

결정적 및 확률적 성분과 수준변수를 활용한 SMP 예측 성과 비교

성신여대 경영학과 이현석

연구의 배경 및 목적

가격의 성분 분해

- **가격 = 결정적(deterministic) 성분 + 확률적(stochastic) 성분**
 - 결정적 성분: 장기 추세 및 캘린더 효과
 - 확률적 성분: 단기적 변동성
- **성분 분해의 장점: 정교한 예측이 가능하고, 가격의 분포에 대한 대응 전략 수립이 용이하다.**
 - 가격에 영향을 미치는 요인을 구분할 수 있다.
 - 각 요인의 장기 및 단기 영향을 추정할 수 있으므로 정교한 예측이 가능하다.
 - 가격의 각 성분에 따른 가격 대응 전략을 수립할 수 있다.
- **성분 분해의 한계: 분석 모형 및 분석 과정이 복잡하다.**
 - 결정적 성분 중 장기 추세 요인도 시간에 따라 변하므로 모형의 안정성 유지가 어렵다.
 - 확률적 성분은 여전히 불확실성을 갖고 있어 예측 정확성이 떨어질 수 있다.

연구의 목적

- **수준변수와 성분 분해에 의한 예측 성능을 비교한다.**
 - 분석 대상 가격: 계통한계가격(SMP; System Marginal Price)
- **관련 변수의 영향, 통계적 가정의 성립 여부, 모형의 설명력 등 다양한 측면을 고려한 분석을 수행하였다.**
 - 공학 측면의 연구는 매우 많은 모형을 사용하여 성과를 비교하고 있으나 모형의 유효성 등에 대한 검토가 부족하다.

SMP의 결정

결정 과정

- 전력거래소(KPX; Korea Power Exchange)는 다음 날의 시간별 전력 수요를 예측한 후, 각 시간별 해당 발전 용량을 충족시키는 발전 사업자를 선택한다.
 - 발전 사업자의 변동비용이 낮은 순으로 발전 사업자를 선택한다.
 - 한국의 발전 사업자는 크게 원자력, 석탄 및 화력, 중유, LNG를 사용하는 사업자로 나눌 수 있다.
 - 발전 비용은 원자력, 석탄 및 화력, 중유, LNG 순으로 상승한다.
- 선택된 시간별 발전 사업자 중 가장 높은 발전 비용을 갖는 사업자에게 지급하는 발전 가격이 SMP이다.
 - 발전 비용이 낮은 사업자도 모두 동일한 발전 가격을 받는다.
 - 예: 가장 비싼 발전 비용을 갖는 LNG 사업자가 해당 시간의 최종 발전 사업자로 선택되면 그 보다 낮은 발전 비용을 갖는 사업자도 동일한 가격을 받는다.

결정 요인

- SMP는 전력 수요와 발전 비용의 두 가지 요인에 의해 결정된다.
 - 전력 수요: 계절적 영향과 휴일 여부, 일중 등의 캘린더 효과를 갖는다.
 - 발전 비용: 전력 수요가 높더라도 LNG나 중유와 같은 석유 제품의 수요가 적은 여름에는 겨울에 비해 SMP가 하락한다.
- 전력 수요와 발전 비용은 장기 추세, 계절적 요인, 단기 변동성을 모두 갖고 있다.

전기가격 예측 기존 연구

수준변수를 사용한 예측:

▪ 전통적 통계 모형 vs. 머신 러닝

- Castelli, Groznik & Popovič(2020): 기후 조건, 원유 가격, 탄소배출권 가격 등 다양한 변수를 고려한 머신 러닝 기법 사용
- Lago, Marcjasz, Schutter & Weron(2021): 머신 러닝이 가장 높은 정확성을 갖고 있음을 제시
- Lehna, Scheller & Herwartz(2022): LSTM과 VAR 모형을 결합하는 경우 예측 성능이 개선됨을 보임
- Kapoor & Wichitaksorn(2023): GARCH, SV와 같은 전통적 통계 모형이 LSTM, GRU와 같은 딥러닝 알고리즘에 비해 우수한 예측 성능을 갖고 있음을 제시

성분 분해를 이용한 예측:

