



1. AR(p) 모형
2. MA(q) 모형
3. ARMA(p,q) 모형



(1) 모형

$$\text{AR}(1) \quad y_t = \phi_1 y_{t-1} + e_t, \quad e_t \sim \text{iid}N(0, \sigma_e^2)$$

$$\text{AR}(p) \quad y_t = \mu + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + e_t, \quad e_t \sim \text{iid}N(0, \sigma_e^2)$$

(2) AR(1)

① ACF

- 반복적인 대입을 통해 y_t 를 교란항의 함수로만 표현해 보면($y_0 = 0$)

$$y_t = \phi y_{t-1} + e_t, \quad e_t \sim (0, \sigma_e^2)$$

$$= \phi^2 y_{t-2} + \phi e_{t-1} + e_t$$

.

$$= \sum_{j=0}^{\infty} \phi^j e_{t-j}$$

- y_t 의 평균, 분산 및 공분산을 구해 보면 다음과 같음

$$E(y_t) = 0$$

$$\text{Var}(y_t) = \sigma_e^2 + \phi^2 \sigma_e^2 + \phi^4 \sigma_e^2 + \dots$$

$$= \frac{\sigma_e^2}{1 - \phi^2}$$

$$\equiv \gamma_0$$

$$\text{Cov}(y_t y_{t-1}) = E(y_t y_{t-1}) = E[(e_t + \phi e_{t-1} + \dots)(e_{t-1} + \phi e_{t-2} + \dots)]$$

$$= \phi \sigma_e^2 + \phi^3 \sigma_e^2 + \dots$$

$$= \frac{\phi}{1 - \phi^2} \sigma_e^2 \equiv \gamma_1$$

$$\text{Cov}(y_t y_{t-k}) = \frac{\phi^k}{1 - \phi^2} \sigma_e^2 \equiv \gamma_k$$

- 따라서 다음과 같이 $\rho_0, \rho_1, \dots, \rho_k$ 를 구할 수 있음

$$\therefore \rho_0 \equiv \frac{\gamma_0}{\gamma_0} = 1$$

$$\rho_1 \equiv \frac{\gamma_1}{\gamma_0} = \phi$$

.

$$\rho_k \equiv \frac{\gamma_k}{\gamma_0} = \phi^k$$

- 이를 그래프로 나타낸 것을 상관도(correlogram)라 하며 이를 이용하여 시계열의 안정성여부를 판단할 수 있음
- 시계열이 안정적이면($\phi \rightarrow 0$), ACF는 급격하게 0을 향해 감소하고
시계열이 불안정적이면($\phi \rightarrow 1$), ACF는 0을 향해 천천히 감소함

② PACF

- k 이외의 모든 시차를 갖는 관측치($y_{t-1}, y_{t-2}, \dots, y_{t-k+1}$)의 영향력을 배제한 가운데 특정의 두 관측치, y_t 및 y_{t-k} 가 얼마나 관련이 있는 지 나타내는 척도로 회귀계수가 편자기상관함수가 됨
- 즉, $\phi_{kk} = \text{corr}(y_t, y_{t-k} \mid y_{t-1}, y_{t-2}, \dots, y_{t-k+1})$
- 시차 k의 편자기상관계수는 다음 식에서 k번째 회귀계수 ϕ_{kk} 를 의미함


$$y_t = \phi_{k1}y_{t-1} + \phi_{k2}y_{t-2} + \dots + \phi_{kk}y_{t-k} + e_t$$

$$\text{즉, AR(1): } \phi_{11} = \phi_1$$


$$\text{AR(2): } \phi_{22} = \phi_2$$

③ 식별


- ACF가 점진적으로 감소하면 불안정시계열이므로 원계열을 차분하여 안정시계열로 만들어 줌
- ACF가 0을 향해 감소하고 PACF는 1-2개 정도만 통계적으로 유의하면 AR모형




$$Y(t) = 0.9 \cdot Y(t-1) + e(t)$$




$$Y(t) = 0.9 \cdot Y(t-1) + e(t)$$



$$Y(t) = 0.9Y(t-1) - 0.5Y(t-2) + e(t)$$



$$Y(t) = 0.9Y(t-1) - 0.5Y(t-2) + e(t)$$



④ 최적 모형의 선정(AIC 기준)

