

## บทที่ 4 ผลการวิจัย

### 4.1 การตรวจจับการนั่งนึ่ง

การตรวจจับการนั่งนึ่ง ประกอบด้วยการทดลอง 2 ส่วน ได้แก่ การเลือกคุณลักษณะ และการจำแนก ซึ่งผลลัพธ์ที่ได้จากการทดลองในหัวข้อนี้ คือ วิธีการสร้างตัวจำแนกที่น่าพอใจที่สุด สำหรับการตรวจจับการนั่งนึ่ง

#### 4.1.1 การเลือกคุณลักษณะ

จากผลการทดลอง ตามบทที่ 3.2.3 ผู้วิจัยได้ผลลัพธ์ดังต่อไปนี้

##### ก. Independent Samples T-test

ผลลัพธ์ที่ได้จาก Independent Samples T-test มีความคล้ายคลึงกัน โดย Levene's Test แสดงให้เห็นว่า ทุกคุณลักษณะมีความแตกต่างในความแปรปรวนภายใต้ประเภทของข้อมูลที่แตกต่างกัน (*Move* และ *Still*) ค่าความผิดพลาดอย่างมีนัยสำคัญ (Significant Error) ของทุกคุณลักษณะ มีค่าน้อยกว่า 0.0001 (ตัวอย่าง ดังรูปที่ 4.1) ซึ่งบ่งชี้ว่า คุณลักษณะทั้งหมดมีความเกี่ยวข้องกับประเภทของข้อมูล บนระดับความเชื่อมั่นที่ 99.99% กล่าวคือ ทุกคุณลักษณะสามารถนำมาใช้ทำนายประเภทของข้อมูลได้ อย่างไรก็ตาม เนื่องจากค่าความผิดพลาดอย่างมีนัยสำคัญมีค่าที่ต่ำมาก ผู้วิจัยจึงไม่สามารถจัดลำดับความสำคัญของคุณลักษณะได้ ว่าคุณลักษณะใดมีความสำคัญมากที่สุด

Method	Variances	DF	t Value	Pr >  t
Pooled	Equal	1324	31.65	<.0001
Satterthwaite	Unequal	674.1	31.65	<.0001

Equality of Variances				
Method	Num DF	Den DF	F Value	Pr > F
Folded F	662	662	109.40	<.0001


รูปที่ 4.1 Independent Samples T-test ในโปรแกรม SAS Enterprise Guide

(ตัวแปรอิสระ = *Class*, ตัวแปรตาม = *Head\_Dist\_Avg*)

### ข. D-Tree, Optimal Decision Nodes

จากการทดลองสร้างโมเดลด้วย D-Tree (รูปที่ 4.2) โดยใช้คุณลักษณะทั้งหมด ผู้วิจัยพบว่าคุณลักษณะ 5 คุณลักษณะเด่นที่อยู่ระดับบนสุดของต้นไม้ ได้แก่

{ *ElbowLeft\_Dist\_Avg*, *ShoulderRight\_Dist\_Avg*, *ShoulderLeft\_Dist\_V*,  
*HandLeft\_Dist\_Max*, *WaistRight\_Dist\_Avg* }

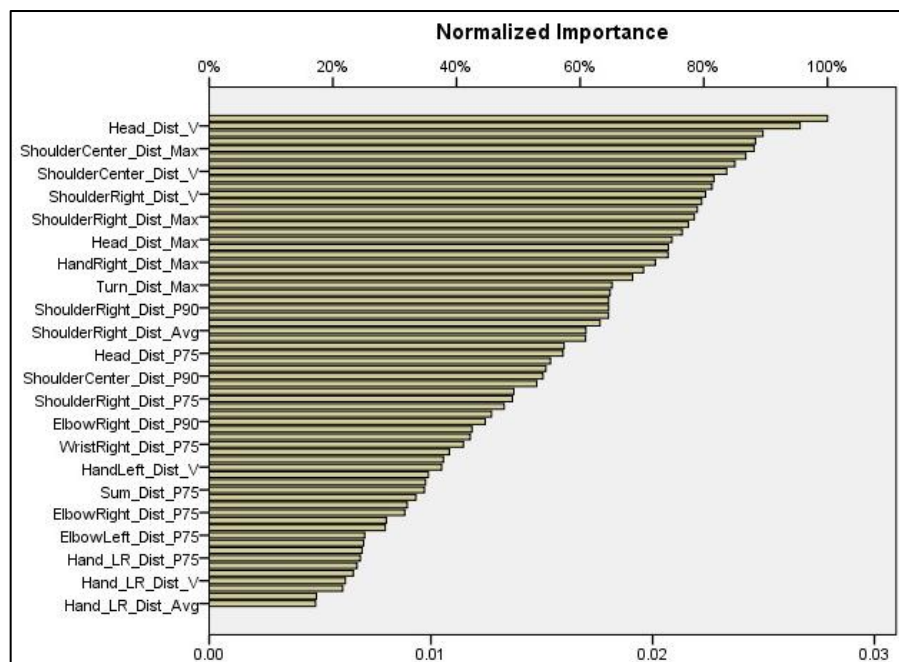


รูปที่ 4.2 D-Tree ที่สร้างจากคุณลักษณะทั้งหมด

### ค. Neural Network และ Normalize Importance (SPSS)

จากการทดลองสร้างโมเดลด้วย Neural Network ในโปรแกรม SPSS คุณลักษณะที่ถูกระบุว่ามีความสำคัญมากที่สุด 5 อันดับแรก ใน Normalized Importance (รูปที่ 4.3) ได้แก่

{ *Head\_Dist\_V*, *ShoulderCenter\_Dist\_Max*, *ShoulderRight\_Dist\_V*,  
*ShoulderRight\_Dist\_V*, *ShoulderRight\_Dist\_Max* }

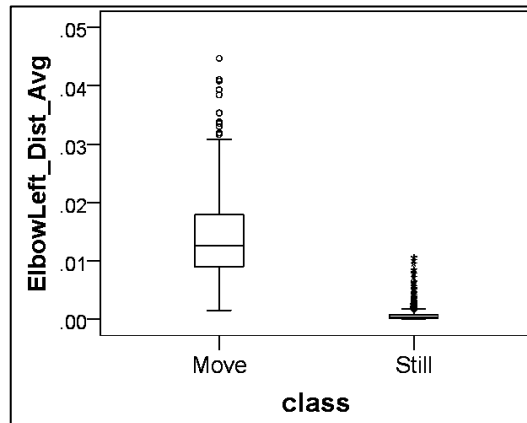


รูปที่ 4.3 Normalized Importance ที่ได้จากการสร้างโมเดลด้วย Neural Network ในโปรแกรม SPSS

### ง. Boxplot

จากการพล็อตกราฟด้วย Boxplot (เช่น รูปที่ 4.4) ผู้วิจัยพบว่าคุณลักษณะที่น่าสนใจ ที่สามารถแสดงผลต่างระหว่างข้อมูล 2 ประเภท บน Boxplot ได้ชัดเจน ได้แก่