▪ 결정적 성분 예측 방법

- Weron(2014): 회귀모형
- Shah, Bibi, Ali, Wang & Yue(2020): 선형 회귀 모형과 스플라인 함수
- Iftikhar, Turpo-Chaparro, Rodrigues and López-Gonzales(2023): 스플라인 분해, 자기회귀(AR), 비모수 자기회귀(NPAR), ARMA 등

▪ 확률적 성분 예측 방법

- Escribano, Pena & Villaplana(2011): GARCH, Jump 모형
- Weron(2014): 점프모형
- Shah, Bibi, Ali, Wang & Yue(2020), Jan, Shah & Ali(2022): AR, NPAR, 함수적 자기회귀(FAR)
 - FAR이 가장 높은 예측력을 갖고 있음을 보여줌

예측 성과 평가 단계

단계 1: SMP 관련 변수의 특성 분석

- SMP와 관련이 있는 에너지 가격, 기후, 캘린더 효과 등의 변수 선택
- 각 변수의 기초통계량, 상관관계, 안정성 등에 대한 검토

단계 2: SMP를 결정적 성분과 확률적 성분으로 분해

- SMP의 성분 분해

단계 3: 수준변수와 성분 분해에 의한 SMP 모형별 예측

- 수준변수 예측 모형: ARDL(Autoregressive Distributed Lag), LSTM(Long Short-Term Memory)
- 성분 분해 예측 모형: AR(Autoregressive) + Jump + GARCH 계열
 - 점프: 단일 점프, 이중지수 점프(DEJD; Double Exponential Jump Diffusion)
 - GARCH 모형: GARCH(1,1), GJR-GARCH(1,1), EGARCH(1,1)

단계 4: 모형별 예측 성과 비교

- 예측 성과 비교 방법
 - 평균절대오차(Mean Absolute Error, MAE)
 - 평균 제곱 백분율 오차(Mean Squared Percentage Error, MSPE)
 - 평균 절대 백분율 오차(Mean Absolute Percentage Error, MAPE)
 - DM(Diebold-Mariano) 테스트

분석 데이터

분석 데이터 및 변수 이름

- 분석 데이터
 - 일별 평균 SMP(AvgSMP): 24시간 SMP의 평균
 - 에너지 가격: 경유 가격(DieselPrice, 원/리터)
 - 기후 및 날씨: 평균 온도(AvgTMP, °C), 평균 풍속(AvgWindSpeed, m/s), 평균 상대습도(AvgHumidity, %rh), 일사합(Solar_Radiation, MJ/m^2)
 - 휴일 및 계절 가변수: 공휴일 및 주말(HolidayDummy), 봄(Spring), 여름(Summer), 가을(Autumn), 겨울(Winter)
- 표본 기간: 2013년 2월 3일 ~ 2024년 6월 25일
 - 전체 데이터 80%를 학습 데이터 혹은 표본내(in-sample)로 설정
 - 나머지 20%를 테스트 데이터 혹은 표본외(out-of-sample)로 설정

기초통계량

	평균	표준편차	최소	25%	50%	75%	최대
AvgSMP	114.18	45.33	37.55	81.15	97.72	141.65	282.65
DieselPrice	1441.59	222.51	1058.75	1272.03	1386.38	1609.91	2167.66
AvgTMP	13.29	9.45	-12.30	5.10	13.90	21.60	30.30
AvgWindSpeed	1.86	0.65	0.80	1.40	1.70	2.20	5.20
AvgHumidity	68.32	12.89	31.00	59.00	70.00	78.00	96.00
Solar_Radiation	14.15	6.43	0.96	9.23	13.50	18.93	29.96

- SMP와 경유 가격 모두 매우 높은 변동성을 갖고 있음을 보여주고 있으며, 기후 관련 데이터도 계절적 특성을 반영하여 변동성이 높게 나타나고 있다.

피어슨 상관계수

- AvgSMP와 가장 관련이 높은 변수는 DieselPrice이다.
- 기온(AvgTMP)과 SMP가 음의 관계를 갖고 있다.
 - 기온이 낮아지면 난방유에 대한 수요가 증가하여, SMP를 상승시키기 때문이다.
 - 난방유 수요가 많은 겨울(Winter)과 SMP의 양의 관계는 이를 뒷받침하고 있다.
- 휴일과 SMP 사이는 음의 상관관계가 있다.
 - 휴일에는 전력 수요가 감소하고 있다.
- 테이블의 붉은 색 숫자는 상관계수가 +0.18보다 크거나 -0.18보다 작은 경우를 나타낸다.

