

บทที่ 4

ระเบียบวิธีวิจัย

สำหรับเนื้อหาในบทนี้จะแสดงถึงแนวทางและกรอบการศึกษาต่าง ๆ เพื่อให้การค้นคว้าแบบอิสระดำเนินไปอย่างเป็นขั้นเป็นตอน อีกทั้งยังสามารถบรรลุถึงเป้าหมายและวัตถุประสงค์ที่ได้กำหนดไว้

4.1 การเก็บข้อมูลตัวแปรที่ใช้สำหรับการศึกษา

การศึกษาในครั้งนี้มีวัตถุประสงค์ในการหาระบบพยากรณ์ที่มีประสิทธิภาพมากที่สุด สำหรับการพยากรณ์ราคาน้ำมันดิบที่สะท้อนให้เห็นถึงต้นทุนที่แท้จริงของมูลค่าการใช้พลังงานของไทย ดังนั้นจึงเลือกใช้ราคาน้ำมันดิบดูไบ ซึ่งประเทศไทยใช้เป็นราคาอ้างอิง (Benchmark) หลัก สำหรับการนำเข้าน้ำมันดิบจากต่างประเทศ มาเป็นตัวแปรในการศึกษา

ซึ่งการรวบรวมข้อมูลในครั้งนี้ จะใช้ซอฟต์แวร์ Reuter 3000 ในการเข้าถึงข้อมูลสารสนเทศ โดยจะเลือกใช้ข้อมูลที่มีลักษณะเป็นอนุกรมเวลา (Time Series) ซึ่งก็คือราคาปิด (Spot Price) รายวันของน้ำมันดิบดูไบฟาเทห์ (Dubai Fateh) โดยแบ่งข้อมูลออกเป็น 2 ช่วง คือ ข้อมูลที่ให้ตัวแบบทั้ง 3 ประเภทใช้ในการสร้างระบบพยากรณ์ เป็นจำนวนทั้งสิ้น 4,838 วัน ตั้งแต่วันที่วันที่ 1 มกราคม พ.ศ. 2540 ถึงวันที่ 31 มีนาคม พ.ศ. 2553 และข้อมูลที่ใช้สำหรับเปรียบเทียบความแม่นยำในการพยากรณ์ของตัวแบบทั้ง 3 ประเภท อีก 45 วัน ตั้งแต่วันที่วันที่ 1 เมษายน พ.ศ. 2553 ถึงวันที่ 15 พฤษภาคม พ.ศ. 2553

4.2 การสร้างระบบพยากรณ์

การพยากรณ์ราคาน้ำมันดิบดูไบ (Dubai Crude Oil) จะใช้ตัวแบบสำหรับการศึกษาครั้งนี้ทั้งหมด 3 ตัวแบบคือ ตัวแบบบ็อกซ์และเจนกินส์ (Box&Jenkins Model) ตัวแบบการช (GARCH Model) และตัวแบบโครงข่ายประสาทประดิษฐ์ (ANNs Model) ซึ่งรายละเอียดของการใช้ตัวแบบแต่ละประเภทในการสร้างระบบพยากรณ์มีดังนี้

4.2.1 การสร้างระบบพยากรณ์ด้วยตัวแบบบ็อกซ์และเจนกินส์ (Box&Jenkins Model)

ขั้นตอนในการพยากรณ์ด้วยตัวแบบบ็อกซ์และเจนกินส์ ประกอบด้วย 5 ขั้นตอนคือ การเตรียมข้อมูล (Data Preparation) การเลือกตัวแบบ (Model Selection) การประมาณค่าพารามิเตอร์

(Parameter Estimation) การตรวจสอบความถูกต้อง (Model Checking) และการพยากรณ์ (Forecasting)

4.2.1.1 การเตรียมข้อมูล (Data Preparation)

เพื่อให้เป็นไปตามข้อกำหนดของการวิเคราะห์อนุกรมเวลา ดังนั้นในขั้นแรกจะ ใช้การทดสอบดิกกี-ฟูลเลอร์ฉบับขยาย (Augmented Dickey-Fuller : ADF Test) เพื่อตรวจสอบว่า อนุกรมเวลาที่พิจารณาของคุณสมบัติหยุดนิ่ง (Non-Stationary) หรือไม่ หากว่าคุณสมบัติดังกล่าว จะต้องใช้วิธีการแปลงข้อมูล (Transformation) ด้วยการหาผลต่าง (Differencing) ไปเรื่อย ๆ จน สามารถตรวจสอบได้ว่าอนุกรมเวลานั้น ๆ มีคุณสมบัติหยุดนิ่ง (Stationary) จึงจะสามารถ ดำเนินการในขั้นตอนต่อ ๆ ไปได้

4.2.1.2 การเลือกตัวแบบ (Model Selection)

ขั้นตอนนี้คือการหากระบวนการอัตโนมัติ (Autoregressive : AR) และ กระบวนการค่าเฉลี่ยเคลื่อนที่ (Moving Average : MA) ที่เหมาะสมให้กับอนุกรมเวลา โดยพิจารณา จากแผนภาพสหสัมพันธ์ (Correlogram) ของฟังก์ชันสหสัมพันธ์ (Autocorrelation Function : ACF) และฟังก์ชันสหสัมพันธ์บางส่วน (Partial Autocorrelation Function : PACF) โดยที่การ เลือกกระบวนการอัตโนมัติ และกระบวนการค่าเฉลี่ยเคลื่อนที่ ควรเน้นหลักของการมัธยัสถ์ (Parsimonious) กล่าวคือ พารามิเตอร์ของตัวแบบต้องสามารถอธิบายการเคลื่อนไหวของอนุกรม เวลาได้เป็นอย่างดี โดยใช้จำนวนพารามิเตอร์ให้น้อยที่สุด