{ *ElbowLeft\_Dist\_Avg*, *ElbowRight\_Dist\_Avg*, *ShoulderRight\_Dist\_Avg*,  
*Head\_Dist\_Avg*, *ElbowRight\_Dist\_V* }



รูปที่ 4.4 Boxplot ที่แสดงผลต่างใน *ElbowLeft\_Dist\_Avg* ระหว่างข้อมูล 2 ประเภท

จากผลลัพธ์ที่ได้ด้วยวิธีการดังที่กล่าวมา ผู้วิจัยได้จัดชุดของคุณลักษณะ (Sets of Features) ออกมาหลายชุด ด้วยการผสมคุณลักษณะต่างๆ ที่ได้จากคำแนะนำ โดยจัดให้มีความหลากหลาย และผู้วิจัยยังคำนึงถึงว่า ชุดของคุณลักษณะที่จัดขึ้นควรมีความเหมาะสม คือ มีประเภทของคุณลักษณะที่เหมือนกัน (เช่น เป็นความแปรปรวนทั้งหมด หรือเป็นค่าเฉลี่ยทั้งหมด) และมีความสมเหตุสมผลในทางตรรกะ (เช่น แทนที่จะใช้ { *ElbowLeft\_Dist\_Avg*, *ShoulderRight\_Dist\_V* } ตามคำแนะนำที่ได้จาก D-Tree ตรงๆ ก็เปลี่ยนไปใช้ { *ElbowLeft\_Dist\_Avg*, *ElbowRight\_Dist\_Avg* } หรือ { *ShoulderLeft\_Dist\_V*, *ShoulderRight\_Dist\_V* } แทน

#### 4.1.2 การจำแนก

ชุดของคุณลักษณะแต่ละชุด ได้ถูกนำไปสร้างโมเดลการจำแนกด้วยวิธีการต่างๆ 4 วิธี ดังที่กล่าวไว้ในบทที่ 3.2.3 การฝึกฝนและทดสอบได้ทำขึ้นโดยใช้วิธี 10-fold Cross Validation เพื่อป้องกันการเกิด Overfitting จากผลการทดลอง ผู้วิจัยพบว่าอัตราความแม่นยำในการจำแนก จะถึงจุดที่เหมาะสมที่สุดเมื่อใช้จุดบนร่างกาย คือ { *Head\_Dist\_Avg*, *ElbowLeft\_Dist\_Avg*, *ElbowRight\_Dist\_Avg* }

ข้อสอกเป็นจุดที่มีความสำคัญที่สุด ซึ่งทราบจากการเลือกคุณลักษณะ ดังนั้น จุด *ElbowLeft* และ *ElbowRight* จึงถูกพิจารณาเป็นอันดับแรก ส่วนจุดหัว คือ *Head* ได้ถูกเพิ่มเข้ามา เพื่อให้โมเดล

สามารถครอบคลุมร่างกายส่วนบนเกือบทั้งร่างกายได้ (ผู้วิจัยพบว่า บางอิริยาบถของการเคลื่อนไหว ข้อศอกจะไม่ขยับ แต่ส่วนหัวจะขยับ)

ตารางที่ 4.1 ได้แสดงให้เห็นว่า อัตราความแม่นยำที่ได้จากการผสมผสานเทคนิคต่างๆ ทุกสายงาน ล้วนเป็นที่น่าพึงพอใจ ขณะที่ระยะเวลาประมวลผลของโมเดลแบบต่างๆ มีน้อยมาก จนไม่มีความแตกต่างกันอย่างมีนัยยะสำคัญ

ตารางที่ 4.1 อัตราความแม่นยำในการจำแนก เพื่อตรวจจับการนั่งนิ่ง

ที่อาศัยจุดบนร่างกาย { Head\_Dist\_Avg, ElbowLeft\_Dist\_Avg, ElbowRight\_Dist\_Avg}

Method	Normalization		
	Non	GMM	PMM
D-Tree	98.11%	* 98.04%	97.66%
Bays	98.19%	98.19%	95.17%
KNN (K5)	96.83%	98.27%	96.08%
NN	98.04%	98.04%	96.00%

ผู้วิจัยได้พิจารณาถึงความผิดพลาดเชิงบวกและเชิงลบของโมเดล โดยในการตรวจจับการนั่งนิ่ง มุ่งเน้นการจับการเคลื่อนไหวเพื่อหยุดสภาวะการนั่งนิ่งต่อเนื่อง (*Positive = Move*) ดังนี้

- ความผิดพลาดเชิงบวก (**False Positive**) หมายถึงการที่ผู้ใช้ นั่งนิ่ง แต่ระบบตีความว่าผู้ใช้มีการเคลื่อนไหว
- ความผิดพลาดเชิงลบ (**False Negative**) หมายถึงการที่ผู้ใช้มีการเคลื่อนไหว แต่ระบบตีความว่าผู้ใช้ นั่งนิ่ง

สำหรับระบบติดตามสุขภาพ ผู้วิจัยเห็นว่าความผิดพลาดเชิงลบเป็นสิ่งที่ยอมรับได้มากกว่าความผิดพลาดเชิงบวก เพราะงานวิจัยทางการยศาสตร์สนับสนุนว่าผู้ทำงานควรมีการเคลื่อนไหวร่างกายอย่างสม่ำเสมอ และระบบที่น่าเสนอสร้างขึ้นเพื่อสนับสนุนให้มีการเคลื่อนไหวร่างกายเพียงพอกความจำเป็นขั้นต่ำ ดังนั้นแล้ว เมื่อความผิดพลาดเชิงลบเกิดขึ้น จะกระตุ้นให้ผู้ทำงานมีการเคลื่อนไหวร่างกายมากกว่าความจำเป็นขั้นต่ำ ซึ่งไม่น่ามีผลเสียใดๆ ในขณะที่ความผิดพลาดเชิงบวกจะทำให้ผู้ใช้เคลื่อนไหวร่างกายไม่เพียงพอต่อความต้องการ ซึ่งเป็นผลเสียต่อสุขภาพอย่างเห็นได้ชัด

เมื่ออ้างอิงหลักการดังกล่าว หากวิเคราะห์ข้อมูลความถูกต้องและความผิดพลาดในการตรวจจับที่ได้ ดังตารางที่ 4.2 จะเห็นได้ว่า โมเดลที่ดีที่สุดที่ถูกกล่าวถึงในบทที่ 4.1 มีความผิดพลาดเชิงบวกและเชิงลบ อยู่ที่ 12 และ 14 ฟิลด์ จากข้อมูลทดสอบจำนวน 1,326 ฟิลด์