	AvgSMP	DieselPrice	AvgTMP	AvgWindSpeed	AvgHumidity	Solar_Radiation	HolidayDummy	Spring	Summer	Autumn
DieselPrice	0.762									
AvgTMP	-0.166	0.071								
AvgWindSpeed	0.008	-0.015	-0.224							
AvgHumidity	-0.093	0.035	0.562	-0.330						
Solar_Radiation	-0.048	0.054	0.426	-0.034	-0.331					
HolidayDummy	-0.099	0.001	0.004	-0.034	0.015	-0.002				
Spring	0.026	0.001	-0.030	0.187	-0.300	0.343	-0.004			
Summer	-0.120	0.037	0.678	-0.117	0.420	0.267	-0.018	-0.346		
Autumn	-0.027	0.041	0.085	-0.180	0.199	-0.201	0.014	-0.338	-0.324	
Winter	0.120	-0.080	-0.737	0.105	-0.312	-0.421	0.009	-0.342	-0.328	-0.321

변수의 시계열 안정성: ADF 테스트

- ADF 테스트의 귀무가설은 ‘시계열 데이터에 단위근이 존재한다’이다. ADF 통계량의 p-값이 유의수준보다 크면 귀무가설을 기각할 수 없으므로 데이터는 안정성을 갖지 못할 가능성이 높다. 본 연구에서는 유의수준을 0.01로 설정하였다.

	ADF 통계량	p-값	안정성 여부
AvgSMP	-1.8069	0.3771	비안정성
log(AvgSMP)	-1.7686	0.3962	비안정성
diff(AvgSMP)	-13.9811	0.0000	안정성
DieselPrice	-2.5542	0.1028	비안정성
log(DieselPrice)	-2.5483	0.1042	비안정성
diff(DieselPrice)	-8.6860	0.0000	안정성
AvgTMP	-4.6115	0.0001	안정성
AvgWindSpeed	-8.0416	0.0000	안정성
AvgHumidity	-6.6782	0.0000	안정성
Solar_Radiation	-5.9888	0.0000	안정성

SMP의 성분 분해

SMP의 성분 구성

- SMP의 분해

$$\log P_t = D_t + R_t$$

- P_t : SMP, D_t : 결정적 성분(deterministic component), R_t : 확률적 성분(stochastic component)

- 결정적 성분 D_t 의 구성

$$D_t = l_t + w_t + b_t + y_t$$

- l_t : 장기 추세(trend), w_t : 요일(weekday) 효과, b_t : 주중 휴일(weekday holiday) 효과, y_t : 연간(yearly) 효과

- 확률적 성분 R_t

$$R_t = \log P_t - \hat{D}_t = \log P_t - (\hat{l}_t + \hat{w}_t + \hat{b}_t + \hat{y}_t)$$

- SMP의 예측 $\hat{P}_t$

$$\hat{P}_t = \exp(\hat{D}_t + \hat{R}_t)$$

결정적 성분 요소의 추정 방법

▪ 추세(Trend), $\hat{l}_t$: 스플라인 함수(spline function)

- 스플라인 함수의 최적 매듭 수 결정: 교차 검증(cross-validation) 방법
- 표본외의 '추세'는 이동 윈도우(rolling window)를 사용한 이중 지수평활 모형(double exponential smoothing)으로 예측

▪ 요일 효과(Weekly Effect), $\hat{w}_t$:

- 1단계: 관측 개체($\log P_t$)에서 추정한 추세($\hat{l}_t$)를 차감하여 추세를 제거한 시계열 자료 $\widehat{DT}_t$ 의 각 요일(d) 별 평균 $\hat{w}_d$ 를 구한다.

$$\hat{w}_d = \frac{1}{N_d} \sum_{i=1}^{N_d} \widehat{DT}_{d,i} = \frac{1}{N_d} \sum_{i=1}^{N_d} (\log P_{d,i} - \hat{l}_{d,i})$$

- 2단계: $t = 1, \dots, T$ 에 해당하는 각 관측개체의 요일에 $\hat{w}_d$ 를 할당하여 $\hat{w}_t$ 시리즈를 구한다.


▪ 주중 휴일(공휴일과 대체 휴일) 효과(Weekday Holiday Effect), $\hat{b}_t$:

- 시리즈 $\widehat{DT}_t - \hat{w}_t$ 중에서 주중 휴일에 해당하면 1을, 그렇지 않으면 0을 할당한 다음 두 그룹의 평균으로 계산하였다.