4.2.1.3 การประมาณค่าพารามิเตอร์ (Parameter Estimation)

วิธีที่ได้รับความนิยมและใช้กันโดยทั่วไปสำหรับการประมาณค่าสัมประสิทธิ์ (Coefficient) ของพารามิเตอร์ คือ วิธีกำลังสองน้อยที่สุดแบบสามัญ (Ordinary Least Square : OLS Method) ซึ่งค่าประมาณของพารามิเตอร์ที่ได้จากวิธีดังกล่าว เป็นค่าประมาณที่ให้ผลรวมกำลังสอง ของค่าคลาดเคลื่อน (Sum of Square Error : SSE) มีค่าน้อยที่สุด โดยพารามิเตอร์ที่มีความเหมาะสม สำหรับนำไปสร้างสมการพยากรณ์ ต้องยอมรับสมมติฐานว่าสัมประสิทธิ์ที่ประมาณค่าได้แตกต่าง จากศูนย์ กล่าวคือค่าความน่าจะเป็น (Probability-Value : Prob) ของค่าสถิติที (t-Statistic) มีค่าน้อย กว่าระดับนัยสำคัญ (significant : α)

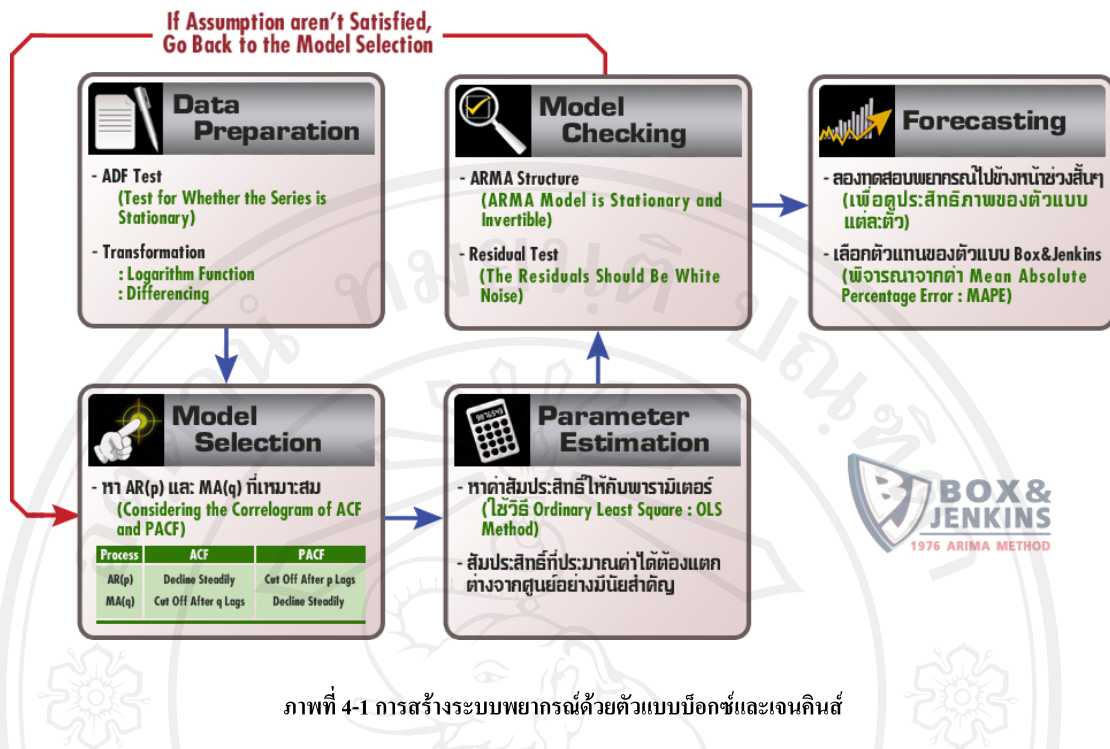
4.2.1.4 การตรวจสอบความถูกต้อง (Model Checking)

ในขั้นตอนนี้จะแบ่งการทดสอบออกเป็น 2 ส่วนคือ หนึ่ง การทดสอบโครงสร้างอาร์มา (ARMA Structure) เพื่อยืนยันว่ากระบวนการอัตถดถอย (Autoregressive : AR) มีคุณสมบัติหยุดนิ่ง (Stationary) รวมทั้งกระบวนการค่าเฉลี่ยเคลื่อนที่ (Moving Average : MA) มีคุณสมบัติผกผัน (Invertible) และสอง การทดสอบส่วนตกค้าง (Residual Test) เพื่อตรวจสอบว่าส่วนตกค้าง (Residual) ที่ได้จากการประมาณค่านั้นมีคุณสมบัติเช่นเดียวกับสัญญาณรบกวนขาว (White Noise) โดยใช้ค่าสถิติคิว (Q-Statistic Test) เพื่อตรวจสอบว่าส่วนตกค้าง (Residual) ไม่มีปัญหาอัตสหสัมพันธ์ (Autocorrelation) นอกจากนี้จะใช้ค่าสถิติฌัก-เบอรา (Jarque-Bera Statistic : JB) ในการตรวจสอบว่าส่วนที่ตกค้าง (Residual) มีการแจกแจงแบบปกติ (Normal Distribution) รวมทั้งตรวจสอบว่าไม่มีปัญหาความแปรปรวนของพจน์คลาดเคลื่อนไม่คงที่ (Heteroscedasticity) โดยใช้การทดสอบอาร์ช-แอลเอ็ม (ARCH-LM Test)

