

[참고] Sectoral Price Data and Models of Price Setting

권이태, June 10, 2025

1 Econometric Framework

□ 이 논문에서는 아래의 **동적요인모형**(dynamic factor model)을 고려한다.

$$\pi_{nt} = \mu_n + A_n(L)u_t + B_n(L)v_{nt}$$

- π_{nt} 는 n 번째 품목의 시점 t 에서의 인플레이션율(MoM)이다.
- μ_n 은 상수항이다.
- u_t 는 분산이 일정한 정규분포를 따르는 백색잡음과정으로, 관찰 불가능한 인자를 묘사한다. 모든 품목은 동일한 u_t 를 공유하나, 서로 다른 가격 조정 행태는 $A_n(L)$ 으로써 반영된다.
- v_{nt} 는 마찬가지로 분산이 일정한 정규분포를 따르는 백색잡음과정으로, u_t 혹은 다른 $v_{n't}$ 와 독립이다. 이는 계열특이적인 변동을 담당한다.

□ 이를 바탕으로, 인플레이션율의 **공통부문**(aggregate component) π_{nt}^A 를 정의할 수 있다.

$$\pi_{nt}^A = A_n(L)u_t$$

□ 같은 이유로 인플레이션율의 계열특이부문 π_{nt}^S 는 아래와 같이 정의된다.

$$\pi_{nt}^S = B_n(L)v_{nt}$$

- 추정할 변수의 개수를 줄이기 위하여, 적절한 변환을 통하여

$$\pi_{nt}^S = C_n(L)\pi_{nt}^A + B_n(0)v_{nt}$$

처럼 계열특이부문이 AR 과정을 따르는 적절한 지속성을 가지고 있다고 바라보는 것도 가능하다.

□ 추정 전 표준화를 통해 $\tilde{\pi}_{nt} = \frac{\pi_{nt} - \mu_n}{\sigma_{\pi_n}}$ 을 정의하고, 이 평균이 0이고 분산이 1인 시계열이

$$\tilde{\pi}_{nt} = a_n(L)u_t + b_n(L)v_{nt}$$

로써 결정된다고 가정한다. 이 경우 충격반응함수를 비교하기 간편해지는 장점이 있다.

□ (**상태공간모형**) 이제 이러한 동적요인모형을 아래처럼 둘로 구분하자.

$$\begin{cases} \tilde{\pi}_{nt} = a_n(L)u_t + \tilde{\pi}_{nt}^S & \text{measurement equation} \\ \tilde{\pi}_{nt}^S = c_n(L)\tilde{\pi}_{nt}^S + \epsilon_{nt} & \text{transition equation} \end{cases}$$

이는 상태공간모형의 일종으로, 관측되지 않은 계열특이부문이 AR 모형으로써 결정되는 전이방정식과 그것이 공통부문과 합쳐서 관측되는 인플레이션율이 나타나는 측량방정식으로 구분된다.

- 이때 $u_t = (u_{1t}, \dots, u_{Kt})^\top \sim N(0, I_K)$, $\epsilon_{nt} \sim N(0, \sigma_n^2)$ 이다.
- 편의상 $c_n(0) = 0$ 으로 한다.

□ N 개의 부문에 대한 측량방정식을 쌓으면, 벡터로 된 방정식

$$\tilde{\pi}_t = a(L)u_t + \tilde{\pi}_t^S$$

를 얻을 수 있다. 이때 $a(L)$ 의 각 lag에 해당하는 행렬은 $N \times K$ 행렬인데, 인자분석에서는 $N \gg K$ 이므로 $a_0 = a(0)$ 으로부터 앞의 K 개 열을 골라 $K \times K$ 행렬 $\tilde{a}_0$ 을 만들 수 있다. 이 $\tilde{a}_0$ 가 주대각선원소가 양인 하삼각행렬이라고 가정하자. 이는 u_t 를 유일하게 결정해주는 일종의 제약이자 인자회전 방법이라 취급할 수 있다. $a(L)$ 은 일반적인 인자분석에서의 팩터 로딩의 기능을 하기 때문이다.