▪ 연간 효과(Yearly Effect), $\hat{y}_t$:

- 1년 365일의 각 날짜에 1부터 365를 할당한 후, 각 날짜의 $\widehat{DT}_t - \hat{w}_t - \hat{b}_t$ 평균을 구하여 추정하였다.
- 연도별 연간 효과의 비교가 일관성을 갖도록 하기 위해 윤년의 2월 29일에 해당하는 관측개체는 제외

결정적 성분의 예측 결과



ARDL에 의한 수준변수 예측

ARDL 모형과 추정 계수

- ARDL(Autoregressive Distributed Lag) 모형

- y_t : AvgSMP_t, x_t : DieselPrice_t


$$y_t = \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \sum_{j=1}^q \beta_j x_{t-j} + \epsilon_t$$

- p 와 q 의 최적 시차를 찾는 방법: 다양한 시차 조합을 대입한 후, AIC(Akaike Information Criterion)를 최소로 하는 시차를 선택

- ARDL 추정 계수

	계수	t-값	p-값
$\hat{\alpha}_0$	-5.2343	-4.9266	0.0000
AvgSMP _{t-1}	0.9722	56.2324	0.0000
AvgSMP _{t-2}	-0.2674	-11.1335	0.0000
AvgSMP _{t-3}	0.1507	6.2742	0.0000
AvgSMP _{t-4}	0.0907	5.2449	0.0000
DieselPrice _t	0.0077	6.9140	0.0000

표본외 기간에 대한 AvgSMP의 예측 결과: ARDL 모형




LSTM에 의한 수준변수 예측

LSTM 모형의 초모수(hyperparameter) 설정

- 은닉층(hidden layer)의 최적 수: 1개
 - 평균 검증 손실(average validation loss)을 최소로 하는 교차 검증 방법을 사용
- 뉴런의 유닛 수와 윈도우 크기의 최적 조합: Grid Search 방법
- 데이터 정규화 방법: 최소-최대 정규화(Min-Max normalization)
- 손실함수: 평균 제곱 오차(Mean Squared Error, MSE)
 - MSE를 감소시키는 최적화 알고리즘: Adam(Adaptive Moment Estimation)
- 훈련 데이터의 반복 학습 횟수(epoch): 20회
 - 한 번의 학습 단계에서 처리하는 표본의 수(batch size): 32

표본외 기간에 대한 AvgSMP의 예측 결과: LSTM 모형



AR과 점프에 의한 확률적 성분 예측

AR

- 모형의 최적 시차: 8
 - 교차 검증 방법으로 최적 시차 선택

$$\hat{R}_t = \sum_{i=1}^8 \varphi_i \hat{R}_{t-i} + \varepsilon_t$$

AR + Jump

- 점프의 비대칭성을 고려하지 않고 일정한 확률에 따라 값이 급격히 변하는 점프 모형

$$\hat{R}_t = \sum_{i=1}^8 \varphi_i \hat{R}_{t-i} + J_t + \eta_t, \quad J_t = \begin{cases} \mu_J + \sigma_J z_t, & \text{확률 } \lambda \\ 0, & \text{확률 } 1 - \lambda \end{cases}$$

- J_t : 시점 t 의 점프 크기, μ_J : 점프의 평균 크기, σ_J : 점프의 표준편차, z_t : 표준 정규분포를 따르는 확률변수, λ : 점프가 발생할 확률


AR+DEJD(Double Exponential Jump Diffusion Model)

- 점프의 비대칭성 고려

$$\hat{R}_t = \sum_{i=1}^8 \varphi_i \hat{R}_{t-i} + J_t + \eta_t, \quad J_t = \begin{cases} \mu_J^+ + \sigma_J^+ \cdot E_t, & \text{확률 } \frac{\lambda}{2} \\ -(\mu_J^- + \sigma_J^- \cdot E_t), & \text{확률 } \frac{\lambda}{2} \\ 0, & \text{확률 } 1 - \lambda \end{cases}$$

- μ_J^+ : 양의 점프 평균 크기, μ_J^- : 음의 점프 평균 크기, σ_J^+ : 양의 점프 표준편차, σ_J^- : 음의 점프 표준편차, E_t : 평균과 표준편차가 1인 지수 분포를 따르는 확률변수

표본외 기간에 대한 확률적 성분의 예측 결과: (AR(8)+점프) 모형



AR과 GARCH 계열 모형에 의한 확률적 성분 예측

AR(8) 모형의 잔차에 대한 Engle의 ARCH 테스트

▪ LM 통계량

LM 통계량	LM p-값	F 통계량	F의 p-값
238.0059	0.0000	25.1845	0.0000

- AR(8) 모형의 잔차는 강한 ARCH 효과를 보여주고 있으므로 GARCH 모형을 사용할 수 있음을 알 수 있다.