ซึ่งในการทดสอบส่วนตกค้าง (Residual) ตามวิธีการของบ็อกซ์และเจนกินส์ (Box&Jenkins Method) ให้ความสนใจกับคุณสมบัติความเป็นตัวแปรสุ่ม (Random Variable) ของส่วนตกค้าง (Residual) ดังนั้นจึงพิจารณาการทดสอบค่าสถิติคิว (Q-Statistic Test) เป็นสำคัญ กล่าวคือหากทดสอบค่าสถิติคิว (Q-Statistic Test) แล้วไม่มีปัญหาอัตสหสัมพันธ์ (Autocorrelation) แต่เมื่อทดสอบรูปแบบปกติ (Normality Test) และทดสอบอาร์ช-แอลเอ็ม (ARCH-LM Test) แล้วพบว่าส่วนตกค้าง (Residual) ไม่ได้แจกแจงแบบปกติและมีปัญหาความแปรปรวนของพจน์คลาดเคลื่อนไม่คงที่ จะสรุปว่าพจน์คลาดเคลื่อน (Error Term) มีลักษณะใกล้เคียง (Nearly) กับสัญญาณรบกวนขาว (White Noise) และจะนำตัวแบบดังกล่าวไปใช้เพื่อการพยากรณ์ในขั้นต่อไป แต่ถ้าทดสอบค่าสถิติคิว (Q-Statistic Test) แล้วพบว่ามีปัญหาอัตสหสัมพันธ์ ก็จะคัดเลือกตัวแบบนั้น ๆ ทิ้งไป

4.2.1.5 การพยากรณ์ (Forecasting)

เมื่อตรวจสอบความถูกต้องของตัวแบบแล้ว ในขั้นตอนนี้จะเป็นการเลือกตัวแบบที่มีประสิทธิภาพในการพยากรณ์มากที่สุดเพียงตัวแบบเดียว ซึ่งจะใช้การพยากรณ์ล่วงหน้าเพื่อเปรียบเทียบ (Ex-Post Forecasting) โดยทำการพยากรณ์ไปข้างหน้าในระยะสั้น ๆ เป็นจำนวน 10 วัน จากนั้นจึงพิจารณาว่าตัวแบบใดที่ให้ค่าร้อยละสัมบูรณ์ความคลาดเคลื่อนเฉลี่ย (Mean Absolute Percentage Error : MAPE) น้อยที่สุด แล้วจึงกำหนดให้ตัวแบบดังกล่าวเป็นตัวแทนของตัวแบบบ็อกซ์และเจนกินส์ (Box&Jenkins Model) ในการนำไปเปรียบเทียบความแม่นยำกับตัวแบบอื่น ๆ



4.2.2 การสร้างระบบพยากรณ์ด้วยตัวแบบการ์ช (GARCH Model)

การพยากรณ์ด้วยตัวแบบการ์ช (GARCH Model) สมการพยากรณ์จะประกอบด้วย สมการค่าเฉลี่ย (Mean Equation) และสมการความแปรปรวน (Variance Equation) โดยสมการค่าเฉลี่ยจะใช้ตัวแบบบ็อกซ์และเจนคินส์ (Box&Jenkins Model) ที่ได้รับการตรวจสอบความถูกต้องแล้ว ส่วนการสร้างสมการความแปรปรวน จะพิจารณาว่าสมการค่าเฉลี่ย (Mean Equation) นั้น ๆ สามารถอธิบายได้ด้วยความแปรปรวนแบบมีเงื่อนไข (Conditional Variance) ประเภทใด ซึ่งขั้นตอนของการสร้างระบบพยากรณ์ด้วยตัวแบบการ์ช (GARCH Model) มีดังนี้

4.2.2.1 การสร้างสมการค่าเฉลี่ย (Mean Equation)

ขั้นตอนนี้เป็นการเลือกสมการค่าเฉลี่ย^๑ (Mean Equation) ให้กับตัวแบบ โดยพิจารณาจากตัวแบบบ็อกซ์และเจนคินส์ (Box&Jenkins Model) ที่ได้รับการตรวจสอบว่า กระบวนการอัตถดถอย (Autoregressive : AR) มีคุณสมบัติหยุดนิ่ง (Stationary) และกระบวนการค่าเฉลี่ยเคลื่อนที่ (Moving Average : MA) มีคุณสมบัติผกผัน (Invertible) รวมทั้งส่วนตกค้าง (Residual) ที่ประมาณค่ามาได้ ไม่มีปัญหาอัตสหสัมพันธ์ (Autocorrelation)

^๑ สมการค่าเฉลี่ย (Mean Equation) สำหรับการศึกษาในครั้งนี้ สร้างขึ้น โดยอาศัยการลอกแบบ (Simulation) จากความล่าช้า (Lag) ของตัวแบบบ็อกซ์และเจนคินส์ (Box&Jenkins) ที่ผ่านขั้นตอนการตรวจสอบความถูกต้อง (Model Checking) แล้ว

4.2.2.2 การสร้างสมการความแปรปรวน (Variance Equation)

ในขั้นตอนนี้จะเป็นการเลือกความแปรปรวนอย่างมีเงื่อนไข (Conditional Variance) ที่สอดคล้องกับสมการค่าเฉลี่ย (Mean Equation) ซึ่งการศึกษาในครั้งนี้จะกำหนดรูปแบบความแปรปรวนอย่างมีเงื่อนไข (Conditional Variance) 3 พจน์ คือ พจน์อาร์ช (ARCH Term) พจน์การ์ช (GARCH Term) และพจน์อีการ์ช (EGARCH Term) โดยสมการความแปรปรวน (Variance Equation) ที่มีความเหมาะสมจะพิจารณาจากค่าความน่าจะเป็น (Probability-Value : Prob) ของค่าสถิติแซด (Z-Statistic) กล่าวคือค่าความน่าจะเป็น (Probability-Value : Prob) ของค่าสถิติแซด (Z-Statistic) ของพารามิเตอร์ในสมการความแปรปรวน (Variance Equation) ต้องน้อยกว่าระดับนัยสำคัญ (significant : α) ที่กำหนด

