

Lección : Algoritmo de Levinson- Durbin

Dr. Jesús Savage
Dr. Carlos Rivera

18 de marzo de 2022

Índice

- 1 Algoritmo Levison-Durbin
- 2 Recursión de Levison-Durbin

Algoritmo de Levinson- Durbin

Recordando que el error de predicción es:

$$f_m(n) = u(n) - \sum_{k=1}^M w_{ok}^* u(n-k)$$

$$J(\underline{w}) = E[\underbrace{f_m(n)f_m^*(n)}]$$

$$= \sigma_u^2 - \underline{r}^H \underline{w} - \underline{w}^H \underline{r} + \underline{w}^H R \underline{w}$$

Finalmente, el gradiente de $J(\underline{w})$ con respecto \underline{w} :

$$\nabla J(\underline{w}) = \frac{dJ(\underline{w})}{d\underline{w}} = \underline{0} - 2\underline{r} + \underline{0} + 2R\underline{w}$$

Por lo tanto para obtener el vector óptimo \underline{w}_o , es decir el mínimo de $J(\underline{w})$

$$\frac{dJ(\underline{w})}{d\underline{w}} = \underline{0} = -2\underline{r} + 2R\underline{w}$$

Solución de Wiener:

$$\underline{r} = R\underline{w} \quad \Rightarrow \quad \boxed{\underline{w}_o = R^{-1}\underline{r}}$$

Algoritmo de Levinson- Durbin

Entonces con el vector óptimo \underline{w}_o , el error cuadrático medio mínimo es:

$$J_{min}(\underline{w}_o) = \sigma_u^2 - \underline{r}^H \underline{w}_o - \underline{w}_o^H \underline{r} + \underline{w}_o^H R \underline{w}_o$$

ya que $R \underline{w}_o = \underline{r}$

$$\begin{aligned} &= \sigma_u^2 - \underline{r}^H \underline{w}_o - \underline{w}_o^H \underline{r} + \underline{w}_o^H \underline{r} \\ &= \sigma_u^2 - \underline{r}^H \underline{w}_o = r(0) - \underline{r}^H \underline{w}_o \\ &= E\{|f_M(n)|^2\} = P_M \end{aligned}$$

Algoritmo de Levinson- Durbin

Agrupando estas ecuaciones:

$$\begin{bmatrix} r(0) & \underline{r}^H \\ \underline{r} & R \end{bmatrix} \begin{bmatrix} 1 \\ -\underline{w}_0 \end{bmatrix} = \begin{bmatrix} P_M \\ \underline{0} \end{bmatrix}$$

$\underline{0}$ es un vector nulo de $M \times 1$ Recordar que $r^*(i - k) = r[k - i]$
 $\underline{r}^H = [r^*(-1) \quad r^*(-2) \quad \dots \quad r^*(-M)] = [r(-1) \quad r(-2) \quad \dots \quad r(-M)]$

Con:

$$\begin{bmatrix} r(0) & \underline{r}^H \\ \underline{r} & R \end{bmatrix} =$$

$$\left[\begin{array}{c|cccc} r(0) & & r(1) & r(2) & \dots & r(M) \\ \hline r(-1) & & r(0) & r(1) & \dots & r(M-1) \\ r(-2) & & r(-1) & r(0) & \dots & r(M-2) \\ \vdots & \vdots & \ddots & \vdots & & \\ r(-M) & & r(-M+1) & r(-M+2) & \dots & r(0) \end{array} \right]$$

Con: $\underline{a}_M^T = [1 - \underline{w}^T]$

Entonces:

$$\begin{bmatrix} r(0) \\ \underline{r} \end{bmatrix} \begin{bmatrix} r^H \\ R \end{bmatrix} \begin{bmatrix} 1 \\ -\underline{w}_0 \end{bmatrix} = \begin{bmatrix} r(0) \\ \underline{r} \end{bmatrix} \begin{bmatrix} r^H \\ R \end{bmatrix} [\underline{a}_M]$$

$$= \left[\begin{array}{c|cccc} r(0) & & r(1) & r(2) & \dots & r(M) \\ \hline r(-1) & & r(0) & r(1) & \dots & r(M-1) \\ r(-2) & & r(-1) & r(0) & \dots & r(M-2) \\ \vdots & \vdots & \ddots & \vdots & & \\ r(-M) & & r(-M+1) & r(-M+2) & \dots & r(0) \end{array} \right] [\underline{a}_M]$$

$$= R_{M+1} \cdot \underline{a}_M = \begin{bmatrix} P_M \\ \underline{0} \end{bmatrix}$$

El objetivo es encontrar los coeficientes \underline{a}_M en un sistema de $M + 1$ ecuaciones

$$\sum_{l=0}^M a_{M,l} r(l-i) = \begin{cases} P_M, & i = 0 \\ 0, & i = 1, 2, \dots, M \end{cases}$$

Predicción hacia atrás

El sistema de ecuaciones encontrado es utilizando el método de predicción hacia adelante.