□ (MCMC 1) 인자 $\{u_t\}$ 와 모수 $a_n(L), c_n(L), \sigma_n$ 에 대한 사후분포로부터 표본을 추출하기 위해서는 **Metropolis-Hastings** 알고리즘이 이용되었다. 이를 위해 아래의 과정을 따라가보자.

– $\tilde{\pi}_{nt}^* = (1 - c_n(L))\tilde{\pi}_{nt}$ 를 정의하면,

$$\begin{aligned}\tilde{\pi}_{nt}^* &= (1 - c_n(L))\tilde{\pi}_{nt} \\ &= (1 - c_n(L))(a_n(L)u_t + \tilde{\pi}_{nt}^S) \\ &:= g_n(L)u_t + \epsilon_{nt}\end{aligned}$$

를 얻는다. 이를 벡터화하면 $F_t = (u_t, u_{t-1}, \dots)^\top$ 에 대하여

$$\tilde{\pi}_t^* = GF_t + \epsilon_t$$

로 적는 것이 가능하다. 이때 $a_n(L), c_n(L)$ 이 각각 M, S 시차까지 포함하고 있다고 하면 G 는 $N \times K(M + S + 1)$ 행렬이 된다. ϵ_t 의 분산은 R 이라 하자.

– F_t 는

$$F_{t+1} = JF_t + \tilde{u}_{t+1}$$

을 따라 결정되며, J 는

$$J = \begin{pmatrix} 0_{K \times K} & 0_{K \times K(M+S)} \\ I_{K(M+S)} & 0_{K(M+S) \times K} \end{pmatrix}$$

인 $K(M + S + 1) \times K(M + S + 1)$ 행렬이며 $\tilde{u}_{t+1} = (u_{t+1}, 0_{K(M+S)})^\top$ 이다. $\tilde{u}_{t+1}$ 의 분산은 $Q = \text{diag}(1_K, 0_{K(M+S)})$ 라고 하자.

– 그 다음 여기에 **Kalman filter**를 아래처럼 적용한다.

$$\begin{aligned}F_{t|t} &= F_{t|t-1} + P_{t|t-1}G^\top(GP_{t|t-1}G^\top + R)^{-1}(\tilde{\pi}_t^* - GF_{t|t-1}) \\ P_{t|t} &= P_{t|t-1} - P_{t|t-1}G^\top(GP_{t|t-1}G^\top + R)^{-1}GP_{t|t-1} \\ F_{t+1|t} &= JF_{t|t} \\ P_{t+1|t} &= JP_{t|t}J^\top + Q\end{aligned}$$

이때 초깃값은 $F_{1|0} = 0, \text{vec}(P_{1|0}) = (I_{K(M+S+1)} - (J \otimes J))^{-1}\text{vec}(Q)$ 으로 설정한다.

– 그 다음, F_T 의 분포를 $N(F_{T|T}, P_{T|T})$ 으로 생각하고 새롭게 팩터 F_T 를 추출한다. $t = T - 1, T - 2, \dots, 1$ 에 대해서는,

$$\begin{aligned}F_{t|t, F_{t+1}} &= F_{t|t} + P_{t|t}J^\top P_{t+1|t}^{-1}(F_{t+1} - F_{t+1|t}) \\ P_{t|t, F_{t+1}} &= P_{t|t} - P_{t|t}J^\top P_{t+1|t}^{-1}JP_{t|t}\end{aligned}$$

을 정의하고 $N(F_{t|t, F_{t+1}}, P_{t|t, F_{t+1}})$ 으로부터 새롭게 팩터 F_t 를 추출한다.

- 프랙티컬하게는 Q 가 비가역임에 따라 문제가 발생할 수 있는데, 이 논문의 모형을 따르면 사실 $F_{t|t, F_{t+1}} = F_{t|t}, P_{t|t, F_{t+1}} = P_{t|t}$ 이므로 해당 사실을 이용해도 괜찮다.
- 위의 과정은 모수들이 주어졌다는 가정 하에, 그에 조건부로 팩터를 샘플링하는 과정을 묘사한다.

□ (MCMC 2) 그 다음으로는 팩터들이 주어져 있을 때, 그를 기반으로 모수들을 샘플링(정확히는 팩터에 대한 조건부 사후분포를 근사)하는 방법을 알아본다.

