

บทที่ 14 การลงทุนเชิงปริมาณและการบริหารพอร์ตสมัยใหม่

วัตถุประสงค์การเรียนรู้

เมื่อศึกษาบทนี้แล้ว ผู้อ่านควรสามารถ

1. อธิบายระบบลงทุนเชิงปริมาณตั้งแต่ข้อมูล สัญญาณ พอร์ต การส่งคำสั่ง การประเมินผล และการกำกับแบบจำลอง
2. สร้าง factor/alpha score ด้วย winsorization, z-score, ranking, neutralization, volatility scaling และ liquidity gating
3. เชื่อม Value, Momentum, Size, Quality และ Low-Volatility กับ factor models และ Smart Beta โดยแยกให้ชัดเจนระหว่างปัจจัยที่ใช้เพื่ออธิบายผลตอบแทนกับสัญญาณที่ใช้สร้างพอร์ต
4. ประเมิน predictive content ด้วย IC/Rank IC และแปลง signal เป็นน้ำหนักภายใต้ risk, turnover, liquidity และ cost constraints
5. ออกแบบ backtest ที่ควบคุม look-ahead, survivorship, leakage, execution bias, data snooping และ multiple testing
6. ใช้ walk-forward, purged validation, bootstrap, sensitivity และ regime analysis เพื่อตรวจสอบ robustness
7. รวม alpha หลายตัวเป็น portfolio of alphas โดยพิจารณาผลตอบแทน ความเสี่ยง correlation turnover และ capacity พร้อมกัน
8. อธิบาย prediction-to-portfolio gap ของ Machine Learning และข้อจำกัดของ Deep Learning, NLP/LLM, alternative data และ reinforcement learning
9. สร้างระบบวิจัยที่ทำซ้ำได้ด้วย experiment registry, model card, audit trail, drift monitoring และ human oversight
10. สังเคราะห์บทที่ 1-13 เป็นวงจรการลงทุนเชิงปริมาณที่ตรวจสอบได้

ข้อสังเกต

แกนของบท

Data → Signal → Portfolio → Execution
→ Validation → Governance → Learning

Backtest เป็นเพียงส่วนหนึ่งของระบบ คุณภาพของกลยุทธ์ขึ้นกับความถูกต้องของทุกกลุ่กรในวงจร

14.1 จากการเลือกหลักทรัพย์สู่การออกแบบระบบตัดสินใจ

การลงทุนเชิงปริมาณควรถูกมองเป็น ระบบตัดสินใจภายใต้ข้อจำกัด มากกว่าการค้นหาสูตรพยากรณ์เพียงตัวเดียว เพราะผลตอบแทนที่เกิดขึ้นจริงขึ้นกับทั้งข้อมูลที่มีอยู่ ณ เวลาตัดสินใจ วิธีแปลงข้อมูลเป็นสัญญาณ การกำหนดน้ำหนัก ความเสี่ยง ต้นทุน และราคาซื้อขายได้จริง

ให้ J_t เป็น information set ที่เข้าถึงได้จริง ณ เวลา t และ $X_t \subseteq J_t$ เป็นข้อมูลที่ระบบอนุญาตให้ใช้กำหนด

$$s_t = f(X_t; \theta_t) \quad (14.1)$$


$$w_t^{\text{tar}} = g(s_t, \hat{\Sigma}_t, \hat{c}_t; \lambda_t) \quad (14.2)$$

เมื่อ s_t คือ signal vector, w_t^{tar} คือน้ำหนักเป้าหมาย, $\hat{\Sigma}_t$ คือ risk estimate และ $\hat{c}_t$ คือข้อมูลต้นทุนกับสภาพคล่องที่คาดหวัง ณ เวลาเดียวกัน การแยก w_t^{tar} ออกจากน้ำหนักที่ถือจริงมีความสำคัญ เพราะข้อจำกัด lot size, partial fill, market impact และราคาเคลื่อนไหวระหว่างส่งคำสั่งอาจทำให้พอร์ตหลังซื้อขายต่างจากเป้าหมาย

ระบบสมบูรณ์จึงเป็น

$J_t \rightarrow X_t \rightarrow s_t \rightarrow w_t^{\text{tar}} \rightarrow q_t \rightarrow w_t^{\text{real}} \rightarrow R_{t+1}^{\text{net}} \rightarrow \text{Validation} \rightarrow \text{Governance}$

โดย q_t คือ trade vector และ w_t^{real} คือน้ำหนักที่เกิดขึ้นหลัง execution ดังนั้นความผิดพลาดระหว่าง target กับ realized holdings เป็นส่วนหนึ่งของ implementation risk ไม่ใช่ noise ที่ควรถูกละเลย



รูปที่ 14.1: ระบบลงทุนเชิงปริมาณเชื่อมข้อมูล point-in-time ไปสู่ผลตอบแทนสุทธิและส่งผลการตรวจสอบกลับเข้าสู่วงจรวิจัย

ข้อสังเกต

คำว่า *alpha signal* ในงานเชิงปริมาณหมายถึงตัวแปรก่อนลงทุนที่คาดว่าจะมี predictive content ส่วน Jensen's alpha เป็น abnormal performance ที่วัดภายหลังภายใต้แบบจำลองอ้างอิง การมี alpha signal จึงไม่รับประกัน ex-post alpha และ signal ที่พยากรณ์ได้ก็อาจยังสร้างพอร์ตที่ไม่ดีเมื่อรวมความเสี่ยงและต้นทุน

14.2 Point-in-Time Data และ Decision Clock

ข้อมูลใน backtest ต้องเป็นข้อมูลที่ผู้ลงทุนสามารถเห็นได้จริง ณ เวลาตัดสินใจ ไม่ใช่ข้อมูลที่แก้ไขย้อนหลังแล้ว

$$\tau^{\text{avail}} \leq \tau^{\text{signal}} \leq \tau^{\text{order}} \leq \tau^{\text{fill}} < \tau^{\text{return}}$$

ประเด็นที่ต้องระวัง

หากใช้ราคาปิดวัน t สร้าง signal แล้วสมมติซื้อได้ที่ราคาปิดเดียวกันโดยไม่มี execution mechanism รองรับ จะเกิด look-ahead หรือ execution bias แม้สูตร signal จะไม่ใช่ข้อมูลอนาคต

ข้อมูลพื้นฐานควรเก็บอย่างน้อย period end, announcement date, effective date และ revision vintage เพราะค่าของตัวแปรเดียวกันอาจถูกแก้ไขย้อนหลัง การใช้ค่าฉบับล่าสุดกับอดีตทำให้โมเดลเห็นข้อมูลที่นักลงทุนในอดีตยังไม่ทราบ ส่วน universe ต้องใช้ historical constituents รวมหลักทรัพย์ที่ delist หรือออกจากดัชนีตามเวลาจริงเพื่อหลีกเลี่ยง survivorship bias

ในเชิงข้อมูล เงื่อนไข $\tau^{\text{avail}} \leq \tau^{\text{signal}}$ ต้องตรวจที่ระดับ observation ไม่ใช่ตรวจเพียงชื่อคอลัมน์ ตัวอย่างเช่น งบสิ้นไตรมาสไม่ได้แปลว่าตลาดรู้ข้อมูล ณ วันสิ้นไตรมาส แต่ต้องรอวันประกาศจริงและเผื่อ processing lag ตามกฎที่กำหนดไว้ล่วงหน้า

Point-in-Time Data Governance

ทุก feature ควรมี data lineage ระบุ source, frequency, timezone, publication lag, adjustment, missing-value rule, corporate-action rule, universe rule, transform version และ snapshot date

14.3 Signal Engineering

14.3.1 Winsorization และ Standardization

สำหรับ cross-sectional feature $x_{i,t}$ อาจลดอิทธิพลของ outlier ด้วย winsorization ที่ quantiles $q_{\ell,t}$ และ $q_{u,t}$

$$x_{i,t}^W = \min\{q_{u,t}, \max(q_{\ell,t}, x_{i,t})\}$$

จากนั้นจึง standardize ภายใน cross-section เดียวกัน

$$z_{i,t} = \frac{x_{i,t}^W - \bar{x}_t^W}{s_{x^W,t}}, \quad s_{x^W,t} > 0$$

หาก cross-section กระจายผิดปกติอย่างรุนแรง อาจใช้ median และ MAD แทน mean และ standard deviation แต่ต้องกำหนด convention ให้คงที่ตลอดการทดลอง

rank score ที่ map ลงช่วง $[-1, 1]$ คือ

$$r_{i,t} = 2 \frac{\text{rank}(x_{i,t}) - 1}{N_t - 1} - 1, \quad N_t > 1$$

Rank ลดอิทธิพลของ outlier และ ไม่สนใจระยะห่างระหว่างค่ามากนัก ขณะที่ z-score รักษาข้อมูลเชิงสเกลมากกว่า การเลือกวิธีจึงต้องสอดคล้องกับ ความหมายทางเศรษฐศาสตร์ของ feature และ ควร fit กฎ winsorization/normalization ภายใน training information เท่านั้นเมื่อตัวแปรมิพารามิเตอร์ที่เรียนรู้จากเวลา

14.3.2 Composite Signal

เมื่อมี normalized features $z_{ik,t}$ จำนวน K ตัว

$$s_{i,t} = \sum_{k=1}^K a_k z_{ik,t}, \quad \sum_{k=1}^K |a_k| = 1$$

น้ำหนัก a_k อาจมาจาก economic prior, equal weighting หรือแบบจำลองเชิงสถิติ แต่ต้องประมาณจาก training information เท่านั้น เงื่อนไข $\sum_k |a_k| = 1$ เป็นเพียง normalization เพื่อให้สเกลตีความง่าย ไม่ใช่ข้อกำหนดทางทฤษฎี

หาก features หลายตัวสะท้อนแนวคิดเศรษฐศาสตร์เดียวกันและมีสหสัมพันธ์สูง การให้น้ำหนักเท่ากันอาจนับข้อมูลซ้ำ การสร้าง composite signal จึงควรตรวจ feature correlation, incremental IC และ ablation test