ตารางที่ 4.2 ข้อมูลความถูกต้องและความผิดพลาดในการตรวจจับการนั่ง

			Predicted-Actual			
			M-M	S-S	M-S	S-M
Model	Normalization	Accuracy	True+	True-	False+	False-
D-Tree	NoN	98.11%	650	651	12	13
	GMM	98.04%	649	651	12	14
Bays	PMM	97.66%	646	649	14	17
	NoN	98.19%	660	642	21	3
	GMM	98.19%	660	642	21	3
KNN (K5)	PMM	95.17%	622	640	23	41
	NoN	96.83%	643	641	22	20
	GMM	98.27%	651	652	11	12
NN	PMM	96.00%	638	635	28	25
	NoN	98.04%	655	645	18	8
	GMM	98.04%	655	645	18	8
	PMM	96.08%	644	630	33	19

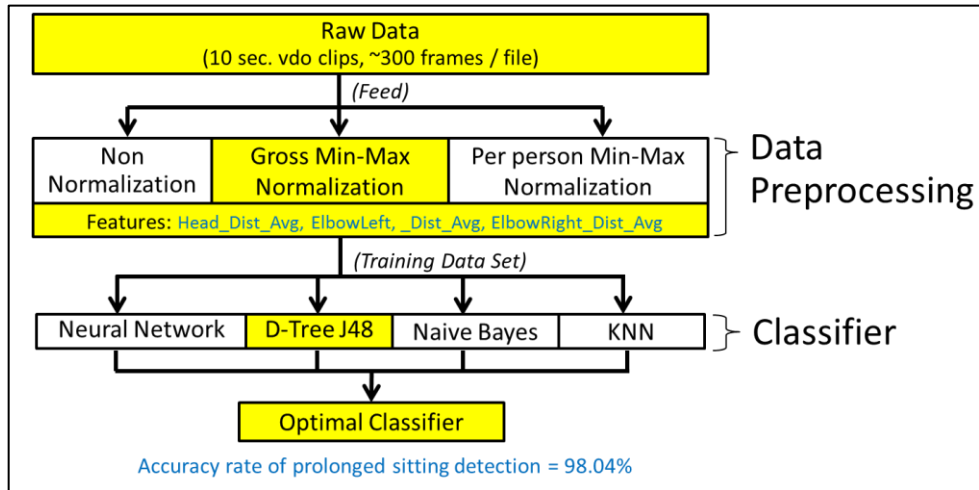
\*\* Total = 1,326 feeds

เมื่อวิเคราะห์จากตารางแล้ว โมเดลที่น่าพอใจที่สุด ควรจะลดค่าความผิดพลาดเชิงบวกให้เหลือน้อยที่สุด ซึ่งโมเดลดังกล่าว คือ KNN (N=5) และ D-Tree ที่ใช้การ Normalization แบบ GMM ซึ่งโมเดลทั้งสองมีความแม่นยำ และความผิดพลาดเชิงบวกที่ใกล้เคียงกันมาก

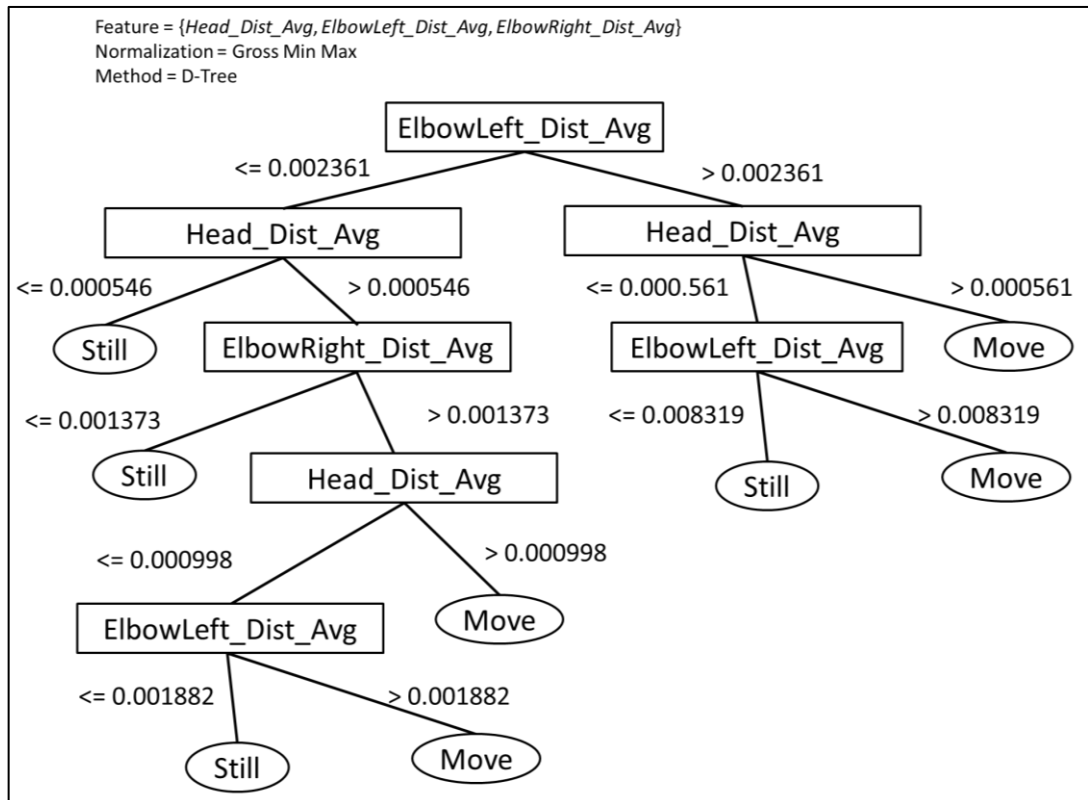
ในกรณีที่โมเดลมีความแม่นยำ และข้อผิดพลาดใกล้เคียงกัน ผู้วิจัยเห็นว่าในการเลือกโมเดลที่น่าพอใจที่สุด สมควรเลือกโมเดลที่เรียบง่าย และดูแล้วเข้าใจที่มาได้

การ Normalization เป็นสิ่งจำเป็น ในการรับมือกับปัญหาเรื่องความแตกต่างในขนาดตัวของผู้ใช้ หากนำ PMM มาใช้ ระบบจะต้องจดจำค่าสูงสุดและต่ำสุดของผู้ใช้แต่ละคน ขณะเดียวกัน หากนำ GMM มาใช้ ระบบจะสามารถทำงานกับผู้ใช้ใดๆ ได้เลย โดยอาศัยค่าสูงสุดและค่าต่ำสุดที่มีอยู่แล้วจากชุดข้อมูลฝึกฝน ดังนั้น การ Normalization แบบ GMM จะทำให้ระบบมีความแข็งแกร่งมากกว่า