▪ GARCH(1,1) 모형

$$\varepsilon_t = \mu + \sigma_t z_t, \quad \sigma_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

▪ AR(8) 모형의 잔차에 대한 GARCH(1,1) 적합 결과

모수	계수	표준오차	t-값	p-값
$\hat{\mu}$	-0.0004	0.0009	-0.420	0.674
$\hat{\omega}$	0.00017	0.00013	1.2870	0.1980
$\hat{\alpha}_1$	0.18620	0.08535	2.1820	0.0291
$\hat{\beta}_1$	0.79790	0.11200	7.1000	0.0000

표본외 기간에 대한 확률적 성분의 예측 결과: (AR(8)+GARCH(1,1)) 모형



모형의 예측 추정 성과

모형별 예측 결과

- 평균절대오차(Mean Absolute Error, MAE): $MAE = \frac{1}{n} \sum_{i=1}^n [y_i - \hat{y}_i]$
- 평균 제곱 백분율 오차(Mean Squared Percentage Error, MSPE): $MSPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right)^2$
- 평균 절대 백분율 오차(Mean Absolute Percentage Error, MAPE): $MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100$
- DM(Diebold-Mariano) 테스트:

$$DM \text{ 통계량} = \frac{\bar{d}}{\sqrt{\{\sum_{i=1}^n (d_i - \bar{d})^2\}/n}}, \quad \bar{d} = \frac{1}{n} \sum_{i=1}^n d_i, \quad d_i = L(e_{1,i}) - L(e_{2,i})$$

구분	Model	MAE	MSPE	MAPE	DM 통계량	DM p-값
수준변수	ARDL	10.87994	0.01096	6.89839	-	-
	LSTM	11.42062	0.00981	7.06649	2.91634	0.00354
성분 분해	AR8	11.58533	0.01160	7.34978	1.64386	0.10020
	AR8+Jump	10.04346	0.00813	6.33519	-2.00584	0.04487
	AR8+DEJD	10.88386	0.01049	6.86673	0.00830	0.99338
	AR8+GARCH	12.68366	0.01441	8.22611	4.02583	0.00006
	AR8+GJR_GARCH	12.67082	0.01439	8.21772	3.99868	0.00006
	AR8+EGARCH	12.73761	0.01450	8.26133	4.13947	0.00003

결과 요약

- 분석에 사용된 경유 가격, 전국 평균 온도, 평균 풍속, 평균 상대습도, 일사합, 요일 및 휴일, 연간 효과 등의 캘린더 효과 사이에 매우 높은 상관관계를 갖고 있으며, 시계열 안정성을 갖지 못하는 변수도 존재하여 예측 모형 설정에서 이를 고려해야 한다.
- 수준변수를 사용한 예측은 ECM과 VECM, ARDL 모형, LSTM을 사용한 딥러닝 등으로 하였으며, 이 중에서 ARDL 모형과 LSTM 모형이 신뢰할 수 있는 예측 성과를 보여주었다.
- 확률적 성분을 분석하기 위한 시계열 회귀(OLS, LASSO, GLS, WLS 등)는 통계적 가정을 충족시키지 못하거나 매우 낮은 예측 성능을 보여주었다.
- 확률적 성분을 자기회귀나 점프, GARCH 계열 모형 등을 고려하여 분석한 결과 자기회귀를 수행한 후의 잔차에 점프를 고려하는 것이 가장 좋은 성과를 보이고 있음을 확인하였다.
- 확률적 성분에 의한 분석이 많은 실행 과정과 시간을 필요로 하지만 잡음의 크기를 줄일 수 있다는 점에서 예측 성능을 제고할 수 있는 보다 바람직한 접근 방법일 가능성이 높다.