- ACF 및 PACF를 이용하여 모형을 식별할 수도 있지만 최적 모형을 선정하는 기준으로 적합성을 측정해 주는 AIC(Akaike Information Criterion) 또는 SBC(Schwarz-Bayesian Criterion) 등이 있음
- AIC 및 SBC는 다음과 같이 계산되는데 작은 값일수록 모형의 적합도가 높음을 나타냄

$$AIC = 2*k - 2*\ln(L^*)$$

$$SBC = k*\ln(n) - 2*\ln(L^*)$$

단, k 는 추정계수의 개수, n 은 관측치 수, $\ln(L^*)$ 은 최적화된 log likelihood의 값

⑤ 추정

- 일반적으로 AR 모형은 최소자승법으로 추정하고 MA 모형은 비선형최소자승법으로 추정
- 두 모형 모두 최우법으로 추정하기도 함

```
> ar1.sim<-arima.sim(model=list(ar=c(0.7)), n=100)
> ar1<-arima(ar1.sim, order=c(1,0,0), include.mean=T)
> ar1

Call:
arima(x = ar1.sim, order = c(1, 0, 0), include.mean = T)

Coefficients:
      ar1  intercept
      0.7127    0.0226
s.e.  0.0685    0.2947

sigma^2 estimated as 0.7526:  log likelihood = -128.04,  aic = 262.08
```

(주의사항)



- $y_t = \mu + \phi y_{t-1} + e_t$ 는 $(1 - \phi L)y_t = \mu + e_t$ 이므로 $y_t = \frac{\mu}{1 - \phi} + (1 - \phi L)^{-1}e_t$ 로 나타낼 수 있고

AR(1)에서 추정된 상수항 $\hat{c} = \frac{\hat{\mu}}{1 - \hat{\phi}}$ 이므로 $\hat{\mu} = \hat{c}(1 - \hat{\phi})$ 이 됨

- 따라서, $\hat{\phi} = 0.7127$ 이고, $\hat{c} = 0.0226$ 이므로 $\hat{\mu} = 0.02269(1 - 0.7127) = 0.0065$ 임.

⑥ 모형의 검토

- 잔차분석 : 모형설정이 제대로 되었으면 잔차항은 백색잡음확률과정을 따를 것임



- 잔차의 독립성 검정 : Ljung-Box 검정

$$Q = T(T+2) \sum_{k=1}^K \frac{1}{T-k} \gamma_k^2 \sim \chi_{K-p-q}^2$$

단, $K = \text{Min}(\frac{T}{2}, T^{1/3})$

```
> Box.test(res, lag=1, type=c("Ljung-Box"))
```

Box-Ljung test

```
data: res
x-squared = 1.5786e-05, df = 1, p-value = 0.9968
```

$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$ (단, ρ_k ($k=1, 2, 3, \dots, K$)는 잔차의 acf임)

⑦ 예측

- 추정된 AR(p)모형을 이용하면 미래의 값에 대한 예측치를 도출할 수 있는데 AR(1)의 경우를 예를 들어 n시점까지의 정보를 바탕으로 k기 이후 즉, (n+k)기에 대한 예측치를 구하는 방법은 다음과 같음

$$y_t = \mu + \phi y_{t-1} + e_t$$

- 위 식에서 (n+1)기(k=1)의 y 즉, y_{n+1} 은 다음과 같이 나타낼 수 있음

$$y_{n+1} = \mu + \phi y_n + e_{n+1}$$

- 따라서 n시점까지의 정보를 이용하여 (n+1)기에 대한 예측치를 구하면 다음과 같음.

$$\hat{y}_{n+1} = \hat{\mu} + \hat{\phi} y_n \quad \text{또는} \quad E[y_{n+1} | I_t] = \mu + \phi y_n \leftarrow E[e_{n+1} | I_t] = 0$$