เพื่อดูว่าการเพิ่ม feature ใหม่ให้ข้อมูลส่วนเพิ่มจริงหรือเพียงเพิ่มความซับซ้อน

14.3.3 Neutralization เป็น Orthogonal Projection

ให้ $X \in \mathbb{R}^{N \times p}$ เป็น exposures ที่ต้องการกำจัดออกจาก signal s เช่น sector dummies, beta หรือ size และเขียน

$$s = X\beta + u$$

ถ้า X มี full column rank เมทริกซ์ residual maker คือ

$$M = I - X(X^T X)^{-1} X^T, \quad s_{\perp} = Ms$$

ส่วนกรณีทั่วไปสามารถเขียนอย่างปลอดภัยด้วย Moore–Penrose pseudoinverse เป็น

$$s_{\perp} = (I - XX^+)s$$

Orthogonality of Neutralized Signal. ในกรณี full column rank

$$X^T s_{\perp} = X^T [I - X(X^T X)^{-1} X^T] s = 0$$

ดังนั้น residualized signal ตั้งฉากกับ column space ของ X ในเชิงตัวอย่าง □

หากต้องการให้หุ้นที่มีสภาพคล่องหรือมูลค่าตลาดต่างกันมีน้ำหนักในการ fit ไม่เท่ากัน สามารถใช้ weighted least squares ซึ่งให้เงื่อนไข $X^T W u = 0$ แทน $X^T u = 0$ ในงานคำนวณควรใช้ least squares, QR หรือ SVD แทนการสร้าง inverse โดยตรง โดยเฉพาะเมื่อ exposure matrix ใกล้ singular

ประเด็นที่ต้องระวัง

Neutralization กำจัด exposure ที่กำหนดไว้ ไม่ได้กำจัด “ความเสี่ยงทั้งหมด” และอาจลด predictive content หาก exposure ที่กำจัดเป็นส่วนหนึ่งของแหล่งผลตอบแทนที่ตั้งใจถือ จึงต้องแยกระหว่าง unwanted exposure กับ intended factor bet ให้ชัด

14.3.4 Volatility Scaling และ Liquidity Gating

เพื่อไม่ให้สินทรัพย์ที่มี volatility estimate ใกล้ศูนย์ได้สเกลสูงผิดปกติ ควรใช้ volatility floor

$$\tilde{s}_{i,t} = \frac{s_{i,t}}{\max(\hat{\sigma}_{i,t}, \sigma_{\min})}, \quad \sigma_{\min} > 0$$

จากนั้นจึงใช้ liquidity gate

$$s_{i,t}^* = g_{i,t} \tilde{s}_{i,t}, \quad 0 \leq g_{i,t} \leq 1$$

โดย $g_{i,t}$ อาจขึ้นกับ ADV, bid-ask spread, volume, days-to-liquidate หรือ liquidity regime และอาจเป็น hard gate (0/1) หรือ soft gate ในช่วง $[0, 1]$

Volatility scaling เป็นการปรับสเกลของ signal ไม่ใช้การพิสูจน์ว่าพอร์ตมีความเสี่ยงเหมาะสมแล้ว เพราะ covariance ระหว่างสินทรัพย์ concentration และ factor exposure ยังต้องถูกควบคุมในชั้น portfolio construction

14.4 Factor Signals

Factor signal ควรเริ่มจากนิยามตัวแปรที่มีความหมายทางเศรษฐศาสตร์และสามารถสร้างแบบ point-in-time ได้ ตัวอย่าง Value ที่ใช้ได้โดยตรงคือ earnings yield

$$VAL_{i,t} = \frac{E_{i,t}^{TTM}}{P_{i,t}}$$

หรือ book-to-market ทั้งนี้ P/E ไม่เหมาะเป็นตัวอย่างที่น่าไป log โดยไม่ตรวจ เพราะเมื่อกำไรเป็นศูนย์หรือติดลบ P/E อาจไม่กำหนดหรือมีพฤติกรรมไม่ต่อเนื่อง การใช้ earnings yield ช่วยให้ negative earnings ยังมีความหมายเชิงอันดับได้ แต่ควร winsorize และแยก sector ตามสมควร

Momentum แบบมีช่วงเวลาน้ำสุดท้าย $K - 1$ จวดเขียนได้เป็น

$$MOM_{i,t}^{(J,K)} = \prod_{j=K}^J (1 + R_{i,t-j}) - 1, \quad J \geq K \geq 1$$

สูตรนี้ครอบคลุมทั้ง momentum ที่รวมจวดน้ำสุดท้ายและรูปแบบที่เว้นช่วงสั้นเพื่อลด microstructure/reversal effect โดยผลตอบแทนที่ใช้ต้องเป็น total return ที่ปรับ corporate actions อย่างสอดคล้อง

Size score อาจกำหนดเป็น

$$SIZE_{i,t} = -\log(ME_{i,t}), \quad ME_{i,t} > 0$$

และ Low-volatility score เป็น

$$LOWVOL_{i,t} = -\hat{\sigma}_{i,t}$$

Quality อาจใช้ profitability, ROE, margin, accrual quality หรือ balance-sheet strength หลังควบคุม

publication lag, accounting comparability, leverage และ sector effects แนวคิดเหล่านี้มีรากฐานในวรรณกรรม factor investing แต่การมีผลตอบแทนส่วนเกินในอดีตไม่ใช่หลักประกันว่า premium จะคงอยู่ในอนาคต [20, 26, 37, 2]

ตารางที่ 14.1: ตัวอย่าง factor signals และจุดที่ต้องตรวจสอบก่อนนำไปสร้างพอร์ต

Signal	Proxy ตัวอย่าง	ประเด็นที่ต้องควบคุม
Value	E/P , book-to-market	negative earnings, sector mix, stale fundamentals
Momentum	cumulative total return	corporate actions, skip period, turnover, crash risk
Size	$-\log(ME)$	liquidity, investability, micro-cap effect
Quality	profitability/ROE/accrual	leverage, accounting definition, publication lag
Low Volatility	$-\hat{\sigma}$	beta/sector exposure, volatility regime, crowding

ข้อสังเกต

Factor Model กับ Factor Strategy

Factor model ใช้อธิบายหรือกำหนดราคาผลตอบแทน ส่วน factor strategy ใช้ characteristics หรือ estimated exposures เพื่อสร้างกฎการลงทุน ทั้งสองเกี่ยวข้องกันแต่ไม่ใช่สิ่งเดียวกัน และ factor strategy อาจมี exposure ต่อหลายปัจจัยโดยไม่ตั้งใจหากไม่มี neutralization หรือ risk control

14.5 Technical Signals ในฐานะ Filter Design

Technical indicator สามารถมองเป็นตัวกรองเชิงเวลาที่แปลงลำดับราคาให้เป็น state หรือ signal แต่ตัว indicator เองยังไม่ใช่กลยุทธ์ จนกว่าจะกำหนด entry, exit, sizing, execution และต้นทุนอย่างครบถ้วน

SMA ระยะ n

$$SMA_t(n) = \frac{1}{n} \sum_{j=0}^{n-1} P_{t-j}$$

ส่วน EMA กำหนดแบบ recursive

$$EMA_t(n) = \alpha_n P_t + (1 - \alpha_n) EMA_{t-1}(n), \quad \alpha_n = \frac{2}{n+1}$$

โดยต้องกำหนด initialization rule เพราะค่าเริ่มต้นมีผลในช่วง warm-up

เพื่อหลีกเลี่ยงความกำกวมของสัญกรณ์ ให้ $\mathcal{E}_n[x]_t$ หมายถึง EMA ระยะ n ของอนุกรม x แล้ว

$$DEMA_t(n) = 2\mathcal{E}_n[P]_t - \mathcal{E}_n[\mathcal{E}_n[P]]_t \quad (14.3)$$

$$TEMA_t(n) = 3\mathcal{E}_n[P]_t - 3\mathcal{E}_n[\mathcal{E}_n[P]]_t + \mathcal{E}_n[\mathcal{E}_n[\mathcal{E}_n[P]]]_t \quad (14.4)$$

Bollinger Bands ใช้เส้นกึ่งกลาง M_t และส่วนเบี่ยงเบนมาตรฐานย้อนหลัง $s_t^{(n)}$

$$U_t = M_t + ks_t^{(n)}, \quad L_t = M_t - ks_t^{(n)}$$

จึงเป็น volatility-normalized envelope รอบเส้นกึ่งกลางภายใต้ convention ที่กำหนด อย่างไรก็ตาม ภัยที่การแตะ band ไม่ได้มีความหมายเชิงซื้อหรือขายโดยอัตโนมัติ เพราะ breakout กับ mean-reversion ใช้ band เดียวกัน แต่ตีความตรงกันข้ามได้

MACD ใช้ความต่างของ EMA สองช่วง

$$MACD_t = EMA_t(n_s) - EMA_t(n_\ell), \quad n_s < n_\ell$$

และอาจกำหนด signal line เป็น EMA ของ $MACD_t$ อีกชั้นหนึ่ง การเปรียบเทียบ technical signals ต้องใช้ warm-up period, corporate-action adjustment, decision clock และ execution convention เดียวกัน

จากงานวิจัยสู่การประยุกต์: กรณีศึกษา Robust Backtesting

กรณีศึกษาจากงานวิจัย SET50 ใช้ข้อมูลรายวันช่วงมกราคม 2018–ธันวาคม 2022 แบ่ง 2018–2021 เป็นช่วงพัฒนาและปี 2022 เป็น out-of-sample เปรียบเทียบ SMA, EMA, DEMA, TEMA และ WMA ใช้ next-day-open execution และรวม commission 0.15% กับ slippage 0.05% ตามการออกแบบของงานต้นทาง พร้อม bootstrap, FDR, parameter sensitivity, cost sensitivity และ rolling stability [69]

สาระที่นำมาใช้ในตำราคือ กระบวนการ robust backtesting ไม่ใช่การนำผู้ชนะในข้อมูลประวัติศาสตร์มาเป็นคำแนะนำลงทุนปัจจุบัน

14.6 Predictive Content: IC และ Rank IC

ให้ $s_{i,t}$ เป็น score ที่ทราบ ณ เวลา t และ $R_{i,t \rightarrow t+h}$ เป็น forward return ใน horizon h ที่เริ่มหลังเวลาที่ สามารถซื้อขายได้ กำหนด cross-sectional Information Coefficient

$$IC_t = \text{Corr}_i(s_{i,t}, R_{i,t \rightarrow t+h})$$

Rank IC ใช้ Spearman correlation ระหว่าง rank ของ signal กับ rank ของ forward return จึงทนต่อ outlier และ monotonic nonlinearity มากกว่า Pearson IC