นอกจากนี้หากความแปรปรวนอย่างมีเงื่อนไข (Conditional Variance) เป็นกระบวนการอาร์ช (ARCH Process) หรือกระบวนการการ์ช (GARCH Process) สัมประสิทธิ์ (Coefficient) ทุกตัวที่ประมาณค่าได้จะต้องไม่เป็นค่าติดลบ (Non-Negative) หากเป็นกระบวนการอีการ์ช (EGARCH Process) จะผ่อนปรนเงื่อนไขดังกล่าว เนื่องจากพิจารณาความแปรปรวนอย่างมีเงื่อนไข (Conditional Variance) ในรูปของลอการิทึม (Logarithm) ซึ่งการประมาณค่าพารามิเตอร์ของสมการความแปรปรวน (Variance Equation) จะใช้วิธีความควรจะเป็นสูงสุด (Maximum Likelihood Method : ML)

4.2.2.3 การทดสอบคุณสมบัติของส่วนตกค้าง (Residual)

ขั้นตอนนี้จะคล้ายกับการตรวจสอบความถูกต้อง (Model Checking) ของตัวแบบบ็อกซ์และเจนคินส์ (Box&Jenkins Model) โดยทดสอบคุณสมบัติของส่วนตกค้าง (Residual) ว่าใกล้เคียงกับสัญญาณรบกวนขาว (White Noise) โดยใช้ค่าสถิติคิว (Q-Statistic Test) ตรวจสอบปัญหาอัตสหสัมพันธ์ (Autocorrelation) ของส่วนตกค้าง (Residual) ในสมการค่าเฉลี่ย (Mean Equation)

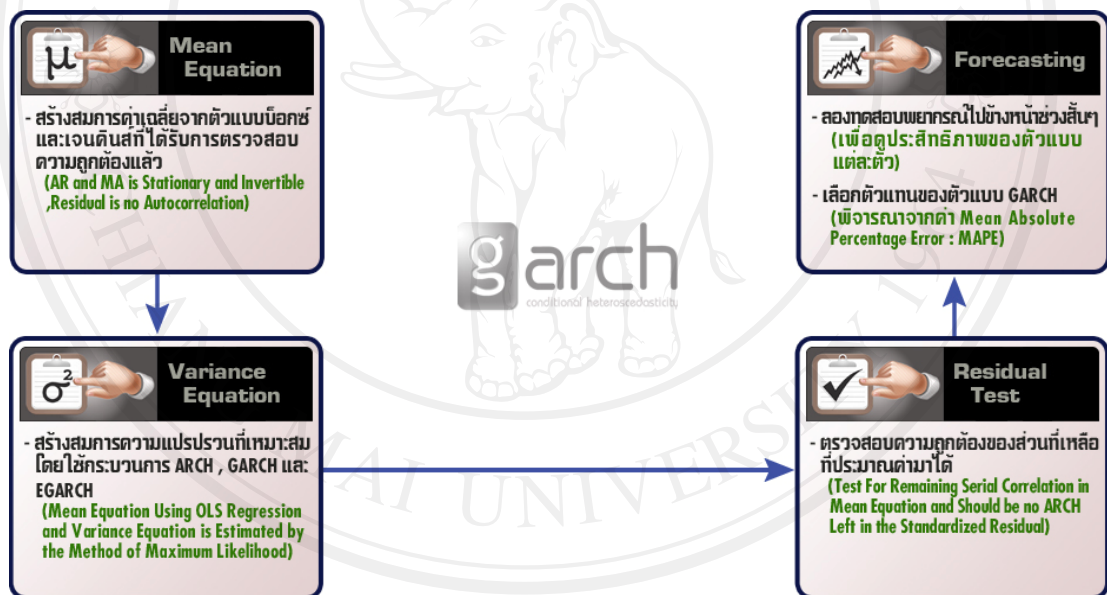
ขณะที่ส่วนตกค้างในรูปคะแนนมาตรฐาน (Standardized Residual) ของสมการความแปรปรวน (Variance Equation) จะใช้การทดสอบอาร์ช-แอลเอ็ม (ARCH-LM Test) ในการตรวจสอบปัญหาความแปรปรวนของพจน์คลาดเคลื่อนไม่คงที่ (Heteroscedasticity) และการทดสอบรูปแบบปกติ (Normality Test) เพื่อพิจารณาว่าตัวแปรดังกล่าวแจกแจงแบบปกติ (Normal Distribution)

ซึ่งการเลือกตัวแบบการ์ช (GARCH Model) สำหรับนำไปสร้างสมการพยากรณ์ จะพิจารณาจากตัวแบบที่ส่วนตกค้าง (Residual) ของสมการค่าเฉลี่ย (Mean Equation) ไม่มีปัญหาอัตสหสัมพันธ์ (Autocorrelation) และส่วนตกค้างในรูปคะแนนมาตรฐาน (Standardized

Residual) ของสมการความแปรปรวน (Variance Equation) ไม่มีปัญหาความแปรปรวนของพจน์คลาดเคลื่อนไม่คงที่ (Heteroscedasticity)

4.2.2.4 การพยากรณ์ (Forecasting)

สำหรับขั้นตอนนี้จะเป็นการหาตัวแทนของตัวแบบการช (GARCH Model) เพื่อนำไปพยากรณ์เปรียบเทียบความแม่นยำกับตัวแบบประเภทอื่น ๆ โดยเลือกตัวแบบการชที่ได้รับ การทดสอบคุณสมบัติของส่วนตกค้าง (Residual) แล้วว่ามีความเหมาะสม มาลองพยากรณ์ไปข้างหน้าช่วงสั้น ๆ เป็นจำนวน 10 วัน โดยตัวแบบที่จะใช้เป็นตัวแทนของตัวแบบการช (GARCH Model) ต้องให้ค่าร้อยละสัมบูรณ์ความคลาดเคลื่อนเฉลี่ย (Mean Absolute Percentage Error : MAPE) น้อยที่สุด