- 따라서, n시점까지의 정보를 이용하여 (n+1)기 예측치에 대한 예측오차(실제치-예측치)와 그 분산은 다음과 같음

$$\begin{aligned} \text{- 예측오차 : } & y_{n+1} - E[y_{n+1} | I_t] \\ &= \mu + \phi y_n + e_{n+1} - (\mu + \phi y_n) \\ &= e_{n+1} \end{aligned}$$

$$\begin{aligned} \text{- 예측오차 분산 : } & \text{Var}(y_{n+1} - E[y_{n+1} | I_t]) \\ &= \text{Var}(e_{n+1}) \\ &= \sigma_e^2 \end{aligned}$$

- 유사한 방법으로 n 시점에서의 $(n+2)$ 기에 대한 예측치는 다음과 같음

$$\begin{aligned}\hat{y}_{n+2} &= \hat{\mu} + \hat{\phi}y_{n+1} \\ &= \hat{\mu} + \hat{\phi}(\hat{\mu} + \hat{\phi}y_n) \\ &= (\hat{\phi} + 1)\hat{\mu} + \hat{\phi}^2y_n\end{aligned}$$

또는 $E[y_{n+2} | I_t] = \mu + \phi E[y_{n+1} | I_t] \leftarrow E[e_{n+2} | I_t = 0]$

- 따라서, n 시점까지의 정보를 이용하여 $(n+2)$ 기 예측치에 대한 예측오차(실제치-예측치)와 그 분산은 다음과 같음

- 예측오차 : $y_{n+2} - E[y_{n+2} | I_t]$

$$\begin{aligned}&= \mu + \phi y_{n+1} + e_{n+2} - \mu - \phi E[y_{n+1} | I_t] \\ &= \phi(y_{n+1} - E[y_{n+1} | I_t]) + e_{n+2} \\ &= \phi e_{n+1} + e_{n+2}\end{aligned}$$

- 예측오차 분산 : $Var(y_{n+2} - E[y_{n+2} | I_t])$

$$\begin{aligned}&= Var(\phi e_{n+1} + e_{n+2}) \\ &= (\phi^2 + 1)\sigma_e^2\end{aligned}$$

- 일반적으로 n 시점에서 h 기 이후 즉, $(n+h)$ 기에 대한 예측치는 다음과 같음

$$\hat{y}_{n+h} = (\hat{\phi}^{h-1} + \hat{\phi}^{h-2} + \dots + 1)\hat{\mu} + \hat{\phi}^h y_n$$

(점 예측치)

-n시점에서의 (n+1)기에 대한 예측치

$$\hat{y}_{t+1} = \hat{\mu} + \hat{\phi}y_t = 0.0065 + (0.7127)(-0.5405) = -0.3787$$

```
[1] 0.17961519 -0.34706078 -1.31076625 -1.13551129 -1.82086235 -2.00349488 -2.02748568 -3.10593329
[9] -1.33636626 -0.78208326 -1.68559522 0.07389827 0.47819301 0.03966362 0.92289020 1.52415663
[17] 1.88849072 2.01058376 1.96132628 1.31101669 0.61174902 0.04775331 -0.66127966 -0.67081304
[25] -1.73496548 0.95448013 1.87609809 0.19016008 -0.26977278 -0.65549630 0.32111771 0.14141333
[33] 0.35230784 0.21806874 0.10977766 1.44544664 0.78604167 2.06669977 -0.10206297 0.51316967
[41] 0.48307302 0.55409268 0.76750436 0.03492960 -0.30875667 -1.23470505 -1.93608476 -1.05173069
[49] -0.28800171 -0.14859697 0.81824959 2.62285940 1.34497041 -1.36768959 0.04835581 -0.67535169
[57] -1.16075480 0.21304301 -0.13564290 -1.31566774 -0.73966394 -0.65665612 -0.45389510 0.06755383
[65] -0.32337235 0.41801590 0.07212457 0.38226916 1.36442743 1.39028069 0.64726490 1.60189305
[73] 2.11482899 2.02877725 1.65887581 0.53330699 1.73396734 0.61351755 2.61679528 3.36436732
[81] 2.11935677 0.45712884 -0.39041638 -0.01640776 -0.25817731 -0.52826671 -1.32140527 -0.97001141
[89] -1.46391246 -2.69268066 -2.26510298 -0.66657548 -1.04194980 -0.12140054 -1.70286308 -1.24756612
[97] -0.35388908 0.05343100 0.14307790 -0.54055148
```