- 적절히 방정식들을 쌓아 우리의 모형을 아래처럼 적을 수 있다(편의상 n 은 생략).

$$\begin{aligned}\tilde{\Pi}_n &= X\theta_+ \tilde{\Pi}^S \\ \tilde{\Pi}^S &= \tilde{X}\phi + \epsilon\end{aligned}$$

이때 $X, \tilde{X}$ 는 각각 $u_t, \tilde{\pi}_t^S$ 들의 과거 시계열들을 모아둔 행렬이며, θ, ϕ 는 각각 상응하는 $a_n(L), c_n(L)$ 들을 모아둔 행렬이다.

- $\phi = (\phi_1, \dots, \phi_S)^\top = (\tilde{\phi}, \phi_S)^\top$ 으로 쓰고 $\Phi = \begin{pmatrix} \tilde{\phi}^\top & \phi_S \\ I_{S-1} & 0_{S-1} \end{pmatrix}$ 으로 정의하면 θ, ϕ, σ^2 의 사전분포는 아래처럼 둔다.

$$[\theta, \phi, \sigma^2] = [\theta][\phi][\sigma^2] = N(\theta_0, \Theta_0^{-1})[N(\phi_0, \Phi_0^{-1})I(\Phi)]IG(\nu_0/2, \delta_0/2)$$

이때 $I(\Phi)$ 는 Φ 의 모든 고유값이 단위원 안에 있는지를 표현하는 지시함수이다. prior에 포함되는 모수들의 경우, Minnesota prior를 따라 결정되었다.

- 세 변수의 사후분포는 아래와 같이 주어진다.

$$\begin{aligned}\theta|\phi, \sigma^2 &\sim N(\Theta_T^{-1}(\Theta_0\theta_0 + \sigma^{-2}X^{*\top}\tilde{\Pi}^\top), \Theta_T^{-1}) \\ \sigma^2|\phi, \theta &\sim IG\left(\frac{\nu_0 + T}{2}, \frac{\delta_0 + (\tilde{\Pi}^* - X^*\theta)^\top(\tilde{\Pi}^* - X^*\theta)}{2}\right) \\ \phi|\theta, \sigma^2 &\propto \Psi(\phi) \times N(\Phi_T^{-1}(\Phi_0\phi_0 + \sigma^{-2}E^\top e), \Phi_T^{-1})I(\Phi)\end{aligned}$$

자세한 디테일은 적지 않으나, 이로써 세 모수의 다른 두 모수에 대한 조건부 사후분포 형태를 알 수 있다.

- θ, σ^2 의 사후분포는 일반적인 형태이기 때문에 Gibbs sampler를 이용한 추출이 가능하지만, ϕ 는 그렇지 않다. 따라서 이 논문에서는 Matropolis-Hastings 알고리즘을 이용하여, 각 반복 j 에서 후보추출 ϕ^* 를 정규분포 $N(\Phi_T^{-1}(\Phi_0\phi_0 + \sigma^{-2}E^\top e), \Phi_T^{-1})I(\Phi)$ 를 따라 추출한 뒤,

$$\rho = \min\left(\frac{\Psi(\phi^*)}{\Phi(\phi^{j-1})}, 1\right)$$


의 확률로 $\phi^j = \phi^*$, $1 - \rho$ 의 확률로 $\phi^j = \phi^{j-1}$ 로 설정한다.

□ (MCMC 3) 종합하면, 팩터와 모수의 추정에는 아래 과정을 통해 이루어진다.

1. 먼저 K 개의 팩터를 주성분분석을 통해 추정
2. 해당 팩터를 기반으로 모수의 초기 회귀추정값 $\{\theta_n, \phi_n, \sigma_n^2\}^{j=0}$ 을 계산
3. 모수 $\{\theta_n, \phi_n, \sigma_n^2\}^{j-1}$ 들을 기반으로, 팩터 $\{u_t\}^j$ 들을 계산
4. $\{u_t\}^j$ 에 조건부로, 모수 $\{\theta_n, \phi_n, \sigma_n^2\}^j$ 를 추출($\theta_n^j|\{\phi_n, \sigma_n^2\}^{j-1} \rightarrow \sigma_n^{2j}|\theta_n^j, \phi_n^{j-1} \rightarrow \phi_n^j|\{\theta_n, \sigma_n^2\}^j$ 순)
5. $j = 1, \dots, 20000$ 에 대해 반복하고, 초기 5000개를 burn-in. 수렴성은 Raftery-Lewis 측도와 Geweke 측도를 통해 판단