เพื่อดูความเสถียรตามเวลา อาจรายงาน

$$\overline{IC} = \frac{1}{T} \sum_{t=1}^T IC_t, \quad ICIR = \frac{\overline{IC}}{s(IC_t)}$$

แต่ $ICIR$ ไม่ควรถูก annualize แบบปกติเมื่อ IC_t มี serial dependence หรือ forward-return windows ซ้อนทับกัน การประเมิน uncertainty ควรใช้ HAC หรือ block bootstrap ที่รักษาโครงสร้างเวลาตามสมควร

ประเด็นที่ต้องระวัง

IC เฉลี่ยเป็น บวก ไม่ได้ รับ ประกัน กำไร หลัง ต้นทุน เพราะ signal-to-weight mapping อาจสร้าง concentration, factor exposure, turnover และ market impact นอกจากนี้ IC ที่เกิดจากไม่กี่วัน หรือไม่กี่กลุ่มอุตสาหกรรมอาจไม่เสถียรเมื่อ regime เปลี่ยน จึงควรดู breadth, dispersion, hit rate และ stability ร่วมกัน

14.7 จาก Signal สู่ Portfolio

ตัวอย่าง long-short score mapping แบบง่ายคือ

$$w_{i,t} = \frac{s_{i,t}^* - \bar{s}_t^*}{\sum_j |s_{j,t}^* - \bar{s}_t^*|}$$

เมื่อ denominator เป็นบวก สูตรนี้ให้ $\sum_i w_{i,t} = 0$ และ $\sum_i |w_{i,t}| = 1$ ภายใต้การหาค่าเฉลี่ยแบบเดียวกัน จึงเป็น dollar-neutral gross-normalized mapping แต่ไม่ใช่คำตอบที่เหมาะสมที่สุดเมื่อสินทรัพย์มี covariance, liquidity หรือข้อจำกัดแตกต่างกัน และถ้า scores ทุกตัวเท่ากันจะไม่สามารถใช้ normalization นี้ได้

ก่อน rebalance ให้น้ำหนักเดิม drift ตามผลตอบแทนจนเป็น w_{t-1}^+ ตัวอย่างในกรณีไม่มี external cash

flow

$$w_{i,t-1}^+ = \frac{w_{i,t-1}(1 + R_{i,t})}{1 + R_{p,t}}$$

จึงควรคำนวณ trade จาก $w_t - w_{t-1}^+$ ไม่ใช่จากน้ำหนักเดิมก่อนตลาดเคลื่อนไหว

การนำไปใช้จริงสามารถแก้ปัญหา

$$\max_w \left\{ \hat{\mu}_t^\top w - \frac{\lambda}{2} w^\top \hat{\Sigma}_t w - \eta \|w - w_{t-1}^+\|_1 \right\}$$

ภายใต้ leverage, position, factor, sector, liquidity, turnover และ concentration limits โดย η ต้องอยู่ในหน่วยที่สอดคล้องกับผลตอบแทนใน objective และหากมี nonlinear impact ควรใช้ cost function ที่สอดคล้องกับขนาดคำสั่งแทน L_1 penalty เพียงอย่างเดียว

สำหรับ fully-invested self-financing long-only portfolio นิยาม one-way turnover ที่ใช้บ่อยคือ

$$TO_t = \frac{1}{2} \sum_i |w_{i,t} - w_{i,t-1}^+|$$

แต่ใน long-short portfolio ที่ gross exposure เปลี่ยนได้ ควรรายงาน gross traded notional $\sum_i |\Delta w_i|$ เพิ่มเติม เพราะ factor 1/2 ไม่ได้มีความหมายเป็น “ฝั่งซื้อหรือฝั่งขาย” โดยอัตโนมัติ

14.8 Portfolio of Alphas

สมมติ alpha strategies K ตัวมี expected return vector μ_α และ covariance matrix Ω ถ้าให้น้ำหนัก γ

$$IR(\gamma) = \frac{\gamma^\top \mu_\alpha}{\sqrt{\gamma^\top \Omega \gamma}}$$

Maximum Information-Ratio Direction. ให้

$$x = \Omega^{1/2} \gamma, \quad y = \Omega^{-1/2} \mu_\alpha$$

จะได้

$$IR(\gamma) = \frac{x^\top y}{\|x\|} \leq \|y\|$$

จาก Cauchy-Schwarz equality เกิดเมื่อ $x \propto y$ ดังนั้น

$$\gamma^* \propto \Omega^{-1} \mu_\alpha$$

เมื่อไม่มีข้อจำกัดเพิ่มเติมและ Ω เป็น positive definite □

ถ้า Ω ใกล้ singular หรือจำนวน alpha มากเมื่อเทียบกับ ประวัติ ข้อมูล ทิศทาง $\Omega^{-1}\mu_\alpha$ อาจไวต่อ estimation error มาก ควรใช้ covariance shrinkage, regularization หรือ pseudoinverse พร้อม weight/risk constraints มากกว่าสร้าง inverse โดยตรง นอกจากนี้ μ_α ต้องถูกประมาณแบบ out-of-sample-aware เช่นเดียวกับ expected return ของสินทรัพย์

ข้อสังเกต

Alpha Novelty

alpha ใหม่ควรเพิ่มข้อมูลที่ไม่ซ้ำกับ alpha เดิม ไม่ใช่เพียงมี Sharpe สูงเมื่อทดสอบเดี่ยว ควรตรวจ correlation matrix, residual alpha หลัง regress บน alpha library, turnover overlap, factor exposure และ performance ใน stress regimes อีกทั้งการรวม alpha ก่อนส่งคำสั่งอาจเกิด *trade netting* ทำให้ต้นทุนรวมต่ำกว่าการบวกต้นทุนของแต่ละ alpha แยกกัน ดังนั้น portfolio of alphas ควรถูกประเมินที่ระดับคำสั่งรวมด้วย

14.9 Transaction Costs, Market Impact และ Capacity

ต้องแยก ต้นทุนเป็นจำนวนเงิน ออกจาก ต้นทุนในหน่วยผลตอบแทน ให้ชัด ให้ C_t เป็นมูลค่าต้นทุนจากการ rebalance ณ เวลา t และ A_t เป็น AUM ก่อนซื้อขาย กำหนด cost rate

$$c_t = \frac{C_t}{A_t}$$

หากต้นทุนถูกหักก่อนเริ่มช่วงถือครอง และ R_{t+1}^{gross} วัดบนเงินทุนหลังต้นทุน จะได้

$$W_{t+1} = (A_t - C_t)(1 + R_{t+1}^{\text{gross}})$$

ดังนั้นผลตอบแทนสุทธิเมื่อวัดเทียบกับ AUM ก่อนซื้อขายคือ

$$R_{t+1}^{\text{net}} = R_{t+1}^{\text{gross}} - c_t(1 + R_{t+1}^{\text{gross}}) \approx R_{t+1}^{\text{gross}} - c_t$$

โดย approximation สุดท้ายเหมาะสมเมื่อ c_t มีขนาดเล็ก การหักต้นทุนจึงต้องสัมพันธ์กับเวลาที่ต้นทุนเกิดขึ้น ไม่ควรลบจำนวนเงินบาทออกจาก return โดยตรงโดยไม่ normalize ด้วยฐานเงินลงทุน

แบบจำลองต้นทุนในหน่วยผลตอบแทนอย่างง่ายอาจเขียน

$$c_t = c_1 TO_t + c_2 TO_t^2$$

ส่วนแบบจำลองระดับคำสั่ง ให้ $Q_{i,t}$ เป็นมูลค่าคำสั่งและ $ADV_{i,t}$ เป็น average daily traded value ในหน่วยเงินเดียวกัน

$$C_{i,t} \approx a_i |Q_{i,t}| + b_i \sigma_{i,t} |Q_{i,t}| \sqrt{\frac{|Q_{i,t}|}{ADV_{i,t}}}$$

พจน์แรกแทน spread/fee เชิงเส้นโดยประมาณ ส่วนพจน์ที่สองเป็น square-root impact approximation ซึ่งเพิ่มเร็วกว่าสัดส่วนเมื่อ participation สูง แบบจำลองนี้เป็น approximation ไม่ใช่กฎสากล และพารามิเตอร์ควรถูก calibrate ตามตลาด ขนาดคำสั่ง และ execution horizon

$$\pi_{i,t} = \frac{|Q_{i,t}|}{ADV_{i,t}}$$


คือ participation rate ที่ช่วยเชื่อมขนาดพอร์ตกับ market impact

บทนิยาม 14.1

Capacity คือระดับ AUM ที่กลยุทธ์ยังสร้างผลตอบแทนสุทธิที่คุ้มกับความเสี่ยงและยังดำเนินการได้ภายใต้ liquidity, participation, borrow, leverage และ risk limits ไม่ใช่เพียงจำนวนเงินสูงสุดที่ระบปรับได้

ถ้า h เป็น required net-alpha hurdle อาจนิยามเชิงแนวคิด

$$A^* = \sup \{A : \alpha_{\text{net}}(A) \geq h \text{ และ constraints ยัง feasible} \}, \quad \alpha_{\text{net}}(A) = \alpha_{\text{gross}}(A) - c(A)$$



รูปที่ 14.2: Capacity เป็นจุดที่ผลตอบแทนสุทธิหลังต้นทุนและข้อจำกัดลดลงถึงระดับ hurdle ที่กำหนด ไม่ใช่ค่าคงที่ที่แยกจาก AUM

14.10 Robust Backtesting

14.10.1 Bias Checklist

Backtest ที่น่าเชื่อถือควรออกแบบ chronology ก่อนคำนวณ performance และบันทึกการทดลองทั้งหมด ไม่ใช่แก้ไขเฉพาะ bias หลังเห็นผล [53, 60, 32]