ภาพที่ 4-2 การสร้างระบบพยากรณ์ด้วยตัวแบบการช

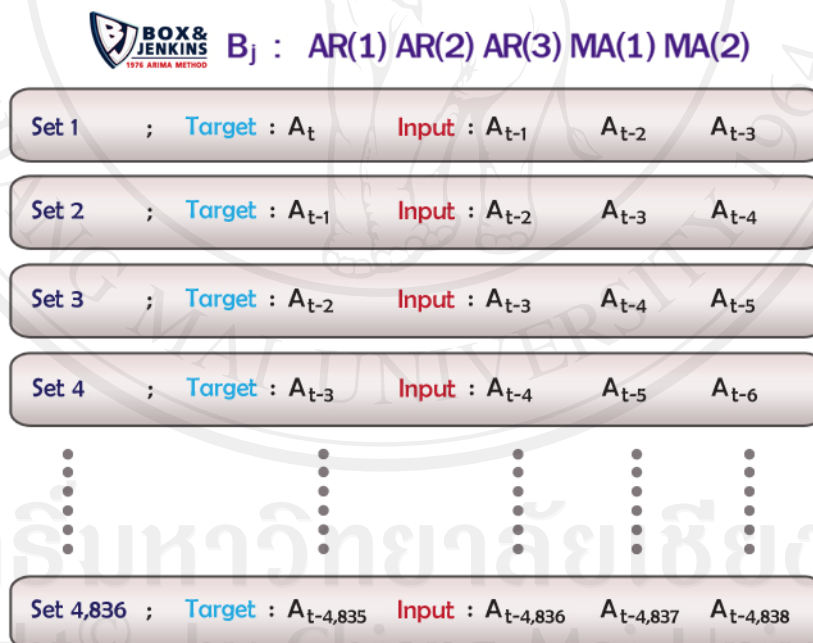
4.2.3 การสร้างระบบพยากรณ์ด้วยตัวแบบโครงข่ายประสาทประดิษฐ์ (ANNs Model)

การพยากรณ์ด้วยตัวแบบโครงข่ายประสาทประดิษฐ์ (ANNs Model) สำหรับการศึกษาคั้งนี้ ประกอบด้วย 5 ขั้นตอน คือ การกำหนดข้อมูลนำเข้า (Input Specification) การออกแบบชั้นซ่อนเร้น (Design Hidden Layer) การสร้างระบบการฝึกสอน (Create Training System) การกำหนดข้อมูลส่งออก (Output Specification) และการพยากรณ์ (Forecasting)

4.2.3.1 การกำหนดข้อมูลนำเข้า (Input Specification)

สำหรับการสร้างชุดการเรียนรู้ (Learning Set) ไม่ได้มีหลักการตายตัว แต่ตัวแปรอิสระหรือข้อมูลนำเข้า (Input) ที่เลือกมาต้องมีความสามารถในการอธิบายค่าเป้าหมาย (Target Response) ได้เป็นอย่างดี ดังนั้นในการสร้างชุดการเรียนรู้^๒ (Learning Set) จะพิจารณาจากความล่าช้า (Lag) ของตัวแบบบ็อกซ์และเจนกินส์ (Box&Jenkins Model) ที่ได้รับการตรวจสอบความถูกต้องแล้ว เนื่องจากความล่าช้า (Lag) ดังกล่าวถูกเลือกมาจากมาตรวัดสหสัมพันธ์ต่างๆ ทั้งฟังก์ชันอัตสหสัมพันธ์ (Autocorrelation Function : ACF) และฟังก์ชันอัตสหสัมพันธ์บางส่วน (Partial Autocorrelation Function : ACF) รวมทั้งมีการทดสอบสมมติฐานทางสถิติแล้วว่าสามารถอธิบายค่าสังเกต (Observation) ได้อย่างมีนัยสำคัญ

^๒ การสร้างชุดการเรียนรู้ (Learning Set) ของตัวแบบโครงข่ายประสาทประดิษฐ์ (ANNs Model) ครั้งนี้อาศัยความล่าช้า (Lag) ของตัวแบบบ็อกซ์และเจนกินส์ (Box&Jenkins Model) ที่ผ่านขั้นตอนการตรวจสอบความถูกต้อง (Model Checking) แล้ว



ภาพที่ 4-3 การสร้างชุดการเรียนรู้โดยอาศัยตัวแบบบ็อกซ์และเจนกินส์

จากภาพที่ 4-3 สมมติว่าตัวแบบ B_j คือตัวแบบบ็อกซ์และเจนกินส์ (Box&Jenkins Model) ที่ได้รับการตรวจสอบแล้ว ซึ่งตัวแบบดังกล่าวสามารถอธิบายได้ด้วยตัวแปรความล่าช้า (Lag Variable) คือ 1 2 และ 3 คาบเวลาซ้อนหลัง ดังนั้นการสร้างชุดการเรียนรู้ (Learning Set) ของตัวแบบโครงข่ายประสาทประดิษฐ์ (ANNs Model) ก็จะใช้ความล่าช้า (Lag) แบบเดียวกัน