2 Responses of Sectoral Price Indexes

- 벤치마크로 사용한 스펙은 u_t 가 스칼라이고, $C_n(L)$ 의 최대 시차는 6으로 설정한 모형
 - out-of-sample 예측이 다른 스펙이나 전통적인 자기회귀모형들에 비해 우수하였기 때문.
 - 다른 스펙의 결과는 강건성 체크를 위해 사용되었으나(6장), 여기에서는 생략
- 각 품목의 인플레이션에 나타나는 변동은 대부분 계열특이부문의 충격으로 인함(중위: 90%, 하위 5%: 79%, 상위 5%: 95%)
- 충격반응함수로 확인해 보면, 계열특이부문의 장기반응은 충격 이후 즉각적으로 발생하며, 계속 지속되는 것을 확인할 수 있다.
 - 반면 공통부문의 장기반응 중 약 15%만이 즉각적으로 발생하며, 계속적으로 그 반응이 증가해 오랜 시간 후 장기반응에 도달함을 수 있다. 즉 비교적 반응이 느리다.
 - 이는 근본적으로 계열특이부문의 충격은 백색잡음과정인 반면, 공통부문의 충격은 거시경제와 관련되며 0.35의 양의 시차상관이 존재하기 때문일 수 있다.



3 Models of Price Setting

- 계량적인 방법으로써 얻어낸 결과가 어떠한 모형과 일치하는지 확인하기 위해, 네 개의 모형
 1. Calvo model
 2. menu cost model
 3. sticky-information model
 4. rational-inattention model

을 고려하고 이들 모형 하에서 어떠한 충격반응이 나타나야 하는지 확인한다.

- 특히 다양한 품목이 존재하는 경제 하에서의 모형을 다룬다.

□ 경제에서 특정 품목 n 의 생산 기업 i 는 차별화된 상품 i 를 생산하며, 그 수요는

$$C_{int} = \left(\frac{P_{int}}{P_{nt}} \right)^{-\theta} \left(\frac{P_{nt}}{P_t} \right)^{-\eta} C_t$$

으로 주어진다. 이때 $\theta, \eta > 1$ 는 각각 상품 i , 품목 n 의 전체 품목/소비재 사이에서의 대체탄력성이 된다.

– 각 품목과 전체 소비재에 대하여, 가격 수준의 합산은

$$P_{nt} = \left(\int_0^1 P_{int}^{1-\theta} di \right)^{\frac{1}{1-\theta}}$$

$$P_t = \left(\int_0^1 P_{nt}^{1-\eta} dn \right)^{\frac{1}{1-\eta}}$$

– 산출은 총요소생산성 Z_{nt} 와 노동투입 L_{int} , 탄력성 α 에 대하여

$$Y_{int} = Z_{nt} L_{int}^\alpha$$

로 결정되며, 시장청산을 위해 $Y_{int} = C_{int}$ 이다.

– 시점 t 에서의 실질임금은 $w(C_t)$ 이며, w 는 강증가하는 함수이다.

– 이를 바탕으로 각 기업의 실질이윤을 최대화하는 최적화 문제를 풀면, 근사적으로

$$p_{int}^\diamond = p_t + \underbrace{\frac{w + \frac{1-\alpha}{\alpha}}{1 + \frac{1-\alpha}{\alpha}\theta} C_t + \frac{\frac{1-\alpha}{\alpha}(\theta - \eta)}{1 + \frac{1-\alpha}{\alpha}\theta} \hat{p}_{nt}^A}_{p_{int}^{A\diamond}} + \underbrace{\frac{\frac{1-\alpha}{\alpha}(\theta - \eta)}{1 + \frac{1-\alpha}{\alpha}\theta} \hat{p}_{nt}^S - \frac{\frac{1}{\alpha}}{1 + \frac{1-\alpha}{\alpha}\theta} z_{nt}}_{p_{int}^{S\diamond}}$$

을 얻는다. 이때 $\hat{p}_{nt} = \ln(P_{nt}/P_t)$ 이다.