ตารางที่ 14.2: ความลำเอียงสำคัญใน quantitative backtesting และวิธีควบคุม

Bias	กลไกที่ทำให้ผลดีเกินจริง	วิธีควบคุม
Look-ahead	ใช้ข้อมูลที่ยังไม่เปิดเผย	point-in-time timestamps และ publication lag
Survivorship	ใช้เฉพาะหลักทรัพย์ที่รอด	historical universe รวม delisting
Leakage	preprocessing/model selection เห็น validation/test	fit ภายใน train และ ใช้ nested selection เมื่อจำเป็น
Execution	สมมติ fill price ที่ไม่มีทางรู้หรือซื้อขายทันที	explicit decision clock, latency และ fill model
Data snooping	ทดลองจำนวนมาก แล้วเลือกรายงานผู้ชนะ	search log และ multiple-testing control
Selection	เลือกช่วง/benchmark หลังเห็นผล	pre-specified protocol และ holdout
Cost omission	ไม่รวม friction หรือ impact	spread, fee, slippage, borrow และ impact ที่สมจริง
Corporate action	ใช้ราคา/ผลตอบแทนที่ปรับไม่สอดคล้อง	point-in-time adjustment และ delisting return

14.10.2 Walk-Forward Validation

Expanding window

$$\{1, \dots, t\} \rightarrow \{t+1, \dots, t+h\}$$

Rolling window

$$\{t-L+1, \dots, t\} \rightarrow \{t+1, \dots, t+h\}$$

ถ้า labels ซ้อนทับกันหรือ features ใช้ข้อมูลช่วงยาว ควรใช้ purge/embargo เพื่อลด information overlap ระหว่าง train และ validation โดย purge ตัด observations ที่ label interval ทับกับ validation ส่วน embargo เว้นช่วงหลัง validation ตามความเสี่ยงของ leakage

ทุก fold ต้องสร้าง preprocessing, feature selection และ hyperparameter tuning จากข้อมูลที่ fold นั้นอนุญาตให้เห็นเท่านั้น หากเลือก hyperparameter จากผลของ test fold แล้วรายงาน fold เดิมเป็น OOS จะ

เกิด model-selection leakage แม้การแบ่งเวลาจะถูกต้อง

14.10.3 Multiple Testing

ถ้าทดสอบ M กลยุทธ์อิสระภายใต้ null และแต่ละกลยุทธ์มี false-positive probability α

$$P(\text{อย่างน้อยหนึ่ง false positive}) = 1 - (1 - \alpha)^M$$

เมื่อ M เพิ่มขึ้น ความน่าจะเป็นพบ “ผู้ชนะโดยบังเอิญ” เพิ่มขึ้นอย่างรวดเร็ว สูตรข้างต้นเป็นภาพประกอบภายใต้สมมติฐานอิสระเท่านั้น ในงานจริงกลยุทธ์มักมีสหสัมพันธ์กัน จึงควรใช้วิธีที่สอดคล้องกับ dependence เช่น resampling-based reality checks หรือควบคุม false discovery rate พร้อมบันทึก search history และจำนวนการทดลองที่แท้จริง

Robustness Stack

OOS + Walk-Forward + Bootstrap
+Parameter Sensitivity + Cost Sensitivity
+Regime Stability + Multiple-Testing Control

กลยุทธ์ที่ดีไม่จำเป็นต้องดีที่สุดในทุกมิติ แต่ไม่ควรพึ่งพาจุดพารามิเตอร์ ช่วงเวลา หรือสมมติฐานต้นทุนเพียงจุดเดียว

14.11 Benchmark Symmetry

การเปรียบเทียบ strategy กับ benchmark ต้องใช้ข้อมูล ช่วงเวลา การปรับ corporate actions ความถี่ การคำนวณผลตอบแทน และต้นทุนที่สมเหตุสมผลในมาตรฐานเดียวกัน

Same Information + Same Horizon
+Same Return Convention + Comparable Costs

มิฉะนั้น performance difference อาจมาจาก measurement asymmetry ไม่ใช่ investment skill คำว่า comparable costs ไม่ได้หมายความว่าต้องบังคับ strategy และ benchmark ให้มีต้นทุนเท่ากัน แต่ต้องใช้ต้นทุนที่สมจริงกับ turnover และวิธี implementation ของแต่ละฝ่าย เช่น benchmark แบบ buy-and-hold

อาจมี turnover ต่ำกว่ากลยุทธ์เชิงรุกอย่างแท้จริง

14.12 Machine Learning: Prediction-to-Portfolio Gap

ให้แบบจำลองพยากรณ์

$$\hat{y}_{i,t+h} = f_{\theta_t}(X_{i,t})$$

โดย θ_t ต้องเรียนรู้จาก information set ที่อนุญาต ณ เวลา t เท่านั้น และ target horizon h ต้องสอดคล้องกับ holding period และ decision clock

การพยากรณ์ที่ดีไม่เท่ากับพอร์ตที่ดี เพราะต้องผ่าน

Prediction → Ranking → Sizing → Risk Control
→ Execution → Net Performance

ดังนั้น RMSE, AUC หรือ R^2 ที่ดีขึ้นอาจไม่มีคุณค่าทางเศรษฐกิจหากความผิดพลาดเกิดในสินทรัพย์ที่ไม่ได้ถือ หรือ โมเดลสร้าง turnover/concentration สูงขึ้น

ปัญหา portfolio-aware ML สามารถเขียนเป็น

$$\max_{w_t} \left\{ \hat{\mu}_t^T w_t - \frac{\lambda}{2} w_t^T \hat{\Sigma}_t w_t - \eta \|w_t - w_{t-1}^+\|_1 \right\}$$

ภายใต้ constraints เดียวกับการนำไปใช้จริง เป้าหมายนี้ทำให้เห็นว่า prediction layer เป็นเพียง input หนึ่งของ portfolio decision ไม่ใช่ objective สุดท้าย

14.12.1 โมเดลและบทบาท

ตารางที่ 14.3: บทบาทของโมเดล Machine Learning ในระบบลงทุนและความเสี่ยงที่ต้องควบคุม

กลุ่มโมเดล	บทบาทที่เหมาะสม	ความเสี่ยงสำคัญ
Supervised	regression, classification, ranking	leakage, overfit, calibration drift
Unsupervised	clustering, PCA, representation	unstable clusters, economic interpretation
Deep learning	nonlinear/ high-dimensional mapping	parameter risk, sample efficiency, governance
NLP/LLM	text features, classification, retrieval/summarization	timestamp, provenance, hallucination, licensing
Alternative-data models	nontraditional features	coverage drift, selection bias, privacy/legal risk

Supervised learning ใช้ regression/classification/ranking เพื่อพยากรณ์ผลตอบแทน ลำดับ หรือเหตุการณ์ ส่วน Unsupervised learning ใช้ clustering, PCA และ representation learning เพื่อค้นหาโครงสร้างที่ไม่มี label โดยตรง

Deep learning อาจเหมาะเมื่อข้อมูลมีโครงสร้างซับซ้อนหรือปริมาณมาก แต่จำนวน observation เติบโตในอัตราที่ต่ำกว่าจำนวนแถวข้อมูลดิบเนื่องจาก cross-sectional และ temporal dependence จึงต้องพิจารณา effective sample size ไม่ใช่จำนวน records เพียงอย่างเดียว

NLP/LLM สามารถแปลงข่าว เอกสาร หรือข้อความ เป็น features แต่ต้องควบคุม timestamp, provenance, model/version drift, hallucination ในขั้น generative, revision และ licensing ส่วน Alternative data ต้องตรวจสอบความคงที่ของ coverage, selection process, legal/privacy constraints และความสามารถในการสร้างข้อมูลย้อนหลังแบบ point-in-time

ประเด็นที่ต้องระวัง

การเลือกโมเดลจาก metric การพยากรณ์เพียงตัวเดียวอาจเกิด prediction-to-portfolio mismatch ควรประเมินทั้ง predictive metric, IC, turnover, exposure, cost-adjusted return, drawdown และ stability ภายใต้ protocol เดียวกัน

14.13 Reinforcement Learning และ Objective Alignment

RL กำหนด state s_t , action a_t , reward r_{t+1} และ policy $\pi(a_t|s_t)$ โดย state ต้องมีข้อมูลเพียงพอให้การตัดสินใจสะท้อนสถานะของพอร์ตและข้อจำกัดที่เกี่ยวข้อง เช่น holdings, cash, risk exposure และข้อมูลตลาดที่อนุญาต

reward สำหรับการลงทุนไม่ควรเป็น gross return อย่างเดียว ตัวอย่างเชิงแนวคิด

$$r_{t+1} = R_{t+1}^{\text{net}} - \lambda_{\sigma}\hat{\sigma}_{t+1}^2 - \lambda_{TO}TO_t - \lambda_{DD}DD_{t+1}$$

โดย coefficients λ_{σ} , λ_{TO} , λ_{DD} ทำหน้าที่ปรับหน่วยและ trade-off ของ objective ไม่ใช่พารามิเตอร์ที่มีค่ามาตรฐานเดียวสำหรับทุกปัญหา หาก reward ใช้ drawdown ซึ่งขึ้นกับ running wealth peak ควรรวมตัวแปรที่ทำให้ path dependence น้อยใน state หรือออกแบบ environment ให้รักษาข้อมูลดังกล่าวอย่างถูกต้อง

ประเด็นที่ต้องระวัง

RL มีความเสี่ยงจาก simulator mismatch, reward hacking, unstable policy, off-policy extrapolation และ regime shift การมี reward สูงใน historical environment ไม่ได้แปลว่า policy จะปลอดภัยในตลาดจริง จึงควรมี hard risk limits, conservative deployment, paper trading และ human override แยกจาก reward optimization

14.14 Model Governance และ Quant Research Gates

Research Gates

1. **G0 Problem:** hypothesis, objective, benchmark และ economic rationale ชัดเจน
2. **G1 Data:** point-in-time, lineage, universe และ data quality ผ่าน
3. **G2 Model:** specification, ablation, leakage control และ reproducibility ผ่าน
4. **G3 Risk:** OOS, stress, cost, turnover, capacity และ failure modes ผ่าน
5. **G4 Impact:** deployment, monitoring, governance และ decision usefulness ผ่าน

Model card ควรระบุ purpose, data, features, assumptions, training period, validation period, benchmark, costs, limitations, risk limits, retraining policy, drift indicators, owner และ retirement criteria