-n시점에서의 (n+2)기에 대한 예측치

$$\hat{y}_{t+2} = \hat{\mu} + \hat{\phi}y_{t+1} = \hat{\mu} + \hat{\phi}(\hat{\mu} + \hat{\phi}y_t) = 0.0065 + (0.7127)(-0.3787) = -0.2634$$

(구간예측)

-n시점에서의 (n+1)기에 대한 95% 구간예측

$$-0.3787 \pm (1.96) \sqrt{0.7526} = [-2.079, 1.3216]$$

```
> predict(ar1,n.ahead=4)
$pred
Time Series:
Start = 101
End = 104
Frequency = 1
[1] -0.3787392 -0.2634227 -0.1812416 -0.1226748


$con
Time Series:
Start = 101
End = 104
Frequency = 1
[1] 0.867547 1.065311 1.152832 1.194831
```

-n시점에서의 (n+2)기에 대한 95% 구간예측

$$-0.2634 \pm (1.96) \sqrt{(1 + 0.7127^2)(0.7526)} = [-2.3513, 1.8245]$$

```
> (far1<-forecast(ar1,h=4))
Point Forecast Lo 80 Hi 80 Lo 95 Hi 95
101 -0.3787392 -1.490545 0.7330671 -2.079100 1.321622
102 -0.2634227 -1.628673 1.1018278 -2.351393 1.824548
103 -0.1812416 -1.658656 1.2961726 -2.440752 2.078268
104 -0.1226748 -1.653912 1.4085622 -2.464500 2.219150
```

Forecasts from ARIMA(1,0,0) with non-zero mean



(1) 모형

$$\text{MA}(1) \quad y_t = e_t - \theta e_{t-1}, \quad e_t \sim \text{iid}N(0, \sigma_e^2)$$

$$\text{MA}(q) \quad y_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}, \quad e_t \sim \text{iid}N(0, \sigma_e^2)$$

(2) MA(1)

① ACF

- y_t 의 평균, 분산, 공분산 및 ACF를 구해 보면 다음과 같음

$$E(y_t) = 0$$

$$\text{Var}(y_t) = \sigma_e^2 + \theta^2 \sigma_e^2 = (1 + \theta^2) \sigma_e^2 \equiv \gamma_0$$

$$\text{Cov}(y_t y_{t-1}) = E(y_t y_{t-1}) = E[(e_t - \theta e_{t-1})(e_{t-1} - \theta e_{t-2})] = -\theta \sigma_e^2 \equiv \gamma_1$$

$$\text{Cov}(y_t y_{t-2}) = E(y_t y_{t-2}) = E[(e_t - \theta e_{t-1})(e_{t-2} - \theta e_{t-3})] = 0 \equiv \gamma_2$$

$$\therefore \rho_1 \equiv \frac{\gamma_1}{\gamma_0} = \frac{-\theta}{1 + \theta^2}$$


$$\rho_2 \equiv \frac{\gamma_2}{\gamma_0} = 0$$

⋮


$$\rho_k = 0$$

② 식별


- PACF는 0을 향해 감소하고 ACF는 1 - 2개 정도만 통계적으로 유의하면 MA모형




$$Y(t) = e(t) + 0.8e(t-1)$$




$$Y(t) = e(t) + 0.8e(t-1)$$



$$Y(t) = e(t) + 0.6e(t-1) - 0.3e(t-2)$$



$$Y(t) = e(t) + 0.6e(t-1) - 0.3e(t-2)$$



③ 추정



```
> ma1<-arima(ma1.sim, order=c(0,0,1), include.mean=F)
> ma1
Call:
arima(x = ma1.sim, order = c(0, 0, 1), include.mean = F)

Coefficients:
      ma1
    0.7399
s.e.  0.0858

sigma^2 estimated as 0.8194:  log likelihood = -132.33,  aic = 268.67
```