– 만약 기업이 최적 가격 $p_{int}^\diamond$ 를 달성하지 못함에 따른 이윤 손실은, 합성소비 $\bar{C}$ 에 대하여

$$\frac{\bar{C}(\theta - 1)(1 + \frac{1-\alpha}{\alpha}\theta)}{2} (p_{int} - p_{int}^\diamond)^2$$

으로 괴리의 제공에 비례하게 나타난다.

– 로그선형화하면 가격 수준의 합산 역시

$$p_{nt} = \int_0^1 p_{int} di$$

$$p_t = \int_0^1 p_{nt} dn$$

으로 적을 수 있다.

3.1 Calvo Model

□ Calvo model에서는 정해진 확률로 기업이 가격을 조정할 수 있다고 가정한다 λ_n 이 품목 n 이 가격을 조정할 수 있는 확률이라고 가정하면, 기업은 아래의 기대손실을 최소화하기 위한 p_{int} 를 결정한다.

$$\mathbb{E} \left[\sum_{s=t}^{\infty} [(1 - \lambda_n)\beta]^{s-t} \frac{\bar{C}(\theta - 1)(1 + \frac{1-\alpha}{\alpha}\theta)}{2} (p_{int} - p_{ins}^\diamond)^2 \middle| \mathcal{I}_t \right]$$

- 그 결과로 나타나는 최적 가격은

$$p_{int}^* = (1 - (1 - \lambda_n)\beta)\mathbb{E}\left[\sum_{s=t}^{\infty}[(1 - \lambda_n)\beta]^{s-t}p_{ins}^{\diamond}\middle|\mathcal{I}_t\right]$$

이다.

- 이로써 각 부문에 대한 가격수준은

$$p_{nt} = (1 - \lambda_n)p_{n,t-1} + \lambda_n p_{int}^*$$

으로 일정 수준의 경직성을 보인다.

- 이러한 가정 하에서, 이 논문은 만약 충격에 대한 $p_{int}^{\diamond}$ 의 충격반응이 충격 직후

$$\frac{\frac{1}{\lambda_n} - (1 - \lambda_n)\beta}{1 - (1 - \lambda_n)\beta}x$$

이고 이후 x 라면, 실제 가격수준의 충격반응은 x 와 같은 수준으로 유지됨을 보였다. 또한 가격수준이 계열특이충격에 충격시점부터 일정한 수준의 반응을 보이기 위해서는, $p_{int}^{\diamond}$ 의 충격반응함수가 가질 수 있는 경로는 위의 것이 유일하다.

- 품목에 대한 생산성에 대해서는

$$z_{nt} = -\frac{1 + \frac{1-\alpha}{\alpha}\theta}{\frac{1}{\alpha}}\left(p_{nt}^{\diamond S} - \frac{\frac{1-\alpha}{\alpha}(\theta - \eta)}{1 + \frac{1-\alpha}{\alpha}\theta}\hat{p}_{nt}^S\right)$$

을 얻을 수 있으므로, 여기에 앞선 p_{nt} 와 $p_{int}^{\diamond}$ 에 대한 충격반응함수를 대입하면 생산성의 충격반응함수를 얻는 것도 가능하다.

- 이러한 결과를 종합하면, Calvo model에 극단적인 추가 가정($\lambda_n \approx 1$)을 세우지 않고서는 실증적 결과와 맞다고 해석하기는 무리가 있다. 반응이 충격 당시에 매우 크게 나타나고, 그 다음 기에 바로 정상 수준으로 돌아온 뒤 유지된다는 것은 충격반응함수에 너무 큰 하향 점프(λ_n^{-2} 수준의)를 만들기 때문이다.