สำหรับวิธีการจำแนก D-Tree ได้ถูกเลือกเป็นวิธีการสร้างโมเดลที่น่าพอใจที่สุด เนื่องจากเหตุผลสนับสนุนว่าเป็นโมเดลจะสามารถอ่านเข้าใจและรู้ที่มาที่ไปได้ ดังนั้นแล้ว ตัวจำแนกที่น่าพอใจที่สุด จึงถูกสร้างขึ้น โดยอาศัยจุดบนร่างกาย ได้แก่ { Head\_Dist\_Avg, ElbowLeft\_Dist\_Avg, ElbowRight\_Dist\_Avg } โดยทำการ Normalization แบบ GMM และสร้างโมเดลแบบ D-Tree ซึ่งอัตราความแม่นยำที่ได้ อยู่ที่ 98.04% ซึ่งสรุปได้ดังรูปที่ 4.5 และโมเดลมีโครงสร้างดังรูปที่ 4.6



รูปที่ 4.5 สายงานที่ได้ตัวจำแนกที่น่าพอใจที่สุด (Optimal Workflow)



รูปที่ 4.6 ตัวจำแนกที่น่าพอใจที่สุด (Optimal Classifier)

## 4.2 การตรวจจับท่าทาง

ผลลัพธ์ที่ได้จากทดลองเรื่องการตรวจจับท่าทาง คือ อัตราความแม่นยำของทฤษฎีที่ใช้ในการอ่าน อองศาร่างกาย รวมถึงโมเดลค่าคงที่ที่ใช้ในการจับการเปลี่ยนแปลงในท่าทางของผู้ใช้ ผู้วิจัยได้นำระบบ ไปทดสอบในสภาพแวดล้อมการทำงานจริง กับอาสาสมัครจำนวน 10 คน โดยให้ปฏิบัติท่าทางต่างๆ ท่าละ 100 ครั้ง และดูว่าระบบสามารถตรวจจับได้ถูกต้องกี่ครั้ง

สำหรับการตรวจจับการลุกนั่ง และการลุกออกไปพัก ระบบสามารถตรวจจับได้ด้วยอัตราความ แม่นยำ 100% ตราบเท่าที่โครงร่างของมนุษย์สามารถเห็นได้จากกล้อง (ผู้ใช้ไม่หลุดออกจากขอบเขต การตรวจจับของกล้อง) ส่วนท่าทางอื่นๆ ได้อัตราความแม่นยำ ดังตารางที่ 4.2

ตารางที่ 4.3 อัตราความแม่นยำในการตรวจจับท่าทาง

user	setup	gender	height	Pitch	NotPitch	TwistL	TwistR	NotTwist
1	1	M	178	100%	100%	82%	96%	100%
2	1	M	178	93%	100%	77%	98%	100%
3	1	F	155	97%	100%	84%	94%	100%
4	1	M	175	92%	100%	72%	93%	100%
5	1	F	170	96%	100%	79%	95%	100%
6	2	F	150	100%	100%	94%	87%	100%
7	2	M	180	92%	100%	91%	85%	100%
8	2	M	173	84%	100%	83%	87%	100%
9	2	F	162	91%	100%	98%	90%	97%
10	2	F	160	100%	100%	100%	91%	100%


ระบบได้ถูกทดสอบด้วยการติดตั้งระบบ 2 แบบ ในแบบที่ 1 ( $setup = 1$ ) กล้องได้ถูกตั้งไว้ทาง ตะวันออกเฉียงเหนือของผู้ใช้ (ดังรูปที่ 3.2 การติดตั้งที่แนะนำ) ส่วนในแบบที่ 2 ( $setup = 2$ ) กล้องได้ ถูกตั้งไว้ทางตะวันตกเฉียงเหนือ ทั้งนี้ เนื่องจากผู้วิจัยสังเกตว่าความแม่นยำในการตรวจจับการบิดตัว (องศาการหัน) น่าจะได้รับผลกระทบจากทิศทางของกล้อง กล่าวคือ เวลาที่กล้องตั้งอยู่ทางขวา ระบบ จะตรวจจับการบิดตัวทางขวาได้ดีกว่าการบิดตัวทางซ้าย ดังที่เห็นได้จากตารางว่า ข้อมูล 5 ตัวอย่าง แรก ความแม่นยำในการตรวจจับการบิดตัวทางขวา ( $TwistR$ ) จะมีค่าสูงกว่าความแม่นยำในการ ตรวจจับการบิดตัวทางซ้าย ( $TwistL$ )

เพื่อพิสูจน์สมมุติฐานดังกล่าวนี้ ผู้วิจัยได้แปลงข้อมูลให้อยู่ในรูปแบบดังตารางที่ 4.3 โดย  $TwistL$  หมายถึง ความแม่นยำในการตรวจจับการบิดตัว เมื่อผู้ใช้บิดเข้าหาทิศทางที่ตั้งกล้อง (รูปที่ 4.7 ภาพ ซ้าย) ขณะที่  $TwistR$  หมายถึง การบิดตัวในที่ทิศทางที่ตรงกันข้ามกับกล้อง (รูปที่ 4.7 ภาพขวา) ส่วน  $\delta$  หมายถึง ผลต่างในอัตราความแม่นยำ ( $TwistR - TwistL$ )

เมื่อข้อมูลอยู่ในรูปดังกล่าว สมมติฐานว่าง คือ “ $\delta = 0$ ” ได้ถูกทดสอบ ด้วย One-Sample T-test และผลลัพธ์ คือ สมมติฐานว่างได้ถูกปฏิเสธโดยค่าความผิดพลาดอย่างมีนัยสำคัญน้อยกว่า 0.001 และสรุปได้ว่า อัตราความแม่นยำของการบิดตัวเข้าหากล้อง สูงกว่าการบิดตัวไปในทิศทางตรงกันข้ามที่ประมาณ 10.79%.

ตารางที่ 4.4 อัตราความแม่นยำในการตรวจจับท่าทาง ที่ถูกแปลงรูป

user	gender	height	Pitch	NotPitch	Twist1	Twist2	delta	NotTwist
1	M	178	100%	100%	96%	82%	14%	100%
2	M	178	93%	100%	98%	77%	21%	100%
3	F	155	97%	100%	94%	84%	10%	100%
4	M	175	92%	100%	93%	72%	21%	100%
5	F	170	96%	100%	95%	79%	16%	100%
6	F	150	100%	100%	94%	87%	7%	100%
7	M	180	92%	100%	91%	85%	6%	100%
8	M	173	84%	100%	83%	87%	-4%	100%
9	F	162	91%	100%	98%	90%	8%	97%
10	F	160	100%	100%	100%	91%	9%	100%
	<b>Mean</b>	<b>168</b>	<b>94.50%</b>	<b>100.00%</b>	<b>94.19%</b>	<b>83.40%</b>	<b>10.79%</b>	<b>99.70%</b>



