, S. Vedpathak, V. Thakre, P. Sethi, and S. Sawarkar, “AutiScan: Screening of Autism Spectrum Disorder Specific to Indian Region,” The IEEE 3rd Global Conference for Advancement in Technology (GCAT), pp. 1–8, Oct. 07, 2022. doi: 10.1109/gcat55367.2022.9972038.
- [10] V. Kavitha and R. Siva, “Classification of Toddler, Child, Adolescent and Adult for Autism Spectrum Disorder Using Machine Learning Algorithm,” Proceeding of the 2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS), pp.2444-2449, Mar 2023, doi: 10.1109/ICACCS57279.2023.10112932.
- [11] J. Shin, Md. Maniruzzaman, Y. Uchida, Md. A. M. Hasan, A. Megumi, and A. Yasumura, “Handwriting-Based ADHD Detection for Children Having ASD Using Machine Learning Approaches,” IEEE Access, vol. 11, pp. 84974–84984, 2023, doi: 10.1109/access.2023.3302903.
- [12] M. Mosharraf and F. Banabazi, “Identifying Children’s Personality Styles through Drawing Analysis using Machine Learning,” The 14th International Conference on Information and Knowledge Technology (IKT), pp. 7–12, Dec. 26, 2023. doi: 10.1109/ikt62039.2023.10433056.
- [13] A. Popescu and N. Popescu, “Drawing Interpretation Using Neural Networks and Accessibility Implementation in Mobile Application,” Computation, vol. 10, no. 11, p. 202, Nov. 2022, doi: 10.3390/computation10110202.
- [14] A. Hendr, U. Ozgunalp, and M. Erbilek Kaya, “Diagnosis of Autism Spectrum Disorder Using Convolutional Neural Networks,” Electronics, vol. 12, no. 3, p. 612, Jan. 2023, doi: 10.3390/electronics120306