④ 모형의 검토

- 잔차분석 : 모형설정이 제대로 되었으면 잔차항은 백색잡음확률과정을 따를 것임



⑤ 예측

- 추정된 MA(q)모형을 이용하면 미래의 값에 대한 예측치를 도출할 수 있는데 MA(1)의 경우를 예를 들어 n시점까지의 정보를 바탕으로 k기 이후 즉, (n+k)기에 대한 예측치를 구하는 방법은 다음과 같음

$$y_t = e_t + \theta e_{t-1}$$

- 위 식에서 (n+1)기(k=1)의 y 즉, y_{n+1} 은 다음과 같이 나타낼 수 있음

$$y_{n+1} = e_{n+1} + \theta e_n$$

- 따라서 n시점까지의 정보를 이용하여 (n+1)기에 대한 예측치를 구하면 다음과 같음.

$$\hat{y}_{n+1} = \hat{\theta} \hat{e}_n \quad \text{또는} \quad E[y_{n+1} | I_t] = \theta e_n \leftarrow E[e_{n+1} | I_t = 0]$$

- 따라서, n시점까지의 정보를 이용하여 (n+1)기 예측치에 대한 예측오차(실제치-예측치)와 그 분산은 다음과 같음

$$\begin{aligned} \text{- 예측오차 : } & y_{n+1} - E[y_{n+1} | I_t] \\ &= e_{n+1} + \theta e_n - \theta e_n \\ &= e_{n+1} \end{aligned}$$

$$\begin{aligned} \text{- 예측오차 분산 : } & \text{Var}(y_{n+1} - E[y_{n+1} | I_t]) \\ &= \text{Var}(e_{n+1}) \\ &= \sigma_e^2 \end{aligned}$$

- 유사한 방법으로 n 시점에서의 $(n+2)$ 기에 대한 예측치는 다음과 같음

$$y_{n+2} = e_{n+2} + \theta e_{n+1} \text{이므로}$$

$$\hat{y}_{n+2} = 0$$

$$\text{또는 } E[y_{n+2} | I_t] = 0 \leftarrow E[e_{n+2} | I_t = 0], E[e_{n+1} | I_t = 0]$$

- 따라서, n 시점까지의 정보를 이용하여 $(n+2)$ 기 예측치에 대한 예측오차(실제치-예측치)와 그 분산은 다음과 같음

$$\begin{aligned} \text{- 예측오차 : } & y_{n+2} - E[y_{n+2} | I_t] \\ & = e_{n+2} + \theta e_{n+1} \end{aligned}$$

$$\begin{aligned} \text{- 예측오차 분산 : } & \text{Var}(y_{n+2} - E[y_{n+2} | I_t]) \\ & = \text{Var}(e_{n+2} + \theta e_{n+1}) \\ & = (1 + \theta^2)\sigma_e^2 \end{aligned}$$

(점 예측치)

-n시점에서의 (n+1)기에 대한 예측치

$$\hat{y}_{t+1} = \hat{\theta} \hat{e}_n = 0.7399(-0.5067) = -0.3749$$

-n시점에서의 (n+2)기에 대한 예측치

$$\hat{y}_{t+2} = 0$$

(구간예측)