3.2 Menu Cost Model

- 비교적 계열특이충격에는 빠르게 반응하고, 공통부문의 충격에는 느리게 반응한다는 점에서 메뉴비용 모형을 고려하는 것이 자연스러움
 - 그러나 메뉴비용 모형에서는 기업이 가격을 조정할 때 가격 조정을 촉발한 부문이 무엇인지에 관계없이 동일한 방식으로 가격을 조정하기 때문에, 계열특이부문의 충격이 잦고 그에 빠르게 반응한다면 공통부문의 충격에도 빠르게 반응해야 함
 - 실증 결과와 일치시키기 위해서는 계열특이충격이 잦지 않아야 하는데, 몇몇 품목을 제외하고는 계열특이충격이 Gaussian이기에 충격은 비교적 잦게 발생한다는 점에서 메뉴비용 역시 적절하지 못함

3.3 Sticky-Information Model

- 기업은 일정 확률로 가격 결정 계획을 조정할 수 있으며, Calvo model과 달리 당기의 가격이 아니라 가격 경로를 설정할 수 있다는 차이점이 있음

- 기업의 가격결정경로는 아래 손실함수를 최소화하도록 결정된다.

$$\mathbb{E} \left[\sum_{s=t}^{\infty} \beta^{s-t} \frac{\bar{C}(\theta-1)(1+\frac{1-\alpha}{\alpha}\theta)}{2} (p_{ins} - p_{ins}^{\diamond})^2 \middle| \mathcal{I}_t \right]$$

- $p_{int}^{\diamond} = p_{nt}^{\diamond A} + p_{nt}^{\diamond S}$ 이며, 기업의 가격결정은

$$p_{ins|t} = \mathbb{E}[p_{ins}^{\diamond} | \mathcal{I}_t]$$

으로 이루어지고 이에 따른 당기의 가격수준은

$$p_{nt} = \sum_{j=0}^{\infty} \lambda_n (1 - \lambda_n)^j \mathbb{E}[p_{int}^{\diamond} | \mathcal{I}_{t-j}]$$

으로 나타난다.

- Calvo model과 비교하면, λ_n 의 비율로 가격을 조정하는 기업뿐만이 아니라 $1 - \lambda_n$ 의 비율로 과거에 정한 가격경로를 이어오고 있는 기업들에 의해서도 인플레이션이 유래되는 차이점이 있다.
- 만약 가격수준에 대한 충격반응이 모든 기에서 x 로 유지되려면, sticky-information 모형에서는 $p_{int}^{\diamond}$ 에 대한 충격반응이 τ 기 이후

$$\frac{1}{1 - (1 - \lambda_n)^{\tau+1}} x$$

의 형태로 나타나야 한다.

- Calvo model과 마찬가지로, 이러한 형태의 충격반응 역시 실증 결과와 매칭시키기에는 무리가 있다. 역시 $\lambda_n \approx 1$ 이어야만 한다.

3.4 Rational-Inattention Model

- 기업이 공통부문과 계열특이부문에 대한 정보를 완전히 가지고 있지 못하고, 적절한 수준의 집중을 통해 불완전한 정보를 얻어 가격을 결정
- 시점 0에서, 기업이 직면하는 손실최소화 문제는

$$\min_{(\sigma_{\epsilon}, \sigma_{\psi}) \in \mathbb{R}_+^2} \mathbb{E} \left[\sum_{t=1}^{\infty} \beta^t \frac{\bar{C}(\theta-1)(1+\frac{1-\alpha}{\alpha}\theta)}{2} (p_{int} - p_{int}^{\diamond})^2 \right]$$

이며, 제약조건은 아래와 같다.

$$\begin{aligned} p_{int}^{\diamond} &= p_{int}^{\diamond A} + p_{int}^{\diamond S} \\ p_{int}^{\diamond A} &= p_{in,t-1}^{\diamond A} + \sigma_A u_t \\ p_{int}^{\diamond S} &= p_{in,t-1}^{\diamond S} + \sigma_S v_{nt} \end{aligned}$$

- 이때 기업의 최적가격은

$$p_{int} = \mathbb{E}[p_{int}^{\diamond} | s_{in}^t]$$

로, $s_{in}^t = (s_{in0}, \dots, s_{int})$ 로 정책결정자가 제시하는 모든 신호열이다.