รูปที่ 4.7 การบิดตัว


ผู้วิจัยได้ใช้ Independent Samples T-test เพื่อตรวจหาปัจจัยที่ส่งผลกระทบต่อความแม่นยำในการตรวจจับ (ตารางที่ 4.4) เช่น การตั้งกล้อง หรือเพศของผู้ใช้ อย่างไรก็ตามค่าความผิดพลาดอย่างมีนัยสำคัญทุกค่า ล้วนสูงกว่า 0.05 ซึ่งการปฏิเสธสมมติฐานว่างล้มเหลว และนำไปสู่ข้อสรุปว่า เพศของผู้ใช้งาน และการตั้งกล้อง จะไม่ส่งผลกระทบต่ออัตราความแม่นยำในการตรวจจับท่าทางใดๆ ยกเว้นเพียงความแม่นยำของการตรวจจับการบิดตัวไปทิศตรงข้ามกับกล้อง (*Twist2*) ที่ระบบตรวจจับได้ดีกว่า เมื่อใช้การตั้งกล้องแบบที่ 1 ( $setup = 1$ ) ส่วนอัตราความแม่นยำของการตรวจจับ “การไม่ก้มหน้า” อยู่ที่ 100% และค่าความผิดพลาดอย่างมีนัยสำคัญไม่สามารถหาได้

#### ตารางที่ 4.5 ค่าความผิดพลาดอย่างมีนัยยะสำคัญ

จากการใช้ Independent Samples T-test หาความสัมพันธ์ระหว่างตัวแปร

	Pitch	NotPitch	Twist1	Twist2	NotTwist
setup	0.53	N/A	0.538	0.004	0.724
gender	0.167	N/A	0.199	0.148	0.374

สำหรับความสัมพันธ์ระหว่างอัตราความแม่นยำในการตรวจจับท่าทางใดๆ กับความสูงของผู้ใช้ ผู้วิจัยได้ทำการวิเคราะห์โดยอาศัยการพล็อตข้อมูลด้วยกราฟจุด (Scatter Plot) ดังรูปที่ 4.8 แต่ไม่พบรูปแบบใดๆ จากกราฟ (เช่น ความสัมพันธ์เชิงเส้นตรง หรือเส้นโค้ง) ซึ่งนำไปสู่ข้อสรุปว่า อัตราความแม่นยำในการตรวจจับท่าทางใดๆ ไม่ได้รับผลกระทบจากความสูงของผู้ใช้



รูปที่ 4.8 กราฟจุดที่บอกความสัมพันธ์ระหว่างตัวแปร

(แนวตั้ง คือ ความสูงของผู้ใช้, แนวนอน คือ อัตราความแม่นยำของการตรวจจับท่าทางใดๆ)

### 4.3 การใช้งาน และระดับการยอมรับ

จากการทดลองดังที่กล่าวในบทที่ 3.3.5 ผู้วิจัยได้เก็บผลคะแนนจากอาสาสมัคร โดยตามความเห็นที่ผู้ใช้คิดว่าระบบมีประโยชน์หรือไม่ (Usefulness) ใช้งานง่ายหรือไม่ (Ease of Use) และพึงพอใจกับแนวคิดของระบบหรือไม่ (Satisfaction) ซึ่งได้ผลออกมาดังตารางที่ 4.5

#### ตารางที่ 4.6 ข้อมูลเรื่องการใช้งาน และระดับการยอมรับ

user	gender	Useful	Easy	Satisfaction
1	M	9	9	9
2	M	9	8	8
3	F	10	10	10
4	M	10	9	10
5	F	10	10	10
6	F	10	8	10
7	M	10	10	9
8	M	8	8	9
9	F	8	10	8
10	F	10	10	10
	Mean	9.40	9.20	9.30

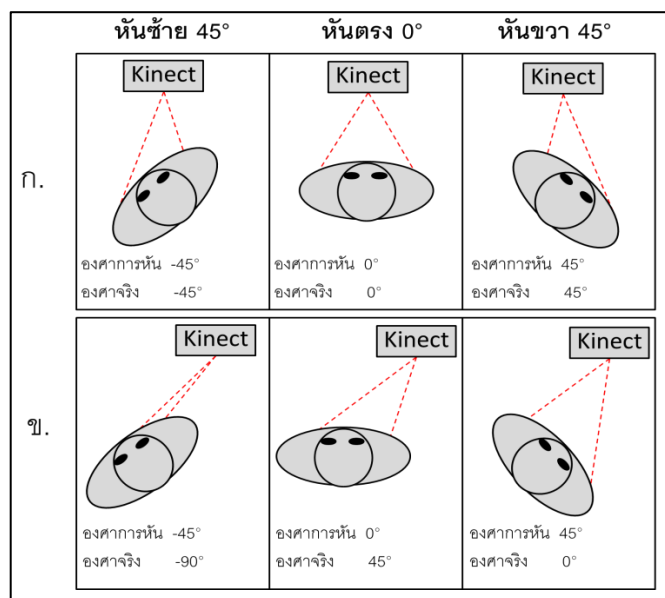
จากการทดสอบสมมุติฐานต่างๆด้วย Independent Samples T-test สมมุติฐานว่างได้ถูกปฏิเสธ และได้ข้อสรุปว่า ไม่มีความแตกต่างในเรื่องการใช้งาน และระดับการยอมรับ ระหว่างผู้ใช้ที่เป็นผู้ชายกับผู้หญิง

#### 4.4 อภิปรายผล

จากการนำระบบที่สมบูรณ์ไปทดสอบในสภาพแวดล้อมการทำงานจริง ผู้วิจัยพบว่าระบบสามารถทำงานได้ในสภาพแวดล้อมที่หลากหลาย และสามารถทำงานได้ค่อนข้างมีเสถียรภาพ ต่อผู้ใช้ที่มีลักษณะแตกต่างกันในด้านขนาดร่างกาย ความสูง อายุ หรือเพศ และจากการทดสอบระบบต้นแบบ ผู้วิจัยค้นพบประเด็นต่างๆ ที่น่าสนใจ ดังนี้

##### 4.4.1 ข้อจำกัดด้านทัศนวิสัย

จากผลการทดสอบตามในบทที่ 4.2 ซึ่งแสดงให้เห็นว่าการบิดตัวทั้งสองข้าง มีค่าความแม่นยำแตกต่างกันอย่างมีนัยยะสำคัญ ผู้วิจัยสันนิษฐานว่าสาเหตุน่าจะมาจากทัศนวิสัยของกล้อง กล่าวคือ สภาพการติดตั้ง ทำให้กล้อง Kinect มองเห็นส่วนต่างๆ ของร่างกายได้ชัดเจนไม่เท่ากัน ซึ่งเป็นสมมุติฐานที่เป็นไปได้สูง เพราะกล้อง Kinect จะตรวจจับโครงร่างของมนุษย์ได้ดีเมื่อผู้ใช้หันตรงเข้าหากกล้อง (รูปที่ 4.9 ก. ภาพกลาง) ดังนั้น เมื่อกล้องติดตั้งอยู่ด้านขวาของผู้ใช้ 45° (รูปที่ 4.9 ข.) การที่ผู้ใช้บิดตัวไปทางขวา จะเสมือนเป็นการหันตรงเข้าหากกล้อง ในขณะที่การบิดตัวไปทางซ้าย จะเสมือนหันข้างเข้าหากกล้อง ซึ่งกล้องน่าจะตรวจจับจุดบนร่างกายโดยเฉพาะจุดไหล่ซ้ายได้ยากขึ้น