-n시점에서의 (n+1)기에 대한 95% 구간예측

$$-0.3749 \pm (1.96) \sqrt{0.8194} = [-2.1491, 1.3992]$$

-n시점에서의 (n+2)기에 대한 95% 구간예측

$$0 \pm (1.96) \sqrt{(1 + 0.7399^2)(0.8194)} = [-2.207, 2.207]$$


[1]	-0.45537808	1.54818192	-0.04090282	0.19626161	1.63159555	0.29484781	-1.20124821	-0.55910317
[9]	-0.44443127	1.28446667	0.14442029	0.50975808	-0.02593756	-0.47022011	1.80123788	0.23737511
[17]	-1.84351271	0.88530355	-0.70696988	-0.82844324	-0.24574157	-0.97497592	-0.62315286	-0.60133103
[25]	-1.61681881	1.02198306	-0.10007430	-0.97207254	1.29012586	0.22424661	-0.20510301	0.86982934
[33]	0.77166096	0.77754365	0.60631904	0.51851340	-0.11318605	-0.25936838	-0.37215350	-0.64764980
[41]	-0.14557427	-1.28244281	2.35854038	0.76435676	-0.96384485	-0.36364417	-0.43934215	0.82502157
[49]	-0.22578665	0.37034654	-0.15055853	0.05139303	1.30485660	-0.37001480	1.65476546	-1.86315759
[57]	1.03382926	-0.29026166	0.50500577	0.13557319	-0.37484432	-0.35727087	-0.95417104	-0.97698787
[65]	0.38328365	0.34675249	0.06538340	0.90569575	1.93336129	-0.69138813	-2.09226034	1.16820729
[73]	-0.97006211	-0.39582339	0.90561827	-0.33945674	-1.14043261	0.29262807	-0.24661173	0.10488639
[81]	0.31113815	-0.36968903	0.69549695	-0.34842780	0.45727622	0.95758992	0.38480683	-0.34952410
[89]	1.21184596	0.78619766	0.56282670	0.15135955	-0.59665121	1.42534442	-0.83841687	2.44748448
[97]	1.03422583	-0.08131154	-1.10768233	-0.50673436				

```
> predict(ma1,n.ahead=4)
$pred
Time Series:
Start = 101
End = 104
Frequency = 1
[1] -0.3749101 0.0000000 0.0000000 0.0000000

$se
Time Series:
Start = 101
End = 104
Frequency = 1
[1] 0.9052254 1.1260459 1.1260459 1.1260459

> (fma1<-forecast(ma1,h=4))
Point Forecast      Lo 80      Hi 80      Lo 95      Hi 95
101      -0.3749101 -1.535003 0.7851829 -2.149119 1.399299
102       0.0000000 -1.443086 1.4430859 -2.207009 2.207009
103       0.0000000 -1.443086 1.4430859 -2.207009 2.207009
104       0.0000000 -1.443086 1.4430859 -2.207009 2.207009
```

Forecasts from ARIMA(0,0,1) with zero mean



(1) 모형


$$\text{ARMA}(1,1) \quad y_t = \mu + \phi y_{t-1} + e_t - \theta e_{t-1}, \quad e_t \sim \text{iid}N(0, \sigma_e^2)$$

$$\text{ARMA}(p,q) \quad y_t = \mu + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}, \quad e_t \sim \text{iid}N(0, \sigma_e^2)$$

(2) ARMA(1,1)

① 식별


- ACF는 시차 $q(=1)$ 까지는 0과 현저히 다르고, 그 이후는 AR(p)처럼 점차적으로 소멸함
- PACF는 시차 $p(=1)$ 까지는 0과 현저히 다르고, 그 이후는 MA(q)처럼 점차적으로 소멸함




주요 확률과정의 acf와 pacf (요약)

확률과정	acf	pacf
AR	점차적으로 0으로 수렴함 (tail off)	시차 p까지만 0과 현저히 다르고 이후 0으로 갑자기 이동 (즉, 마지막 스파이크의 시차길이는 AR의 차수와 동일) (cuts off after lag p)
MA	시차 q까지만 0과 현저히 다르고 이후 0으로 갑자기 이동 (즉, 마지막 스파이크의 시차길이는 MA의 차수와 동일) (cuts off after lag q)	점차적으로 0으로 수렴함 (tail off)
ARMA	시차 q까지는 0과 현저히 다르고, 그 이후는 AR(p)처럼 점차적으로 소멸함	시차 p까지는 0과 현저히 다르고, 그 이후는 MA(q)처럼 점차적으로 소멸함
white noise	모든 시차에 대해 0	모든 시차에 대해 0

$$Y(t) = 0.3Y(t-1) + e(t) + 0.2e(t-1)$$




$$Y(t) = 0.3Y(t-1) + e(t) + 0.2e(t-1)$$




(3) 사례분석(ARMA(1,1))

① 데이터




② 식별


Series djtinx




Series djtinx



Series ddjtinx



Series ddjtinx



③ 추정

```
> (arma11<-arima(ddjtinx, order=c(1,0,1), include.mean=F))
```

Call:

```
arima(x = ddjtinx, order = c(1, 0, 1), include.mean = F)
```


Coefficients:

	ar1	ma1
	0.9482	-0.7407
s.e.	0.0600	0.1221


```
sigma^2 estimated as 3.456: log likelihood = -130.82, aic = 267.65
```