โดยชุดการเรียนรู้ที่ 1 เมื่อกำหนดค่าเป้าหมาย (Target Response) เป็น A_t จะได้ข้อมูลนำเข้า (Input) เป็น A_{t-1} A_{t-2} และ A_{t-3} ตามลำดับ สำหรับชุดการเรียนรู้ที่ 2 เมื่อกำหนดค่าเป้าหมาย (Target Response) เป็น A_{t-1} จะได้ข้อมูลนำเข้า (Input) เป็น A_{t-2} A_{t-3} และ A_{t-4} ตามลำดับ ซึ่งการศึกษาครั้งนี้ใช้ข้อมูลทั้งสิ้น 4,838 ค่าสังเกต ดังนั้นหากสร้างชุดการเรียนรู้ (Learning Set) ด้วยตัวแปรความล่าช้า (Lag Variable) เป็น 1 2 และ 3 คาบเวลาซ้อนหลัง จะได้ชุดการเรียนรู้ (Learning Set) ทั้งหมด 4,836 ชุด

4.2.3.2 การออกแบบชั้นซ่อนเร้น (Design Hidden Layer)

การศึกษาครั้งนี้จะกำหนดองค์ประกอบต่าง ๆ ของชั้นซ่อนเร้น (Hidden Layer) ดังนี้คือ ใช้ชั้นซ่อนเร้น (Hidden Layer) เพียงชั้นเดียว โดยการกำหนดจำนวนนิวรอน (Neuron) ในชั้นนี้ จะใช้วิธีสุ่มเลือก (Arbitrary Approach) กล่าวคือค่อยๆ เพิ่มจำนวนนิวรอน (Neuron) โดยแบ่งเป็น 3 ช่วงคือ หนึ่ง เพิ่มทีละ 1 นิวรอน ตั้งแต่ 1 ถึง 10 นิวรอน สอง เพิ่มทีละ 2 นิวรอน ตั้งแต่ 12 ถึง 20 นิวรอน และสาม เพิ่มทีละ 10 นิวรอน ตั้งแต่ 30 ถึง 100 นิวรอน ดังนั้นตัวแบบโครงข่ายใยประสาทประดิษฐ์ (ANNs Model) แต่ละตัวจะประกอบไปด้วย 23 ตัวแบบย่อย (Sub-Model) ขณะที่ฟังก์ชันการแปลงค่า (Transfer Function) ในชั้น (Layer) นี้จะใช้ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ซิกมอยด์ (Hyperbolic Tangent Sigmoid : Tan-Sigmoid Function) สำหรับการส่งข้อมูลไปยังชั้นต่อ ๆ ไป

4.2.3.3 การสร้างระบบการฝึกสอน (Create Training System)

ระบบการฝึกสอน (Create Training System) จะใช้การส่งข้อมูลไปข้างหน้าเพียงอย่างเดียวแบบหลายชั้น (Multilayer Feed Forward) สำหรับการเชื่อมโยงองค์ประกอบของแต่ละชั้น (Layer) เข้าด้วยกัน โดยใช้ควบคู่กับการเรียนรู้แบบมีผู้สอน (Supervised Learning) ซึ่งจะกำหนดวิธีแพร่ย้อนกลับแบบแอลเอเอ็ม (LM Backpropagation) เป็นฟังก์ชันการฝึกสอน (Training Function) เนื่องจากสามารถปรับค่าน้ำหนัก (Weight) ให้ลู่อเข้าสู่เป้าหมายได้เร็วที่สุดและผิดพลาดน้อยที่สุด โดยการหยุดการฝึกสอนในชุดการเรียนรู้ (Learning Set) ใด ๆ จะเกิดขึ้นเมื่อโครงข่าย (Networks) สามารถปรับแก้ค่าน้ำหนักจนได้ความคลาดเคลื่อนในระดับที่ยอมรับได้ หรือยังไม่สามารถปรับค่าน้ำหนักจนถึงระดับที่ยอมรับได้ แต่ชุดการเรียนรู้ (Learning Set) นั้น ๆ ได้รับการฝึกสอน (Training) จนครบวงจรการเรียนรู้ (Epochs) ที่กำหนด ซึ่งการศึกษาในครั้งนี้จะกำหนดการฝึกสอนไว้ที่ 500 วงจรการเรียนรู้ (Epochs)

4.2.3.4 การกำหนดข้อมูลส่งออก (Output Specification)

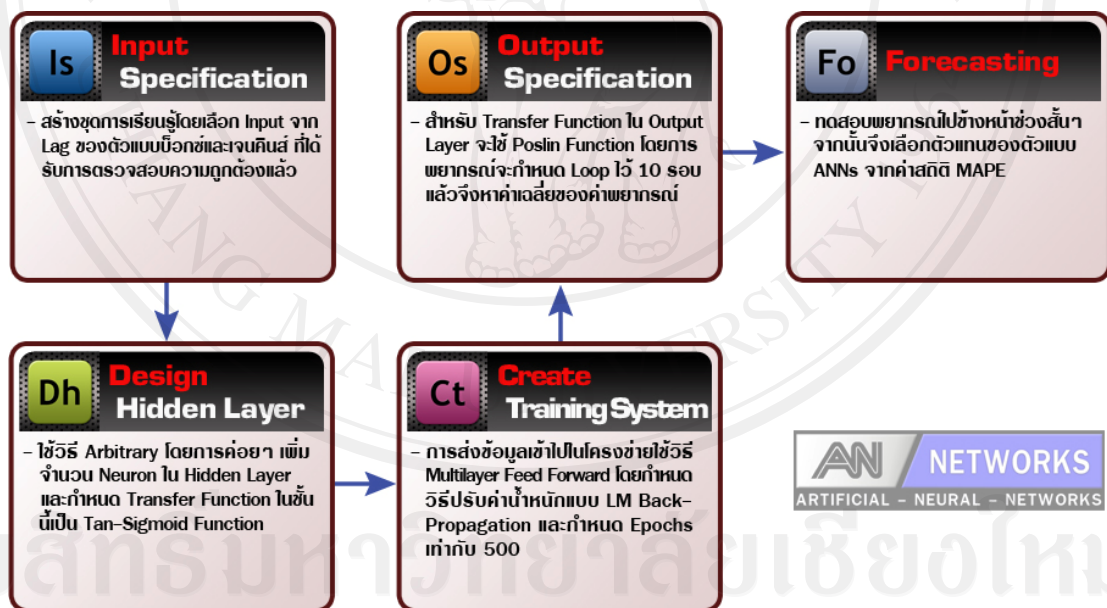
สำหรับฟังก์ชันการแปลงค่า (Transfer Function) ในชั้นข้อมูลส่งออกเลือกใช้ฟังก์ชันโพสลิน (Positive Linear Transfer Function : Poslin Function) เนื่องจากให้ค่าพยากรณ์เป็นจำนวนเต็มบวก (Positive) เท่านั้น อย่างไรก็ตามค่าพยากรณ์ของตัวแบบโครงข่ายใยประสาทประดิษฐ์ (ANNs Model) เป็นอัลกอริทึมเฟ้นสุ่ม^๓ (Stochastic Algorithm) ดังนั้นเพื่อให้ค่า