14.14.1 Drift และ Kill Criteria


ตัวชี้วัด drift อาจประกอบด้วย

$$IC_t, \quad Sharpe_t, \quad TE_t, \quad TO_t, \quad Cost_t, \quad Exposure_t$$

ระบบควรมีเกณฑ์ลดความเสี่ยง หยุดส่งคำสั่ง หรือเข้าสู่ model review เมื่อข้อมูลหรือพฤติกรรมของโมเดล ออกนอกช่วงที่ยอมรับได้ แต่ kill criteria ไม่ควรอาศัย Sharpe หรือ IC จุดเดียว เพราะตัวชี้วัดระยะสั้นมี noise สูง ควรใช้ escalation หลายระดับ เช่น data-integrity breach หรือ risk-limit breach เป็น hard stop ขณะที่ performance deterioration ใช้ persistence, confidence interval และ regime context ประกอบ

การเปลี่ยนโมเดลหลัง deployment ต้องถูก versioned และผ่าน gate ที่เหมาะสมอีกครั้ง มิฉะนั้น adaptive tuning อาจเปลี่ยน live system ให้กลายเป็นการทำ research บนข้อมูลจริงโดยไม่มี holdout

14.15 Integrated Quant Research Architecture



นี่คือจุดที่ทฤษฎีจากทั้งเล่มกลับมาทำงานพร้อมกัน ได้แก่ผลตอบแทน ความเสี่ยง covariance การประเมินมูลค่า Markowitz factor models optimization allocation VaR/ES performance evaluation และ fund implementation

จุดสำคัญคือแต่ละขั้นต้องส่งต่อ **ทั้งค่าประมาณและความไม่แน่นอน** ไปยังขั้นถัดไป ตัวอย่างเช่น expected return ที่ไม่แน่นอนไม่ควรถูกแปลงเป็นน้ำหนักสุดโต่ง และ cost estimate ที่ไม่แน่นอนควรถูก stress ก่อนเพิ่ม AUM การออกแบบระบบจึงเป็นปัญหาของ error propagation และ feedback control พอ ๆ กับ prediction

14.16 Investment Labs

Investment Lab: Lab 14A – Signal Engineering

สร้าง cross-sectional features อย่างน้อย 3 ตัว ทำ winsorization, z-score, rank และ neutralization เปรียบเทียบ IC, Rank IC, turnover และ factor exposure ของแต่ละวิธี

Investment Lab: Lab 14B – Leakage-Free Backtest

สร้าง strategy หนึ่งชุดโดยกำหนด availability time, signal time, order time และ fill time อย่างชัดเจน เปรียบเทียบผลของ same-close execution กับ next-period execution เพื่อเห็น execution bias

Investment Lab: Lab 14C – Portfolio of Alphas

สร้าง alpha อย่างน้อย 5 ตัว ประมาณ μ_α และ Ω แล้วเปรียบเทียบ equal weight กับ inverse-covariance combination พร้อม shrinkage และ correlation stress

Investment Lab: Lab 14D – Cost and Capacity

เพิ่ม spread, commission, slippage และ nonlinear market impact เข้า backtest แล้วสร้างกราฟ net alpha เทียบ AUM เพื่อประมาณ capacity

Investment Lab: Lab 14E – Quant Research Audit

สร้าง audit package ของ backtest ประกอบด้วย README, data dictionary, code version, environment, random seed, experiment registry, parameter-search log, final holdout, benchmark symmetry check, cost assumptions, limitations และ one-page model card

ผลส่งมอบของทุก Lab ควรแยก **research artifact** ออกจาก **decision artifact**: research artifact เก็บข้อมูล โค้ด พารามิเตอร์ และ diagnostics เพื่อทำซ้ำได้ ส่วน decision artifact สรุปว่ากลยุทธ์ผ่านหรือไม่ผ่าน gate ไດ เพราะเหตุใด และเงื่อนไขใดทำให้ต้องทบทวนผล

14.17 บทสรุปท้ายบท


การลงทุนเชิงปริมาณไม่ใช่การค้นหายุทธวิธีให้ backtest สูงที่สุด แต่เป็นการออกแบบระบบตัดสินใจที่ข้อมูลและเวลาไม่รั่วไหล สัญญาณมีเหตุผลทางเศรษฐศาสตร์ พอร์ตควบคุมความเสี่ยง ต้นทุนถูกนับอย่างสมจริง และผลลัพธ์ผ่านการตรวจสอบนอกตัวอย่าง

แกนทางคณิตศาสตร์ของระบบเริ่มจากการแปลงข้อมูลเป็น signal การ neutralize ด้วย projection การแปลง signal เป็นพอร์ตภายใต้ covariance และ constraints การรวม alpha หลายตัวผ่าน expected alpha กับ covariance ของ alpha returns และการหักต้นทุนในหน่วยที่สอดคล้องกับผลตอบแทน

ความซับซ้อนของ Machine Learning ไม่ลดความจำเป็นของทฤษฎีพอร์ต ตรงกันข้าม โมเดลพยากรณ์ต้องผ่าน prediction-to-portfolio mapping และถูกประเมินหลังต้นทุน ความเสี่ยง และข้อจำกัดการซื้อขาย

Robust validation ต้องแยก development ออกจาก evaluation ใช้ walk-forward หรือ rolling design ควบคุม multiple testing และตรวจ sensitivity ต่อ parameter, cost และ regime พร้อม benchmark ที่เปรียบเทียบอย่างสมมาตร

ท้ายที่สุด quantitative investing ที่ใช้งานได้จริงต้องมี governance, reproducibility, monitoring และ retirement rule ระบบที่ดีจึงไม่ใช่เพียง “โมเดลที่ทำนายได้” แต่เป็นวงจร



คำศัพท์สำคัญ

Alpha Signal ตัวแปรหรือคะแนนที่สร้างก่อนลงทุนและคาดว่าจะมี predictive content

Point-in-Time Data ข้อมูลเวอร์ชันที่เข้าถึงได้จริง ณ เวลาตัดสินใจ

Neutralization การกำจัด exposure ที่ไม่ต้องการออกจาก signal

Information Coefficient สหสัมพันธ์ภาคตัดขวางระหว่าง signal กับ forward return

Turnover ปริมาณการเปลี่ยนน้ำหนักพอร์ตระหว่างรอบ

Market Impact ผลของคำสั่งซื้อขายต่อราคาที่สามารถดำเนินการได้

Capacity ขนาด AUM ที่กลยุทธ์ยังสร้างผลตอบแทนสุทธิที่คุ้มความเสี่ยง

Walk-Forward Validation การประเมินแบบเลื่อนเวลาโดยใช้เฉพาะอดีตสร้างโมเดล

Purging การตัด observations ที่มี information overlap ระหว่าง train และ validation

Data Snooping การค้นหาหลายแบบจนพบผลดีโดยบังเอิญ

Model Drift การเปลี่ยนแปลงของข้อมูลหรือความสัมพันธ์จนโมเดลเสื่อม

Model Card เอกสารสรุปวัตถุประสงค์ ข้อมูล สมมติฐาน validation ข้อจำกัด และ governance ของโมเดล

14.18 แบบฝึกหัดท้ายบท

1. อธิบายความแตกต่างระหว่าง ex-ante alpha signal และ ex-post alpha
2. เขียน decision clock สำหรับกลยุทธ์ที่ใช้ราคาปิดสร้าง signal และซื้อที่ราคาเปิดวันถัดไป
3. ยกตัวอย่าง look-ahead bias ที่เกิดจากข้อมูลบัญชี
4. คำนวณ z-score ของข้อมูล (2, 4, 6, 8, 10)
5. map rank ของข้อมูลห้าค่าลงช่วง $[-1, 1]$
6. พิสูจน์ว่า neutralized signal ตั้งฉากกับ exposure matrix
7. อธิบายกรณีที่ rank transformation เหมาะกว่า z-score และกรณีที่ winsorization อาจเปลี่ยนลำดับข้อมูล
8. สร้าง composite score จาก Value, Momentum และ Quality พร้อมกำหนดน้ำหนัก
9. อธิบายผลของ volatility scaling ต่อ position size
10. ออกแบบ liquidity gate จาก ADV และ bid-ask spread
11. คำนวณ momentum 3 งวดจากผลตอบแทนที่กำหนดเอง และอธิบายว่าจะเปลี่ยนสูตรอย่างไรหากต้องการเว้นงวดล่าสุด
12. อธิบายความแตกต่างระหว่าง factor model และ factor strategy
13. คำนวณ EMA เมื่อ $n = 9$ และมีราคาต่อเนื่อง 5 ค่า
14. อธิบายเหตุผลที่ next-day-open execution ลด execution bias ในกรณี signal ใช้ราคาปิด
15. คำนวณ IC จาก signal และ forward return ของหุ้น 5 ตัว
16. อธิบายว่าทำไม IC บวกอาจให้ net return ติดลบ
17. แปลง signal (2, 1, 0, -1, -2) เป็น dollar-neutral gross-normalized weights
18. คำนวณ one-way turnover จากน้ำหนักก่อนและหลัง rebalance
19. ตั้ง optimization ที่มี expected return, variance และ turnover penalty
20. พิสูจน์ว่า maximum-IR alpha combination มีทิศทาง $\Omega^{-1}\mu_\alpha$
21. อธิบายผลของ alpha correlation ต่อ diversification
22. สร้างตัวอย่าง alpha ใหม่ที่ Sharpe สูงแต่ไม่มี novelty เมื่อเทียบกับ alpha library
23. คำนวณ net return เมื่อ gross return เท่ากับ 1.2% และต้นทุนรวม 0.35%

24. อธิบายความแตกต่างระหว่างต้นทุนจำนวนเงิน C_t กับ cost rate c_t และระหว่าง linear cost กับ nonlinear market impact
25. ออกแบบการประมาณ capacity ของกลยุทธ์หนึ่งชุด
26. คำนวณความน่าจะเป็นพบ false positive อย่างน้อยหนึ่งครั้งเมื่อ $M = 20$ และ $\alpha = 0.05$ ภายใต้สมมติฐานอิสระ
27. เปรียบเทียบ expanding-window กับ rolling-window validation
28. อธิบายเหตุผลของ purging และ embargo
29. ออกแบบ benchmark-symmetry checklist
30. สร้าง Model Card สำหรับกลยุทธ์เชิงปริมาณหนึ่งกลยุทธ์ พร้อมกำหนด drift indicators และ kill/escalation criteria อย่างน้อยสามประเภท