④ 모형의 검토

Series arma11\$resid



Series arma11\$resid



⑤ 예측

- ARMA(1,1)의 경우를 예를 들어 n시점까지의 정보를 바탕으로 k기 이후 즉, (n+k)기에 대한 예측치를 구하는 방법은 다음과 같음

$$y_t = \mu + \phi y_{t-1} + \theta e_{t-1} + e_t$$

- 위 식에서 (n+1)기의 y 즉, y_{n+1} 은 다음과 같이 나타낼 수 있음

$$y_{n+1} = \mu + \phi y_n + \theta e_n + e_{n+1}$$

- 따라서 n시점까지의 정보를 이용하여 (n+1)기에 대한 예측치를 구하면 다음과 같음.

$$\hat{y}_{n+1} = \hat{\mu} + \hat{\phi} y_n + \hat{\theta} e_n \quad \text{또는} \quad E[y_{n+1} | I_t] = \mu + \phi y_n + \theta e_n \leftarrow E[e_{n+1} | I_t = 0]$$

- 따라서, n시점까지의 정보를 이용하여 (n+1)기 예측치에 대한 예측오차(실제치-예측치)와 그 분산은 다음과 같음

$$\begin{aligned} \text{- 예측오차 : } & y_{n+1} - E[y_{n+1} | I_t] && (*) \\ & = \mu + \phi y_n + \theta e_n + e_{n+1} - (\mu + \phi y_n + \theta e_n) \\ & = e_{n+1} \end{aligned}$$

$$\begin{aligned} \text{- 예측오차 분산 : } & \text{Var}(y_{n+1} - E[y_{n+1} | I_t]) \\ & = \text{Var}(e_{n+1}) \\ & = \sigma_e^2 \end{aligned}$$

- 유사한 방법으로 (n+2)기의 y 즉, y_{n+2} 은 다음과 같이 나타낼 수 있음

$$y_{n+2} = \mu + \phi y_{n+1} + \theta e_{n+1} + e_{n+2}$$

- 따라서 n시점에서의 (n+2)기에 대한 예측치는 다음과 같음

$$\begin{aligned}\hat{y}_{n+2} &= \hat{\mu} + \hat{\phi} \hat{y}_{n+1} \\ &= \hat{\mu} + \hat{\phi} (\hat{\mu} + \hat{\phi} y_n + \hat{\theta} e_n) \\ &= (\hat{\phi} + 1) \hat{\mu} + \hat{\phi}^2 y_n + \hat{\phi} \hat{\theta} e_n\end{aligned}$$

또는 $E[y_{n+2} | I_t] = \mu + \phi E[y_{n+1} | I_t] \leftarrow E[\theta e_{n+1} | I_t = 0], E[e_{n+2} | I_t = 0]$

- 따라서, n 시점까지의 정보를 이용하여 $(n+2)$ 기 예측치에 대한 예측오차(실제치-예측치)와 그 분산은 다음과 같음

$$\begin{aligned}
 \text{- 예측오차 : } & y_{n+2} - E[y_{n+2} | I_t] \\
 &= \mu + \phi y_{n+1} + \theta e_{n+1} + e_{n+2} - \mu - \phi E[y_{n+1} | I_t] \\
 &= \phi e_{n+1} + \theta e_{n+1} + e_{n+2}
 \end{aligned}$$

$$\therefore \phi y_{n+1} - \phi E[y_{n+1} | I_t] = \phi (y_{n+1} - E[y_{n+1} | I_t]) = \phi e_{n+1} \quad \text{from (*)}$$

$$\begin{aligned}
 \text{- 예측오차 분산 : } & \text{Var}(y_{n+2} - E[y_{n+2} | I_t]) \\
 &= \text{Var}(\phi e_{n+1} + \theta e_{n+1} + e_{n+2}) \\
 &= (\phi^2 + \theta^2 + 1 + 2\phi\theta)\sigma_e^2
 \end{aligned}$$

- 일반적으로 n 시점에서 h 기 이후 즉, $(n+h)$ 기에 대한 예측치는 다음과 같음

$$\hat{y}_{n+h} = (\hat{\phi}^{h-1} + \hat{\phi}^{h-2} + \dots + 1)\hat{\mu} + \hat{\phi}^h y_n + \hat{\phi}^{h-1}\hat{\theta}e_n$$