^๓ อัลกอริทึมเฟ้นสุ่ม (Stochastic Algorithm) เป็นลักษณะการให้คำตอบของตัวแบบประเภทปัญญาประดิษฐ์ (Artificial Intelligence : AI) หรือการเรียนรู้เครื่องกล (Machine Learning) โดยตัวแบบไม่สามารถให้คำตอบที่เหมือนเดิมได้ เมื่อทำการทดลองซ้ำอีกครั้ง แม้ว่าโครงสร้างของโครงข่าย (Networks) จะมีลักษณะคงเดิม เนื่องจากระบบปัญญา (Intelligence) ไม่ได้มีสูตรการคำนวณตายตัว หากแต่สร้างขึ้นมาจากการเรียนรู้ (Learning) หรือการปรับแก้ค่าน้ำหนัก (Weight)

พยากรณ์มีความน่าเชื่อถือ ในขั้นตอนนี้จึงกำหนดวงวนการพยากรณ์ (Prediction Loop) ไว้ 10 รอบ หากการพยากรณ์ในวงรอบใดเกิดลักษณะของค่านอกกลุ่ม (Outlier) จะทำการแก้ปัญหาโดยใช้วิธีกำจัดค่านอกกลุ่ม (Eliminated Outlier) กล่าวคือตัดค่าพยากรณ์ในรอบนั้น ๆ ทิ้งไปทั้งคอลัมน์ (Delete Column)

4.2.3.5 การพยากรณ์ (Forecasting)

สำหรับขั้นตอนนี้จะเป็นการหาตัวแทนของตัวแบบโครงข่ายประสาทประดิษฐ์ (ANNs Model) เพื่อนำไปพยากรณ์เปรียบเทียบความแม่นยำกับตัวแบบอื่น ๆ โดยทุกโครงสร้างของตัวแบบโครงข่ายประสาทประดิษฐ์ (ANNs Model) สามารถนำไปพยากรณ์ได้ ซึ่งการเลือกตัวแทนของตัวแบบโครงข่ายประสาทประดิษฐ์ (ANNs Model) จะทำการทดลองพยากรณ์ไปข้างหน้าช่วงสั้น ๆ เป็นจำนวน 10 วัน โดยเลือกตัวแบบที่ให้ค่าร้อยละสัมบูรณ์ความคลาดเคลื่อนเฉลี่ย (Mean Absolute Percentage Error : MAPE) น้อยที่สุด