คำถามชวนคิด

1. กลยุทธ์ที่ Sharpe สูงมากใน backtest แต่มี economic rationale อ่อนควรผ่าน research gate หรือไม่
2. หาก ML model มี RMSE ต่ำกว่าแต่สร้าง turnover สูงกว่า โมเดลใดควรถูกเลือกสำหรับการลงทุน
3. การเพิ่มข้อมูลจำนวนมากช่วยลด model risk เสมอหรืออาจเพิ่ม data-mining risk
4. Alpha ที่ correlation ต่ำกับ alpha library แต่มี capacity ต่ำมากยังมีคุณค่าต่อพอร์ตหรือไม่
5. ควรหยุดใช้โมเดลเมื่อ Sharpe ลดลงเท่าใด หรือควรใช้เกณฑ์หลายมิติร่วมกัน
6. ในยุค AI ความได้เปรียบที่ยั่งยืนควรอยู่ที่โมเดล ข้อมูล execution หรือ governance มากที่สุด เพราะเหตุใด

เอกสารอ้างอิงท้ายบทที่ 14

- [2] Andrew Ang, Robert J. Hodrick, Yuhang Xing, and Xiaoyan Zhang. “The Cross-Section of Volatility and Expected Returns”. In: *The Journal of Finance* 61.1 (2006), pp. 259–299.
- [10] Prachya Boonprasurt, Pipat Sampaokit, and Wichai Witayakiattilerd. “MACD Indicator with the Modified Signal Line and Trading Weight Inference in Fuzzy Environment”. In: *Thailand Statistician* 20.1 (2022), pp. 98–123.
- [20] Eugene F. Fama and Kenneth R. French. “Common Risk Factors in the Returns on Stocks and Bonds”. In: *Journal of Financial Economics* 33.1 (1993), pp. 3–56.

- [26] Narasimhan Jegadeesh and Sheridan Titman. “Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency”. In: *The Journal of Finance* 48.1 (1993), pp. 65–91.
- [28] C. Kesamoon and W. Witayakiattilerd. “Hierarchy Analysis Process under Fuzzy Environment: A Positive Way of Selecting Stocks into Portfolio under Ambiguity in Stock Information”. In: *Science & Technology Asia* 25.4 (2020), pp. 1–11. DOI: [10 . 14456 / scitechasia . 2019 . 24](https://doi.org/10.14456/scitechasia.2019.24).
- [32] Marcos López de Prado. *Advances in Financial Machine Learning*. Wiley, 2018.
- [37] Robert Novy-Marx. “The Other Side of Value: The Gross Profitability Premium”. In: *Journal of Financial Economics* 108.1 (2013), pp. 1–28.
- [53] Ryan Sullivan, Allan Timmermann, and Halbert White. “Data-Snooping, Technical Trading Rule Performance, and the Bootstrap”. In: *The Journal of Finance* 54.5 (1999), pp. 1647–1691.
- [60] Halbert White. “A Reality Check for Data Snooping”. In: *Econometrica* 68.5 (2000), pp. 1097–1126.
- [63] Wichai Witayakiattilerd et al. “Advanced Forecasting of Non-Performing Loans: Revised Chronological and Decision-Aware Framework”. Revised project manuscript; cited for validation methodology. 2026.
- [64] Wichai Witayakiattilerd. “QuantX TU Blueprint 2026–2029: Thammasat Quantitative Finance & AI Society”. Project blueprint, Thammasat University. 2026.
- [65] Wichai Witayakiattilerd. “Thailand Capital Flow Intelligence Platform (Phase I): Mathematical Foundation and Prototype”. CMDf proposal framework under development. 2026.
- [66] Wichai Witayakiattilerd. “การวิจัยอัลฟาและการสร้างพอร์ตการลงทุนเชิงระบบ: ทฤษฎี วิธีวิทยา และการประยุกต์ใช้กับแพลตฟอร์ม WorldQuant BRAIN”. Project textbook manuscript, draft dated 20 June 2026. 2026.
- [67] Wichai Witayakiattilerd. “รายงานการพัฒนาแบบจำลอง Alpha เชิงระบบสำหรับการลงทุนเชิงปริมาณ: Systematic Alpha Portfolio Construction for Quantitative Trading Based on Mean Reversion, Volatility Scaling, and Liquidity Signals”. Project research report, Thammasat University. 2026.

- [69] Wichai Witayakiattilerd and Wararit Panichkitkosolkul. “Robust Backtesting of Bollinger Bands with Alternative Moving Averages: An Empirical Study on SET50 Stocks”. In: *Bangmod International Journal of Mathematical and Computational Science* 12 (2026), pp. 96–118. DOI: [10.58715/bangmodjmcs.2026.12.6](https://doi.org/10.58715/bangmodjmcs.2026.12.6).

Part VI

ภาคผนวก

บทที่ A เครื่องมือทางคณิตศาสตร์สำหรับการลงทุนและการบริหารพอร์ต

A.1 บทบาทของภาคผนวกนี้

ภาคผนวกนี้รวบรวมเครื่องมือทางคณิตศาสตร์ที่ใช้ซ้ำในหลายบทของตำรา เพื่อให้ผู้อ่านสามารถย้อนกลับมาทบทวนได้โดยไม่ต้องขยายรายละเอียดพื้นฐาน ในบทหลัก เนื้อหาจึงมีลักษณะเป็น *mathematical reference* มากกว่าบทเรียนคณิตศาสตร์แบบเต็มรายวิชา

A.2 สัญกรณ์ผลรวมและผลคูณ

สำหรับจำนวนจริง $x_1, \dots, x_n$

$$\sum_{i=1}^n x_i = x_1 + \dots + x_n, \quad \prod_{i=1}^n x_i = x_1 x_2 \dots x_n.$$

หาก R_t คือผลตอบแทนแบบ simple return ในงวดที่ t แล้ว มูลค่าเงินลงทุนหลัง T งวดคือ

$$V_T = V_0 \prod_{t=1}^T (1 + R_t).$$

A.3 ลอการิทึมและผลตอบแทนแบบลอการิทึม

นิยาม log return เป็น

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right).$$

จากสมบัติ $\ln(ab) = \ln a + \ln b$ จะได้

$$\sum_{t=1}^T r_t = \ln\left(\frac{P_T}{P_0}\right).$$

ประเด็นที่ต้องระวัง

Simple return เหมาะกับการรวมผลตอบแทนของสินทรัพย์หลายชนิดภายในงวดเดียว ส่วน log return มีสมบัติ additive ตามเวลา จึงไม่ควรสลับใช้สองนิยามโดยไม่ระบุให้ชัดเจน

A.4 เวกเตอร์และเมทริกซ์

ให้เวกเตอร์น้ำหนักของพอร์ตเป็น

$$\mathbf{w} = \begin{bmatrix} w_1 \\ \vdots \\ w_n \end{bmatrix}, \quad \mathbf{1}^T \mathbf{w} = 1,$$

และเวกเตอร์ผลตอบแทนคาดหวังเป็น

$$\boldsymbol{\mu} = \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_n \end{bmatrix}.$$

ดังนั้นผลตอบแทนคาดหวังของพอร์ตคือ

$$\mu_p = \mathbf{w}^T \boldsymbol{\mu}.$$

A.5 Covariance Matrix และ Quadratic Form

ให้

$$\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_2^2 & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_n^2 \end{bmatrix},$$

โดย

$$\sigma_{ij} = \text{Cov}(R_i, R_j).$$

ความแปรปรวนของพอร์ตคือ

$$\sigma_p^2 = \mathbf{w}^T \Sigma \mathbf{w}.$$

เมทริกซ์ความแปรปรวนร่วมเป็น symmetric positive semidefinite ดังนั้น

$$\mathbf{x}^T \Sigma \mathbf{x} \geq 0$$

สำหรับเวกเตอร์ $\mathbf{x}$ ทุกเวกเตอร์

A.6 การหาอนุพันธ์ของฟังก์ชันพอร์ต

สำหรับ

$$f(\mathbf{w}) = \mathbf{w}^T \Sigma \mathbf{w}$$

เมื่อ Σ เป็นเมทริกซ์สมมาตร

$$\nabla_{\mathbf{w}} f(\mathbf{w}) = 2\Sigma \mathbf{w}.$$

ผลลัพธ์นี้เป็นพื้นฐานของ minimum-variance optimization และการวิเคราะห์ marginal contribution to risk

A.7 ตัวคูณลากรังจ์

พิจารณาปัญหา

$$\min_{\mathbf{w}} \quad \frac{1}{2} \mathbf{w}^T \Sigma \mathbf{w}$$

ภายใต้

$$\mathbf{1}^T \mathbf{w} = 1.$$

กำหนด

$$\mathcal{L}(\mathbf{w}, \lambda) = \frac{1}{2} \mathbf{w}^T \Sigma \mathbf{w} - \lambda(\mathbf{1}^T \mathbf{w} - 1).$$

เงื่อนไขอันดับหนึ่งให้

$$\Sigma \mathbf{w} - \lambda \mathbf{1} = \mathbf{0}.$$

เมื่อ Σ ผกผันได้

$$w = \lambda \Sigma^{-1} \mathbf{1}.$$

ใช้ข้อจำกัดน้ำหนักรวมเท่ากับหนึ่ง จะได้

Global Minimum-Variance Portfolio

$$w_{\text{GMV}} = \frac{\Sigma^{-1} \mathbf{1}}{\mathbf{1}^T \Sigma^{-1} \mathbf{1}}$$

A.8 กรณีมีผลตอบแทนเป้าหมาย

หากเพิ่มข้อจำกัด

$$w^T \mu = \mu^*$$

ปัญหา Markowitz แบบมาตรฐานคือ

$$\min_w w^T \Sigma w$$

ภายใต้

$$\mathbf{1}^T w = 1, \quad w^T \mu = \mu^*.$$

ภาคผนวกนี้ให้เพียงโครงสร้างทางคณิตศาสตร์ ส่วนการตีความ efficient frontier และการใช้จริงอยู่ในบทหลักของตำรา