- 신호열은 아래처럼 $\sigma_{\epsilon}, \sigma_{\psi}$ 가 작을수록 실제 정보 $p_{int}^{\diamond}$ 를 잘 복원해낼 수 있게 주어진다.

$$s_{int} = \begin{pmatrix} s_{int}^A \\ s_{int}^S \end{pmatrix} = \begin{pmatrix} p_{int}^{\diamond A} \\ p_{int}^{\diamond S} \end{pmatrix} + \begin{pmatrix} \sigma_{\epsilon} \epsilon_{int} \\ \sigma_{\psi} \psi_{int} \end{pmatrix}$$

□ 기업이 가지고 있는 정보에 대한 제약은 아래처럼 쓸 수 있다.

$$\underbrace{H(p_{int}^{\diamond A}|s_{in}^{t-1}) - H(p_{int}^{\diamond A}|s_{in}^t)}_{\kappa^A} + \underbrace{H(p_{int}^{\diamond S}|s_{in}^{t-1}) - H(p_{int}^{\diamond S}|s_{in}^t)}_{\kappa^S} \leq \kappa$$

즉 새로운 신호를 받음에 따라 $p_{int}^{\diamond A}, p_{int}^{\diamond S}$ 에 대해 얻게 되는 정보량은 κ 로 캡이 걸려 있다.

- 기업은 κ^A, κ^S 에의 적절한 할당을 통해 각각에 대한 대략의 정보를 얻고, 그를 바탕으로 가격 결정을 해야만 한다.
- 이러한 제약은 기업에게 사용하는 정보량에 따른 비용함수 $c(\kappa) = \phi\kappa$ 를 추가적인 손실로 뒀으로써 확인될 수 있고, 그것이 동일하다면 손실함수에 단순히 $\frac{\beta}{1-\beta}c(\kappa)$ 를 더하면 된다.

□ 이 경우, 가격결정 행태는 아래의 식을 따름이 알려져 있다.

$$\begin{aligned} p_{int}^{\diamond} - p_{int} &= \sum_{l=0}^{\infty} \left[(2^{-2\kappa^A})^{l+1} \sigma_A u_{t-l} - (2^{-2\kappa^A})^l (2^{-\kappa^A}) \sigma_A \epsilon_{in,t-1} \right] \\ &+ \sum_{l=0}^{\infty} \left[(2^{-2\kappa^S})^{l+1} \sigma_S v_{n,t-l} - (2^{-2\kappa^S})^l (2^{-\kappa^S}) \sigma_S \psi_{in,t-1} \right] \end{aligned}$$

- 이 식을 들여다 보면, κ^S 가 κ^A 보다 더 높은 경우, 공통부문의 충격보다 계열특이부문의 충격에 더 빠르게 반응하게 됨을 알 수 있다.
- κ^A, κ^S 의 배정에 있어서는,

$$\frac{2^{\kappa^S} - 2^{-\kappa^S}}{2^{\kappa^A} - 2^{-\kappa^A}} = \frac{\sigma_S}{\sigma_A}$$

가 성립한다. 즉 변동성이 더 높은 시계열에 더 많은 관심을 기울이게 되며, 더 빠르게 반응한다.

4 Cross-Sectional Regression Analysis

- Calvo model에 따르면, 충격에 반응하는 속도가 빠른 것은 곧 가격 조정이 잦음을 의미한다. 분석 결과 공통부문 충격에 반응하는 속도와 가격 조정 빈도 사이에는 양의 관계가 있는 것으로 나타났지만, 계열특이부문 충격에 반응하는 속도와 가격 조정 빈도 사이에는 명확한 관계가 관찰되지 않았다.
- rational-inattention model에 따르면, 충격의 변동성과 가격 조정 속도는 비례한다. 이에 일치하게, 횡단면 분석 결과 충격에 반응하는 속도와 충격의 변동성은 공통부문과 계열특이부문 모두에서 양의 상관관계를 보였다.
- menu cost model에 따르면, 가격 조정 빈도가 높은 기업은 더 높은 변동성의 충격에 노출될 가능성이 크다. 또한 이는 정상 상태에서의 더 높은 인플레이션율과도 연관된다. 그러나 횡단면 분석 결과 명확한 상관관계는 관찰되지 않았다.

References

- [1] B. Maćkowiak, E. Moench, and M. Wiederholt, “Sectoral price data and models of price setting,” *Journal of Monetary Economics*, vol. 56, pp. S78–S99, 2009.