(점 예측치)

-n시점에서의 (n+1)기에 대한 예측치

$$\Delta \hat{y}_{t+1} = \hat{\phi} \Delta y_t + \hat{\theta} e_t$$

$$\begin{aligned} \Delta y_{(2018:6)} &= (0.9482) \Delta y_{(2018:5)} + (-0.7407) e_{2018:5} \\ &= (0.9482 * 2.24) + (-0.7407 * 0.29193) \\ &= 2.124 - 0.2162 \\ &= 1.9077 \end{aligned}$$

-n시점에서의 (n+2)기에 대한 예측치

$$\Delta \hat{y}_{t+2} = \hat{\phi} \Delta \hat{y}_{t+1}$$

$$\begin{aligned} \Delta y_{(2018:7)} &= (0.9482) \Delta y_{(2018:6)} \\ &= (0.9482 * 1.9077) \\ &= 1.8088 \end{aligned}$$

(구간예측)

-n시점에서의 (n+1)기에 대한 95% 구간예측

$$1.9077 \pm (1.96) \sqrt{3.456} = [-1.735737, 5.551083]$$

-n시점에서의 (n+2)기에 대한 95% 구간예측

$$\begin{aligned} &1.8088 \pm (1.96) \sqrt{((0.9482^2 + (-0.7407)^2 + 1 - 2 * 0.9482 * 0.74407) 3.456)} \\ &= [-1.912163, 5.529787] \end{aligned}$$

```
> (ddjtinx<-djtinx.ts-lag(djtinx.ts,k=-1))
```

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
2013		-0.10	-1.07	-2.29	1.17	-0.44	-3.21	0.93	2.36	-0.37	-1.07	2.05
2014	2.24	1.02	-0.49	2.29	2.24	-0.78	2.87	-0.39	-0.34	1.03	3.06	1.95
2015	1.17	2.14	2.83	0.34	5.26	1.99	0.10	-0.05	0.83	0.29	-3.45	1.12
2016	0.19	0.05	2.87	1.12	-0.73	-3.02	1.71	1.90	1.75	-1.37	-3.26	-1.02
2017	1.51	-1.32	3.46	3.26	3.95	0.63	2.24	3.46	3.26	3.95	0.63	2.24
2018	3.46	3.26	3.95	0.63	2.24							


```
> res
```

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug
2013		-0.083734825	-0.952026376	-1.858598917	1.976374839	-0.112227150	-2.859156128	1.861863574
2014	1.967708905	0.353391736	-1.195338364	1.869169358	1.453183120	-1.827491752	2.255888563	-1.440252482
2015	-0.003132137	1.028312424	1.562609468	-1.185859240	4.059209999	0.009394083	-1.779914250	-1.463265888
2016	0.072756567	-0.076260210	2.766102384	0.447685298	-1.460341540	-3.409559448	2.047908903	1.795578536
2017	2.088960102	-1.204377869	3.819466887	2.808526658	2.939321382	-0.938036467	0.947810084	2.038160785
2018	1.640915768	1.194793452	1.743969648	-1.823477606	0.291931158			

```
> (f3<-forecast(arma11, h=6))
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jun 2018	1.907673	-0.4746248	4.289971	-1.735737	5.551083
Jul 2018	1.808812	-0.6242027	4.241827	-1.912163	5.529787
Aug 2018	1.715075	-0.7626509	4.192800	-2.074279	5.504429
Sep 2018	1.626195	-0.8910495	4.143439	-2.223598	5.475988
Oct 2018	1.541921	-1.0103300	4.094172	-2.361410	5.445252
Nov 2018	1.462014	-1.1213041	4.045333	-2.488830	5.412859

Forecasts from ARIMA(1,0,1) with zero mean



```
> predict(arma11,n.ahead=4)
```

\$pred	Jun	Jul	Aug	Sep
2018	1.907673	1.808812	1.715075	1.626195

\$sse	Jun	Jul	Aug	Sep
2018	1.858917	1.898492	1.933379	1.964216