A.9 Convexity และเหตุผลที่สำคัญต่อ Portfolio Optimization

ถ้า $\Sigma \succeq 0$ แล้ว

$$f(w) = w^T \Sigma w$$

เป็นฟังก์ชัน convex ดังนั้น minimum-variance problem ภายใต้ข้อจำกัดเชิงเส้น เป็น convex optimization problem

ประเด็นที่ต้องระวัง

การที่ objective เป็น convex ไม่ได้หมายความว่า input data ถูกต้องเสมอ Covariance estimation error, ill-conditioning, constraints และ transaction costs ยังสามารถทำให้พอร์ตที่ได้ไม่เสถียรในทางปฏิบัติ

A.10 Matrix Identities ที่ใช้บ่อย

สำหรับเวกเตอร์และเมทริกซ์ที่มีมิติสอดคล้องกัน

$$(AB)^T = B^T A^T, \quad (A^{-1})^T = (A^T)^{-1},$$

และถ้า Σ เป็น symmetric

$$\Sigma^T = \Sigma.$$

A.11 สรุป

เครื่องมือในภาคผนวกนี้ครอบคลุมสัญญาณ เวกเตอร์ เมทริกซ์ quadratic form อนุพันธ์ Lagrange multiplier และ convexity ซึ่งเป็นฐานคณิตศาสตร์ของการวิเคราะห์พอร์ตตลอดทั้งเล่ม

บทที่ B ความน่าจะเป็นและสถิติสำหรับผลตอบแทนและความเสี่ยง

B.1 บทบาทของภาคผนวกนี้

ภาคผนวกนี้รวบรวมแนวคิดความน่าจะเป็นและสถิติ ที่ใช้เป็นพื้นฐานในการวิเคราะห์ผลตอบแทน ความเสี่ยง การกระจายความเสี่ยง การประมาณค่าพารามิเตอร์ และการวัด tail risk

B.2 ตัวแปรสุ่มและค่าคาดหวัง

ให้ R เป็นตัวแปรสุ่มแทนผลตอบแทน ค่าคาดหวังคือ

$$\mathbb{E}(R) = \mu.$$

ถ้า a, b เป็นค่าคงที่

$$\mathbb{E}(a + bR) = a + b\mathbb{E}(R).$$

สำหรับผลตอบแทนหลายสินทรัพย์

$$R_p = \sum_{i=1}^n w_i R_i$$

จึงมี

$$\mathbb{E}(R_p) = \sum_{i=1}^n w_i \mathbb{E}(R_i).$$

B.3 Variance และ Standard Deviation

นิยาม

$$\text{Var}(R) = \mathbb{E}[(R - \mu)^2]$$

และ

$$SD(R) = \sqrt{\text{Var}(R)}.$$

สำหรับค่าคงที่ a, b

$$\text{Var}(a + bR) = b^2 \text{Var}(R).$$

B.4 Covariance และ Correlation

นิยาม covariance เป็น

$$\text{Cov}(R_i, R_j) = \mathbb{E}[(R_i - \mu_i)(R_j - \mu_j)].$$

Correlation คือ

$$\text{Corr}(R_i, R_j) = \frac{\text{Cov}(R_i, R_j)}{\sigma_i \sigma_j}.$$

เมื่อ $\sigma_i, \sigma_j > 0$ จะมี

$$-1 \leq \text{Corr}(R_i, R_j) \leq 1.$$

ประเด็นที่ต้องระวัง

Correlation ต่ำช่วยสร้าง diversification ได้ แต่ correlation เป็นค่าที่ประมาณจากข้อมูลและสามารถเปลี่ยนแปลงอย่างมาก ในช่วงวิกฤต จึงไม่ควรถือว่าเป็นค่าคงที่ถาวร

B.5 ความแปรปรวนของพอร์ต

สำหรับพอร์ตสองสินทรัพย์

$$\sigma_p^2 = w_1^2 \sigma_1^2 + w_2^2 \sigma_2^2 + 2w_1 w_2 \sigma_{12}.$$

กรณี n สินทรัพย์

$$\sigma_p^2 = \sum_{i=1}^n \sum_{j=1}^n w_i w_j \sigma_{ij} = \mathbf{w}^T \Sigma \mathbf{w}.$$

B.6 Sample Mean, Sample Variance และ Sample Covariance

สำหรับข้อมูลผลตอบแทน $R_1, \dots, R_T$ sample mean คือ

$$\bar{R} = \frac{1}{T} \sum_{t=1}^T R_t.$$

sample variance คือ

$$s^2 = \frac{1}{T-1} \sum_{t=1}^T (R_t - \bar{R})^2.$$

sample covariance คือ

$$s_{ij} = \frac{1}{T-1} \sum_{t=1}^T (R_{i,t} - \bar{R}_i)(R_{j,t} - \bar{R}_j).$$

B.7 Normal Distribution

ถ้า

$$R \sim N(\mu, \sigma^2),$$

แล้ว

$$Z = \frac{R - \mu}{\sigma} \sim N(0, 1).$$

Normal distribution มีความสำคัญในฐานะแบบจำลองอ้างอิง แต่ผลตอบแทนจริงอาจมี skewness, fat tails และ volatility clustering

B.8 Lognormal Price Model

ถ้า log return เป็น normal

$$\ln \left(\frac{P_T}{P_0} \right) \sim N(m, s^2),$$

แล้ว P_T มี lognormal distribution และมีค่าเป็นบวกเสมอ

B.9 Skewness และ Kurtosis

Skewness ใช้วัดความไม่สมมาตรของการแจกแจง ส่วน kurtosis ใช้วัดความหนาของส่วนหางเมื่อเทียบกับการแจกแจงอ้างอิง

สำหรับข้อมูลการเงิน คำดังกล่าวมีประโยชน์ในการตรวจว่า mean–variance description เพียงอย่างเดียวอาจไม่เพียงพอหรือไม่

B.10 Quantile

ให้ F_L เป็น CDF ของตัวแปรขาดทุน L quantile ระดับ α นิยามเป็น

$$q_\alpha = \inf\{\ell : F_L(\ell) \geq \alpha\}.$$

แนวคิดนี้เป็นพื้นฐานของ Value at Risk

B.11 Value at Risk และ Expected Shortfall

สำหรับ loss variable L นิยาม

$$\text{VaR}_\alpha(L) = q_\alpha.$$

Expected Shortfall ในกรณีต่อเนื่องเขียนได้เป็น

$$\text{ES}_\alpha(L) = \mathbb{E}[L \mid L \geq \text{VaR}_\alpha(L)].$$

อีกนิยามที่มีความทั่วไปมากกว่าใช้ quantile integral

$$\text{ES}_\alpha(L) = \frac{1}{1-\alpha} \int_\alpha^1 \text{VaR}_u(L) du.$$

ประเด็นที่ต้องระวัง

ต้องตรวจสอบ sign convention ทุกครั้งว่าแบบจำลองนิยาม “ผลตอบแทน” หรือ “ขาดทุน” เพราะ VaR ที่คำนวณจาก return distribution กับ VaR ที่คำนวณจาก loss distribution อาจใช้เครื่องหมายต่างกัน

B.12 Conditional Expectation

ถ้า $\mathcal{F}_t$ แทนข้อมูลที่ทราบ ณ เวลา t ค่าคาดหวังแบบมีเงื่อนไขคือ

$$\mathbb{E}(R_{t+1} \mid \mathcal{F}_t).$$

แนวคิดนี้เป็นสะพานไปสู่การพยากรณ์ factor models, volatility models และ quantitative strategies

B.13 Law of Large Numbers และ Sampling Error

เมื่อขนาดตัวอย่างเพิ่มขึ้น sample mean มีแนวโน้มเข้าใกล้ population mean ภายใต้เงื่อนไขที่เหมาะสม แต่ในข้อมูลตลาดการเงิน observations อาจไม่เป็นอิสระ และ distribution อาจเปลี่ยนตาม regime

ดังนั้นการเพิ่มจำนวนข้อมูลเพียงอย่างเดียว ไม่รับประกันว่าพารามิเตอร์ที่ประมาณจะเสถียรในอนาคต

B.14 สรุป

ภาคผนวกนี้ให้ภาษาความน่าจะเป็นและสถิติพื้นฐาน สำหรับ expected return, variance, covariance, distribution, quantile, VaR และ ES โดยรายละเอียดการประยุกต์ใช้ใน portfolio construction และ risk management อยู่ในบทหลัก

บทที่ C สูตรสำคัญสำหรับการลงทุนและการบริหารพอร์ต

C.1 แนวทางการใช้

ภาคผนวกนี้เป็น *formula reference* สำหรับค้นสูตรอย่างรวดเร็ว รายละเอียดสมมติฐาน การพิสูจน์ การตีความ และข้อจำกัดของแต่ละสูตรให้ย้อนกลับไปยังบทหลัก

C.2 ผลตอบแทน

Simple Return

$$R_t = \frac{P_t - P_{t-1} + D_t}{P_{t-1}}$$

Cumulative Return

$$R_{0:T} = \prod_{t=1}^T (1 + R_t) - 1$$

Log Return

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right)$$

Annualization

ถ้ามี m งวดต่อปี

$$\mu_{\text{ann}} \approx m\bar{R}, \quad \sigma_{\text{ann}} \approx \sqrt{m}\sigma$$

ภายใต้สมมติฐานที่เหมาะสม

C.3 พอร์ตการลงทุน

Portfolio Return

$$R_p = \mathbf{w}^T \mathbf{R}$$

Expected Portfolio Return

$$\mu_p = \mathbf{w}^T \boldsymbol{\mu}$$

Portfolio Variance

$$\sigma_p^2 = \mathbf{w}^T \boldsymbol{\Sigma} \mathbf{w}$$

Portfolio Volatility

$$\sigma_p = \sqrt{\mathbf{w}^T \boldsymbol{\Sigma} \mathbf{w}}$$

C.4 Markowitz Portfolio

Global Minimum-Variance Portfolio

$$\mathbf{w}_{\text{GMV}} = \frac{\boldsymbol{\Sigma}^{-1} \mathbf{1}}{\mathbf{1}^T \boldsymbol{\Sigma}^{-1} \mathbf{1}}$$