รูปที่ 4.9 การมองเห็นของกล้อง กับ การบิดตัวของผู้ใช้  
(ก. คือ การติดตั้งในอุดมคติ, ข. คือ การติดตั้งที่แนะนำ)

#### 4.4.2 อิทธิพลของท่าทางเริ่มต้น

ระบบที่นำเสนอ คำนวณการเปลี่ยนแปลงในโครงสร้างกาย โดยใช้การเปรียบเทียบของร่างกาย ณ เวลาใดๆ กับองศาของท่าทางเริ่มต้น (บทที่ 3.3.3) ดังนั้นแล้ว คุณภาพของท่าทางเริ่มต้นจะมีผลต่อประสิทธิภาพการตรวจจับ ผู้ใช้จึงต้องมีความรู้เรื่องท่าทางที่ถูกสุขลักษณะตามหลักกายศาสตร์ และต้องมีความเข้าใจในการใช้กล้อง Kinect กล่าวคือ ในระหว่างจดจำท่าทาง จะต้องนั่งตัวตรงไม่ก้มหน้ามองตรงไปข้างหน้า และต้องสั่งให้ระบบจดจำท่าทางเมื่อโครงสร้างเริ่มเสถียร

การจดจำท่าทางเริ่มต้นมีความจำเป็นในขณะนี้ เพราะผู้วิจัยยังไม่สามารถหาแนวทางอื่นเพื่อระบุแนวระนาบ และองศาการหันเริ่มต้นได้ กล่าวคือ หากไม่มีท่าทางเริ่มต้น ระบบจะไม่สามารถทราบได้เลยว่าองศาที่เวลาใดๆ หมายถึงการก้มหน้า หรือการไม่ก้มหน้า องศาการหันที่เวลาใดๆ หมายถึงการนั่งตัวตรง หรือการนั่งบิดตัว รวมถึงระยะห่างเท่าใดที่จะบอกได้ว่าผู้ใช้ลุกออกไปพัก

#### 4.4.3 ความอ่อนไหวต่อแกน Z (Sensitivity to Z-Axis)

สมมุติฐานว่า ระหว่างผู้ใช้ยืนใกล้และอยู่ไกล ความสามารถในการตรวจจับท่าทางจะมีความแม่นยำไม่เท่ากัน และการตรวจจับน่าจะเกิดข้อผิดพลาดจากแกน Z ได้มากกว่าแกน X และ Y

การทดสอบระบบที่จัดทำขึ้น จัดทำในสภาพแวดล้อมที่ผู้ใช้อยู่ห่างประมาณ 1-2 เมตร จึงยังไม่พบความอ่อนไหวต่อแกน Z ที่ชัดเจน แต่การวิเคราะห์ดังกล่าวจะมีความสำคัญ สำหรับงานในอนาคตที่ต้องการตรวจจับท่าทางของผู้ใช้ที่ลุกออกไปในระยะเกินกว่า 2 เมตร ผู้วิจัยจึงขอเสนอแนะให้เก็บข้อมูลตัวอย่าง และวิเคราะห์หาด้วยวิธีทางสถิติ เช่น Independent Samples T-test เพื่อดูว่าความแม่นยำในการตรวจจับ ได้รับผลกระทบจากระยะห่างจากกล้องหรือไม่

#### 4.4.4 การประเมินผลการสร้างมโนภาพ (Visualization Evaluation)

ผู้วิจัยไม่ได้ทำการประเมินผลการสร้างมโนภาพโดยตรง แต่ประเมินระบบเป็นภาพรวม (บทที่ 4.3) อย่างไรก็ตาม เนื่องจากการสร้างมโนภาพเป็นส่วนสำคัญส่วนหนึ่งของระบบ ผู้วิจัยจึงเห็นว่าสมควรมีการประเมินผลการสร้างมโนภาพอย่างละเอียดในอนาคต

### ก. เทคนิคที่สามารถนำมาใช้

จากการทบทวนวรรณกรรมเกี่ยวกับการประเมินผลการสร้างมโนภาพ การสร้างมโนภาพที่ดีจะช่วยให้ผู้ใช้สามารถเข้าถึง จดจำ และตีความข้อมูลได้อย่างมีประสิทธิภาพมากขึ้น [164] โดยในการประเมิน สามารถอาศัยเทคนิคต่างๆ ดังนี้

#### 1. การทดสอบภายใต้สภาพแวดล้อมที่มีการควบคุม

ยกตัวอย่างเช่น งานของ Chen et al. [165, 166] ที่หาความสัมพันธ์ระหว่างตัวแปรอิสระ ได้แก่ เครื่องมือ งาน ข้อมูล และประเภทของผู้ใช้ กับตัวแปรตาม ได้แก่ ความแม่นยำ และประสิทธิภาพ โดยความแม่นยำวัดจากความถูกต้องในการตีความข้อมูล และประสิทธิภาพวัดจากเวลาที่ใช้ในการปฏิบัติงานดังกล่าว โดยเทียบกับเวลาที่ตั้งเป็นมาตรฐานไว้ อีกตัวอย่างหนึ่ง คือ งานของ Kobsa et al. [167] ที่ประเมินผลระบบการสร้างมโนภาพที่แตกต่างกัน 3 ระบบ โดยทดลองกับการปฏิบัติงานต่างๆ ซึ่งงานดังกล่าวมีการตั้งคำตอบเตรียมไว้ การประเมินผลทำโดยเปรียบเทียบเวลาที่ผู้ใช้ ใช้เพื่อหาคำตอบของคำถามที่ตั้งไว้ และความถูกต้องของคำตอบที่ได้

#### 2. การประเมินการใช้งาน

เป็นการประเมินที่ให้ความสำคัญกับส่วนเชื่อมต่อของผู้ใช้ โดยอาศัยการสังเกตการใช้งานภายใต้การปฏิบัติงานที่ออกแบบไว้ ยกตัวอย่างเช่น การใช้เทคนิคการคิดออกเสียง (Think Aloud Protocol) [168] ที่ให้ผู้ใช้แก้ไขปัญหา พร้อมกับพูดสิ่งที่คิดไปด้วย เพื่อดูวิธีการคิดวิเคราะห์ของผู้ใช้ในขณะที่ใช้งานระบบ ซึ่งเหมาะจะใช้หาจุดบกพร่องต่างๆ เช่น จุดที่ไม่ชัดเจนของมโนภาพ ที่อาจทำให้ผู้ใช้ตีความหมายของข้อมูลผิดไป