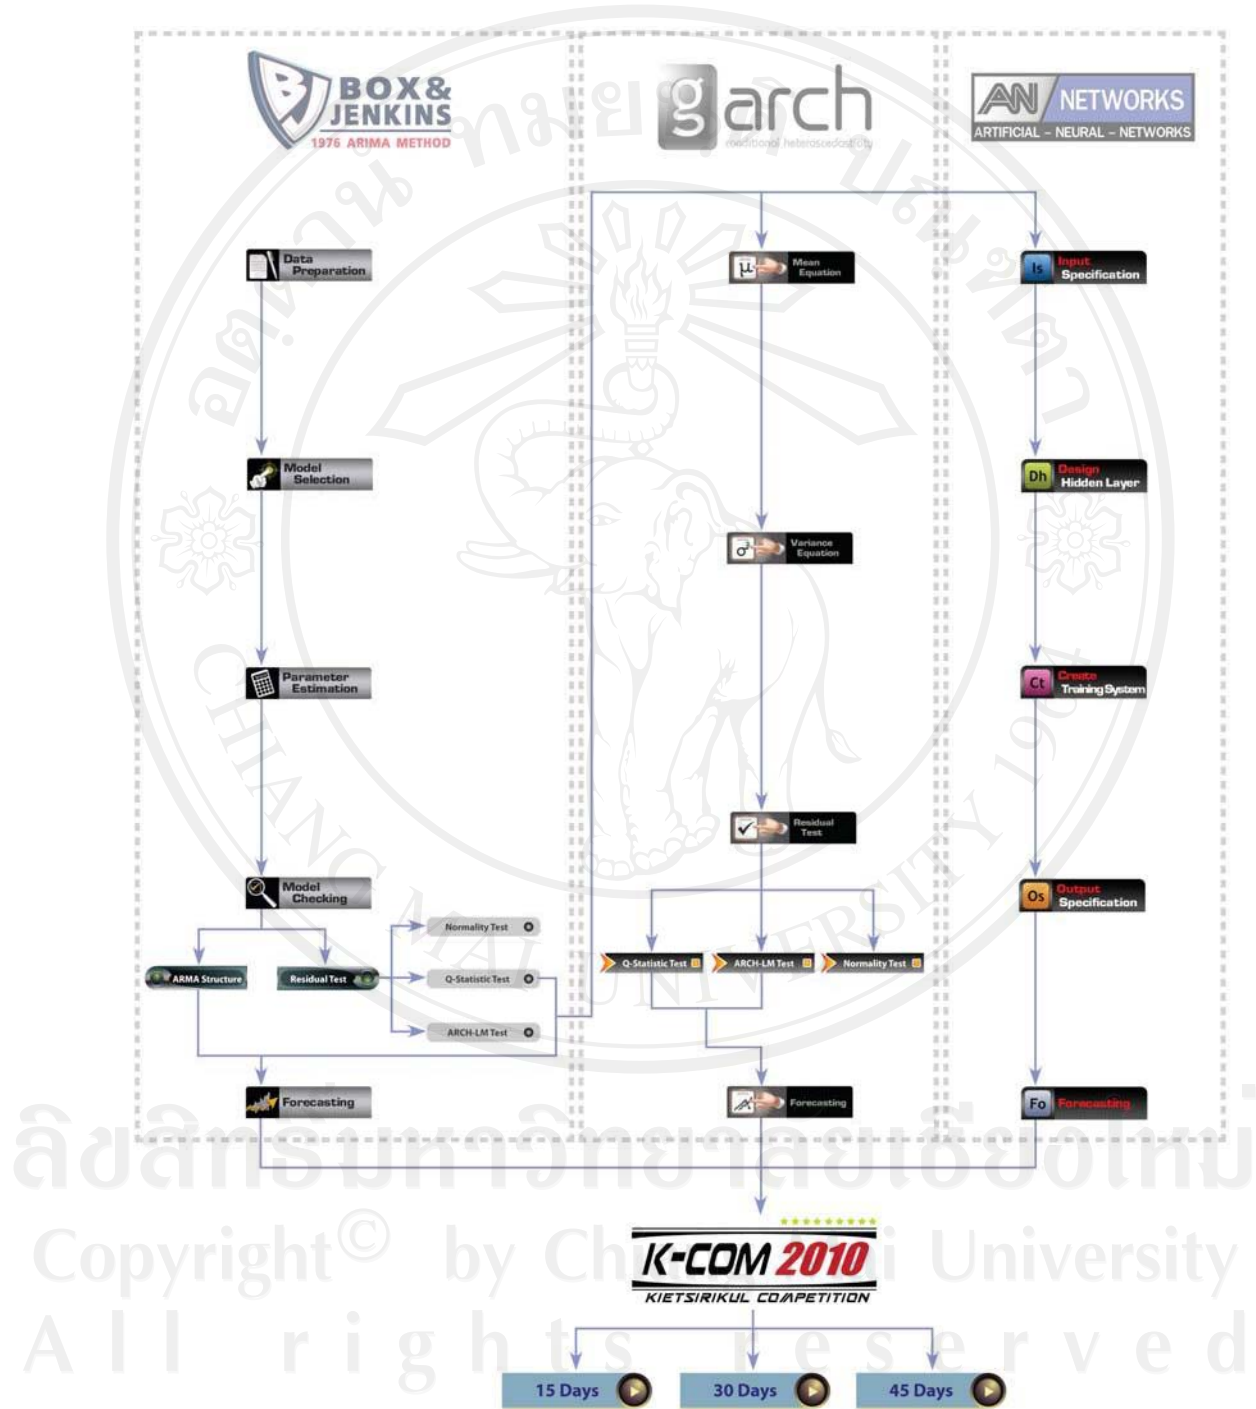


ภาพที่ 4-4 การสร้างระบบพยากรณ์ด้วยตัวแบบโครงข่ายประสาทประดิษฐ์

4.3 การทดสอบความแม่นยำในการพยากรณ์ของตัวแบบแต่ละประเภท

ในการค้นคว้าแบบอิสระ (Independent Study) ครั้งนี้จะเปรียบเทียบความแม่นยำในการพยากรณ์ของตัวแบบต่าง ๆ โดยแบ่งเป็น 3 ระยะคือ ระยะ 15 วัน ระยะ 30 วัน ระยะ 45 วัน ซึ่งการพยากรณ์ไปข้างหน้าทีละวัน จะใช้ค่าพยากรณ์ที่ได้มาใช้เป็นข้อมูลสำหรับการพยากรณ์ในวันถัดไป โดยที่การตัดสินใจว่าตัวแบบประเภทใดสามารถให้ค่าพยากรณ์ที่มีความแม่นยำมากที่สุดจะพิจารณา


จากค่าร้อยละสัมบูรณ์ความคลาดเคลื่อนเฉลี่ย (Mean Absolute Percentage Error : MAPE) ซึ่งความเชื่อมโยงของการสร้างระบบพยากรณ์ด้วยตัวแบบทั้งสามนั้น แสดงดังภาพที่ 4-5



ภาพที่ 4-5 ความเชื่อมโยงของการสร้างระบบพยากรณ์ด้วยตัวแบบทั้งสามประเภท

4.4 ซอฟต์แวร์ที่ใช้สำหรับคำนวณระบบพยากรณ์ของตัวแบบแต่ละประเภท

สำหรับการพยากรณ์ด้วยตัวแบบบ็อกซ์และเจนคินส์ (Box&Jenkins Model) และการพยากรณ์ด้วยตัวแบบการزش (GARCH Model) จะประมาณค่าสัมประสิทธิ์ (Coefficient) ของพารามิเตอร์ และทดสอบค่าสถิติต่าง ๆ ด้วยซอฟต์แวร์ Eviews 7.1 ขณะที่การพยากรณ์ด้วยตัวแบบโครงข่ายประสาทประดิษฐ์ (ANNs Model) จะคำนวณด้วยการเขียนคำสั่งและใส่รหัสต้นทาง (Source Code) ลงในซอฟต์แวร์ MATLAB 7.0.1



ลิขสิทธิ์มหาวิทยาลัยเชียงใหม่
Copyright© by Chiang Mai University
All rights reserved