กำหนด

$$A = \mathbf{1}^T \boldsymbol{\Sigma}^{-1} \mathbf{1}, \quad B = \mathbf{1}^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}, \quad C = \boldsymbol{\mu}^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu},$$

และ

$$D = AC - B^2$$

พอร์ต minimum variance ที่ให้ผลตอบแทนเป้าหมาย μ^* คือ

$$\mathbf{w}(\mu^*) = \boldsymbol{\Sigma}^{-1} \left[\frac{C - B\mu^*}{D} \mathbf{1} + \frac{A\mu^* - B}{D} \boldsymbol{\mu} \right]$$

C.5 Tangency Portfolio

เมื่อมี risk-free rate r_f และอนุญาตให้ใช้ unconstrained risky-asset weights

$$\mathbf{w}_T = \frac{\Sigma^{-1}(\boldsymbol{\mu} - r_f \mathbf{1})}{\mathbf{1}^T \Sigma^{-1}(\boldsymbol{\mu} - r_f \mathbf{1})}$$

C.6 CAPM และ Beta

Beta

$$\beta_i = \frac{\text{Cov}(R_i, R_M)}{\text{Var}(R_M)}$$

CAPM

$$\mathbb{E}(R_i) = r_f + \beta_i(\mathbb{E}(R_M) - r_f)$$

C.7 Performance Measures

Sharpe Ratio

$$SR_p = \frac{\bar{R}_p - r_f}{\sigma_p}$$

Treynor Ratio

$$T_p = \frac{\bar{R}_p - r_f}{\beta_p}$$

Jensen's Alpha

$$\alpha_p = \bar{R}_p - [r_f + \beta_p(\bar{R}_M - r_f)]$$

Information Ratio

$$IR = \frac{\bar{R}_p - \bar{R}_b}{TE}, \quad TE = SD(R_p - R_b)$$

Sortino Ratio

$$\text{Sortino}_p = \frac{\bar{R}_p - R_{\text{MAR}}}{\text{DownsideDeviation}}$$

C.8 Drawdown

ถ้า

$$W_t$$

คือ wealth index แล้ว

$$DD_t = \frac{W_t - \max_{s \leq t} W_s}{\max_{s \leq t} W_s},$$

และ

$$MDD = \min_t DD_t$$

C.9 Risk Measures

Parametric Normal VaR

สำหรับ loss L ที่ประมาณเป็น normal

$$\text{VaR}_\alpha = \mu_L + z_\alpha \sigma_L$$

ถ้าใช้ return convention ต้องปรับเครื่องหมายให้สอดคล้องกับนิยาม loss

Normal Expected Shortfall

$$\text{ES}_\alpha = \mu_L + \sigma_L \frac{\phi(z_\alpha)}{1 - \alpha}$$

C.10 EWMA Volatility

$$\sigma_t^2 = \lambda \sigma_{t-1}^2 + (1 - \lambda) R_{t-1}^2$$

C.11 Fixed Income Reference

สำหรับ bond ที่มีกระแสเงินสด CF_t

$$P = \sum_{t=1}^n \frac{CF_t}{(1+y)^t}$$

Macaulay duration

$$D_{\text{Mac}} = \frac{\sum_{t=1}^n t PV(CF_t)}{P}$$

Modified duration

$$D_{\text{mod}} = \frac{D_{\text{Mac}}}{1+y}$$

การประมาณการเปลี่ยนแปลงราคาอันดับหนึ่ง

$$\frac{\Delta P}{P} \approx -D_{\text{mod}} \Delta y$$

เมื่อเพิ่ม convexity

$$\frac{\Delta P}{P} \approx -D_{\text{mod}} \Delta y + \frac{1}{2} \mathcal{C} (\Delta y)^2$$

C.12 Rebalancing และ Turnover

นิยามแบบหนึ่งของ turnover คือ

$$\text{Turnover}_t = \frac{1}{2} \sum_{i=1}^n |w_{i,t}^{\text{target}} - w_{i,t}^{\text{pretrade}}|$$

ถ้า cost rate ของสินทรัพย์ i คือ c_i สามารถประมาณ transaction cost เป็น

$$\text{Cost}_t \approx \sum_{i=1}^n c_i |w_{i,t}^{\text{target}} - w_{i,t}^{\text{pretrade}}|$$

C.13 สูตรตรวจสอบหน่วย

ประเด็นที่ต้องระวัง

ก่อนใช้สูตรใดให้ตรวจสอบอย่างน้อย 4 เรื่อง: (1) return เป็น simple หรือ log, (2) อัตราเป็นรายวัน รายเดือน หรือรายปี, (3) ใช้ return หรือ loss convention, และ (4) covariance/volatility ถูก annualize ด้วยฐานเวลาเดียวกัน

บทที่ D อภิธานศัพท์ สัญลักษณ์ และคำย่อ

D.1 บทนำ

ภาคผนวกนี้รวบรวมสัญลักษณ์ คำย่อ และศัพท์สำคัญที่ปรากฏตลอดตำรา เพื่อช่วยให้ผู้อ่านตรวจสอบความหมายได้อย่างรวดเร็ว โดยไม่แทนที่นิยามอย่างเป็นทางการในบทหลัก

D.2 สัญลักษณ์ทางคณิตศาสตร์และการเงิน

สัญลักษณ์	ความหมาย
P_t	ราคาสินทรัพย์ ณ เวลา t
D_t	เงินปันผลหรือ cash distribution ในงวด t
R_t	Simple return ในงวด t
r_t	Log return ในงวด t
μ_i	ผลตอบแทนคาดหวังของสินทรัพย์ i
μ_p	ผลตอบแทนคาดหวังของพอร์ต
σ_i	ส่วนเบี่ยงเบนมาตรฐานของผลตอบแทนสินทรัพย์ i
σ_p	ส่วนเบี่ยงเบนมาตรฐานของผลตอบแทนพอร์ต
σ_{ij}	Covariance ระหว่างผลตอบแทนสินทรัพย์ i และ j
ρ_{ij}	Correlation ระหว่างผลตอบแทนสินทรัพย์ i และ j
w	เวกเตอร์น้ำหนักพอร์ต
w_i	น้ำหนักของสินทรัพย์ i ในพอร์ต
μ	เวกเตอร์ผลตอบแทนคาดหวัง
Σ	Covariance matrix
$\mathbf{1}$	เวกเตอร์ที่ทุกองค์ประกอบเท่ากับหนึ่ง
r_f	อัตราผลตอบแทนไร้ความเสี่ยง
β_i	Beta ของสินทรัพย์ i เทียบกับตลาด
α_p	Jensen's alpha หรือ intercept ตามบริบท

สัญลักษณ์	ความหมาย
R_M	ผลตอบแทนของ market portfolio หรือ market benchmark
R_b	ผลตอบแทน benchmark
VaR_α	Value at Risk ที่ระดับความเชื่อมั่น α
ES_α	Expected Shortfall ที่ระดับความเชื่อมั่น α
λ	Decay factor ใน EWMA หรือ multiplier ตามบริบท
y	Yield ของตราสารหนี้
D_{Mac}	Macaulay duration
D_{mod}	Modified duration
$\mathcal{C}$	Convexity ตามนิยามที่ใช้ในบทความตราสารหนี้

D.3 คำย่อสำคัญ

คำย่อ	ความหมาย
APR	Annual Percentage Return หรือ Annualized Return ตามบริบท
CAPM	Capital Asset Pricing Model
CML	Capital Market Line
CVaR	Conditional Value at Risk; ในหลายบริบทใช้ใกล้เคียง Expected Shortfall
ETF	Exchange-Traded Fund
ES	Expected Shortfall
EWMA	Exponentially Weighted Moving Average
GMV	Global Minimum Variance
IR	Information Ratio
MDD	Maximum Drawdown
MPT	Modern Portfolio Theory
NAV	Net Asset Value
PSD	Positive Semidefinite
SML	Security Market Line
SR	Sharpe Ratio

คำย่อ	ความหมาย
TE	Tracking Error
VaR	Value at Risk

D.4 ศัพท์ไทย-อังกฤษที่ใช้ตลอดเล่ม

คำไทย	English term
การจัดสรรสินทรัพย์	Asset Allocation
การกระจายความเสี่ยง	Diversification
การปรับสมดุลพอร์ต	Rebalancing
การประเมินผลการบริหารพอร์ต	Portfolio Performance Evaluation
ผลตอบแทนคาดหวัง	Expected Return
ความแปรปรวน	Variance
ส่วนเบี่ยงเบนมาตรฐาน	Standard Deviation
ความแปรปรวนร่วม	Covariance
สัมประสิทธิ์สหสัมพันธ์	Correlation Coefficient
พอร์ตความแปรปรวนต่ำสุด	Minimum-Variance Portfolio
พอร์ตสัมผัส	Tangency Portfolio
เส้นขอบเขตประสิทธิภาพ	Efficient Frontier
ความเสี่ยงเชิงระบบ	Systematic Risk
ความเสี่ยงเฉพาะตัว	Idiosyncratic Risk
อัตราส่วนชาร์ป	Sharpe Ratio
ค่าความเสี่ยง	Value at Risk
ค่าคาดหวังของความเสียหายส่วนทาง	Expected Shortfall
การลดลงจากจุดสูงสุด	Drawdown
ต้นทุนธุรกรรม	Transaction Cost
ความคลาดเคลื่อนจากดัชนีอ้างอิง	Tracking Error

D.5 หลักการใช้คำและสัญลักษณ์

ประเด็นที่ต้องระวัง

สัญลักษณ์เดียวกันอาจมีความหมายแตกต่างกันในตำราการเงินแต่ละเล่ม การใช้สูตรจากแหล่งภายนอกจึงควรตรวจนियาม หน่วยเวลา sign convention และ normalization ก่อนนำมาใช้ร่วมกับสูตรในตำราเล่มนี้

D.6 หมายเหตุสำหรับการอ่านร่วมกับบทหลัก

อภิธานศัพท์นี้ตั้งใจให้เป็นจุดค้นหอย่างรวดเร็ว หากต้องการนิยามทางคณิตศาสตร์ที่ครบถ้วน สมมติฐาน การพิสูจน์ ตัวอย่าง หรือข้อจำกัด ให้ย้อนกลับไปยังบทที่แนะนำแนวคิดนั้นเป็นครั้งแรก