#### 3. การศึกษาภาคสนาม และการศึกษาระยะยาว

เป็นการศึกษาที่ให้ความสำคัญกับ สิ่งที่เรียนรู้และค้นพบได้จากมโนภาพ โดยในแต่ละวัน จะให้ผู้ใช้เขียนสิ่งที่เรียนรู้ได้จากข้อมูลเป็นบันทึกสั้นๆ ผู้ใช้จะได้รับการฝึกฝนการใช้มโนภาพอย่างต่อเนื่อง และจะค่อยๆ มีความชำนาญมากขึ้น บันทึกที่ได้จะถูกนำไปวิเคราะห์โดยผู้เชี่ยวชาญ เพื่อดูว่าความสามารถในการแก้ไขปัญหา และสิ่งที่เรียนรู้จากข้อมูลผ่านทางมโนภาพ มีแนวโน้มการเปลี่ยนแปลงเป็นอย่างไร [169]

## ข. สิ่งบ่งชี้ความสำเร็จของมโนภาพ

ความสำเร็จของมโนภาพ [164, 170] มีองค์ประกอบสำคัญดังนี้

### 1. ในระยะยาว สามารถทำให้ผู้ใช้มองเห็นมุมมองใหม่ๆ ในข้อมูลเดิม

การค้นพบ (Discovery) ส่วนใหญ่ไม่ได้สิ่งที่เกิดขึ้นทันทีทันใด แต่เกิดจากการเรียนรู้และจัดการกับข้อมูลเดิมซ้ำๆ เหมือนเช่นที่นักชีววิทยาศึกษาข้อมูลชุดเดิมอยู่หลายสัปดาห์หรือหลายเดือนเพื่อหารูปแบบของยีน กล่าวคือ ธรรมชาติของการเรียนรู้จะเริ่มจากการทำความเข้าใจ ทำความคุ้นเคย และหามุมมองใหม่ๆ จากสิ่งเดิม จนเกิดเป็นการค้นพบ

การประเมินผลมโนภาพส่วนใหญ่จะเป็นการสังเกตระยะสั้น และผู้ใช้ระบบมักเป็นมือใหม่ที่ยังไม่เข้าใจเครื่องมือเท่าที่ควร ทำให้ความสนใจของผู้ใช้ไปอยู่ที่ส่วนเชื่อมต่อแทนการสนใจในสิ่งที่เห็นได้จากข้อมูล ซึ่งขณะที่การประเมินผลระยะยาว จะเป็นการประเมินที่มีประสิทธิภาพมากกว่า เพราะช่วยให้เห็นถึงพฤติกรรมที่เปลี่ยนไปของผู้ใช้ และเห็นถึงผลกระทบที่เกิดจากการสร้างมโนภาพ อย่างไรก็ตามการประเมินในระยะยาวเป็นสิ่งที่สิ้นเปลือง และยากที่จะปฏิบัติ รวมถึงจำเป็นต้องมีแนวทางการเก็บข้อมูลที่มีประสิทธิภาพ เพื่อนำข้อมูลเดิมกลับมาศึกษาซ้ำในอนาคต

### 2. สามารถตอบโจทย์ ที่ไม่มีโจทย์

“ตอบโจทย์ ที่ไม่มีโจทย์” หมายถึง การที่ผู้ใช้มโนภาพสามารถค้นพบสิ่งใหม่ๆ ที่เป็นคำตอบของคำถามที่ไม่ได้ถูกตั้งไว้ หรือไม่เคยมองด้วยซ้ำว่าจะมีคำถามดังกล่าวอยู่ คือการที่มโนภาพสามารถนำไปสู่การค้นพบที่ไม่คาดคิด ซึ่งจะมีประโยชน์อย่างมากเมื่อวิเคราะห์งานที่ประเด็นมีความน่าสนใจ และมีการสนับสนุนให้ผู้ใช้สามารถวิเคราะห์ข้อมูลและรายงานสิ่งที่พบเจออย่างอิสระ

### 3. เพิ่มโอกาสในการค้นพบ และการกระตุ้นความสนใจ

งานวิจัยส่วนมากจะให้ความสำคัญกับการประเมินเวลาที่ผู้ใช้ปฏิบัติงาน และปริมาณข้อผิดพลาด อย่างไรก็ตาม สิ่งในงานวิจัยส่วนมากมักละเลย คือ การศึกษาปัจจัยที่ก่อให้เกิดข้อผิดพลาด เช่น ผลกระทบจากส่วนเชื่อมต่อผู้ใช้ ที่ทำให้เกิดการตีความข้อมูลผิดไป รวมถึงการศึกษาในโอกาสที่จะก่อให้เกิดการค้นพบแนวโน้มนหรือสิ่งใหม่ๆ จากข้อมูล และอีกปัจจัยสำคัญที่ควรหาทางประเมิน คือ ความสามารถของมโนภาพในการกระตุ้นให้ผู้ใช้ค้นคว้าต่อข้อมูล สามารถจดจำรายละเอียดได้ดีขึ้น และส่งผลให้ใช้ความคิดตัดสินใจได้อย่างมีประสิทธิภาพ

## 4.5 การประเมินระบบโดยผู้เชี่ยวชาญ

ภายหลังระบบพัฒนาจนแล้วเสร็จ ผู้วิจัยได้สอบถามความเห็นจาก รศ.พญ. ปิยะภัทร เดชพระธรรม ผู้เชี่ยวชาญด้านเวชศาสตร์ฟื้นฟู ซึ่งได้รับคำแนะนำ และความเห็นที่มีต่อระบบ โดยรายละเอียดเพิ่มเติมของการประเมิน สามารถดูได้จากภาคผนวก ค.

### 4.5.1 ประเด็นทั่วไป

- ผู้เชี่ยวชาญมีความเห็นว่าระบบติดตามโรคคนทำงานออฟฟิศจะช่วยเตือนสติผู้ทำงานให้ระวังสุขภาพการนั่งได้ ซึ่งเป็นสิ่งสำคัญมาก เพราะในการรักษาโรคคนทำงานออฟฟิศ แพทย์พบปัญหาว่าผู้ป่วยที่รับการรักษาจำนวนมาก ที่อาการทุเลาแล้ว ก็กลับมาเป็นอีก เนื่องจากผู้ป่วยกลับไปใช้นิสัยแบบเดิมๆ ด้วยเหตุผลว่าไม่มีสมาธิจะใส่ใจทำนั่งขณะทำงาน
- รายงานสุขภาพจะสามารถสร้างแรงกระตุ้นให้ผู้ทำงานใส่ใจสุขภาพมากขึ้น เนื่องจากสามารถเห็นถึงแนวโน้มการเปลี่ยนแปลงในพฤติกรรม และสุขภาพของตนเอง
- การจัดสถานที่หรือโต๊ะทำงานเป็นสิ่งสำคัญมาก เพราะสามารถส่งผลทั้งต่อความแม่นยำการตรวจจับและพฤติกรรมของผู้ใช้ ดังนั้น สมควรจัดสถานที่ทำงานให้มีความเหมาะสมตามหลักการยศาสตร์ ก่อนการติดตั้งระบบ
- สำหรับการตรวจจับการนั่ง การอาศัยจุดบนร่างกาย 3 จุด ถือว่าสามารถครอบคลุมอากัปกิริยาการเคลื่อนไหวร่างกายส่วนใหญ่ ที่เพียงพอจะเป็นผลดีต่อสุขภาพ
- การก้มหน้าและการบิดตัวที่จะส่งผลต่อสุขภาพ จะเป็นท่าทางที่มองเห็นได้ชัดเจน ซึ่งกล้องน่าจะตรวจจับได้ ผู้เชี่ยวชาญกล่าวว่า ยังไม่น่าจะมีงานวิจัยใดที่สนับสนุนว่าการถนัดซ้าย-ขวาของผู้ใช้ ส่งผลให้บิดตัวซ้าย-ขวาได้ต่างกันอย่างมีนัยยะสำคัญ
- อายุ เป็นปัจจัยหนึ่ง ที่มีความสัมพันธ์โดยตรงกับความเสียหายทางสุขภาพ รวมถึงพฤติกรรมการนั่ง เช่น ผู้ใช้ที่มีอายุมาก มีโอกาสที่จะติดนิสัยนั่งก้มหน้ามากกว่าคนหนุ่มสาว อีกทั้งท่าทางที่ผิดสุขลักษณะ และการนั่งเป็นระยะเวลาานาน จะส่งผลเสียต่อร่างกายผู้สูงอายุมากกว่า

### 4.5.2 การประเมินผลการสร้างมโนภาพ

รายงานสุขภาพอาจไม่ส่งผลต่อการวินิจฉัยของแพทย์อย่างมีนัยยะสำคัญ เนื่องจากแพทย์จะให้ความสำคัญที่อาการซึ่งเกิดจากผู้ป่วยเป็นหลัก แต่มโนภาพจะมีประโยชน์ที่สุดในด้านการสร้างแรงจูงใจต่อผู้ใช้ ดังนั้น การประเมินสมควรประเมินในประเด็นที่ว่า “มโนภาพสามารถสร้างแรงใจและมีส่วนช่วยในการปรับเปลี่ยนพฤติกรรมของผู้ใช้อย่างไร” ซึ่งการประเมิน สมควรใช้การประเมินแบบระยะยาว

### 4.5.3 คะแนนและระดับความเสี่ยงทางสุขภาพโดยรวม

จากบทที่ 3.4.2 การประเมินความเสี่ยงทางสุขภาพโดยรวมในปัจจุบัน ตั้งอยู่บนสมมติฐานว่า 3 หัวข้อ การตรวจจับ คือ การนั่งนิ่ง การก้มหน้า และการบิดตัว มีความสำคัญเท่าๆกัน

ผู้เชี่ยวชาญมีความเห็นว่าสิ่งสำคัญในการติดตามสุขภาพการนั่ง คือ การติดตามระยะเวลาการนั่งของผู้ใช้ ในการประเมินคะแนนและระดับความเสี่ยงทางสุขภาพโดยรวม สัดส่วนที่เหมาะสมนั้นกำหนดได้ยาก เพราะการนั่งนิ่งมีความสำคัญสูงกว่ามาก เมื่อเทียบกับการก้มหน้าและการบิดตัว ส่วนการก้มหน้าและการบิดตัวถือว่ามีระดับความเสี่ยงพอๆกัน ดังนั้นแล้ว ทางแก้ไขหนึ่งที่เป็นไปได้ คือ แยกความเสี่ยงทางสุขภาพเป็นสองส่วน ส่วนแรกเป็นการนั่งนิ่งอย่างเดียว และส่วนที่สองที่คือท่าทางการนั่ง (การก้มหน้าและการบิดตัว) อย่างไรก็ตาม การคิดระดับความเสี่ยงรวมจากทั้งสามหัวข้อ ก็ยังสามารถทำได้ แต่ต้องปรับสัดส่วนใหม่ ให้การนั่งนิ่งเป็นระยะเวลานานมีน้ำหนักความสำคัญที่เด่นชัด ผู้วิจัยจึงได้ปรับสัดส่วนการคำนวณใหม่ดังตารางที่ 4.7

ตารางที่ 4.7 สัดส่วนการคำนวณความเสี่ยงทางสุขภาพโดยรวม

Prolonged	Pitch	Twisted	Total Risk
70%	15%	15%	100%

### 4.5.4 ความเห็นเรื่องการกรองสัญญาณรบกวน

ในการติดตามสุขภาพการนั่ง จะให้ความสำคัญกับความต่อเนื่องของท่าทางเป็นระยะเวลานาน เช่น ครึ่งชั่วโมง หรือหลายชั่วโมง แม้แต่การก้มหน้า หรือการบิดตัว หากเกิดขึ้นเพียงช่วงเวลาสั้นๆ ก็สามารถเป็นผลดีต่อสุขภาพได้เสมือนการยืดเส้นยืดสาย หรือเปลี่ยนท่าก้มหน้า สำหรับการกรองสัญญาณรบกวนถือว่าไม่ได้มีนัยยะสำคัญทางการแพทย์ ดังนั้น หากการกำหนด Buffer Time 1 วินาที สามารถป้องกันสัญญาณรบกวนได้ ก็ถือว่าเพียงพอ และหากการตรวจจับ จะมีระยะเวลาต่างๆ คลาดเคลื่อนต่างกันเพียงไม่กี่วินาที ถือว่าไม่มีผลกระทบต่อสุขภาพ

### 4.5.5 การวัดความผิดพลาดเชิงบวกและเชิงลบของโมเดล

ข้อผิดพลาดเชิงลบเป็นสิ่งที่ยอมรับได้มากกว่าความผิดพลาดเชิงบวก แต่เนื่องจากโมเดลแต่ละตัวมีความแม่นยำที่สูงมากอยู่แล้ว จึงกล่าวได้ว่า ไม่มีข้อแตกต่างที่มีนัยยะสำคัญนัก ทั้งนี้ ผู้เชี่ยวชาญให้ความเห็นเพิ่มเติมว่า สมควรมุ่งเน้นความสนใจไปที่อัตราความแม่นยำในการตรวจจับท่าทาง เช่น การก้มหน้า และการบิดตัว มากกว่า เพราะความแม่นยำในการตรวจจับท่าทางทั้งสองมีโอกาสได้รับผลกระทบจากการติดตั้งระบบ