Se puede hacer también una predicción hacia atrás, se tiene $u(n), u(n-1), \dots, u(n-M+1)$ y se trata de predecir $u(n-M)$:

$$u(n-M | \underline{u}_N) = \sum_{k=0}^M g_k^* u(n-k+1)$$

Error de predicción hacia atrás:

$$b_M(n) = u(n-M) - u(n-M | \underline{u}_N)$$

Sea P_m el mínimo error cuadrático medio de predicción:

$$P_M(n) = E \left\{ |b_M(n)|^2 \right\}$$

Sea \underline{g} el vector óptimo de $M \times 1$ del predictor hacia atrás,

$$\underline{g}^T = [g_1 \quad g_2 \quad \cdots \quad g_M]$$

Para solucionar la ecuación normal para el vector \underline{g} , se requiere la matriz de correlación de M por M de la entrada $\underline{u}^T = [u_1 \quad u_2 \quad \cdots \quad u(n - M + 1)]$

$$R = E \left[\underline{u}(n) \underline{u}^H(n) \right]$$

$$R = \begin{bmatrix} r(0) & r(1) & \cdots & r(M-1) \\ r(-1) & r(0) & \cdots & r(M-2) \\ \vdots & \vdots & \ddots & \vdots \\ r(-M+1) & r(-M+2) & \cdots & r(0) \end{bmatrix}$$

Se necesita también:

$$\underline{r}^{B*} = E [\underline{u}(n) \quad u^*(n - M)]$$

$$\underline{r}^{B*T} = [r(M), \quad r(M - 1), \quad \dots \quad r(1)]$$

donde:

$$r(M - k) = E [u(n - k)u^*(n - m)], \quad k = 0, 1, \dots, M - 1$$

Se necesita también la varianza que es igual a $r(0)$

Ecuación Normal

$$R\underline{g} = \underline{r}^{Bt}$$

Error de predicción hacia atrás

$$P_M = r(0) - \underline{r}^{BT} \underline{g}$$

error de predicción

$$b_M(n) = u(n - M) - \sum_{k=1}^M g_{M,k}^* u(n - k + 1)$$

definiendo:

$$c_{M,k} = \begin{cases} -g_{k+1}, & k = 0, 1, \dots, M-1 \\ 1, & k = M \end{cases}$$

$$b_M(n) = \sum_{k=0}^M c_{M,k}^* u(n-k)$$

Se puede definir también el vector de constantes \underline{g} como

$$g_{M-k+1}^* = w_{ok}, \quad k = 1, 2, \dots, M$$

o

$$g_k = w_{o,M-k+1}^* \quad , \quad k = 1, 2, \dots, M$$

$$c_{m,k} = \begin{cases} -w_{o,M-k}^* & k = 1, 2, \dots, M-1 \\ 1, & k = M \end{cases}$$

entonces $c_{M,k} = a_{M,M-k}^*$

Entonces el error puede ser expresado en la siguiente forma:

$$b_M(n) = \sum_{k=0}^M a_{M, M-k} u(n-k)$$

Combinando la ecuación normal

$$R\underline{g} = \underline{r}^{B*}$$

y el error de predicción hacia atrás

$$P_M = r(0) - \underline{r}^{BT} \underline{g}$$

$$\begin{bmatrix} R & \underline{r}^{B*} \\ \underline{r}^{BT} & r(0) \end{bmatrix} \begin{bmatrix} -\underline{g} \\ 1 \end{bmatrix} = \begin{bmatrix} 0 \\ P_M \end{bmatrix} \quad (1)$$

$$\begin{bmatrix} R & \underline{r}^{B*} \\ \underline{r}^{BT} & r(0) \end{bmatrix} \begin{bmatrix} -\underline{g} \\ 1 \end{bmatrix} \quad (2)$$

$$= \begin{bmatrix} r(0) & r(1) & r(2) & \dots & r(M) \\ r(-1) & r(0) & r(1) & \dots & r(M-1) \\ r(-2) & r(-1) & r(0) & \dots & r(M-2) \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ r(-M) & r(-M+1) & r(-M+2) & \dots & r(0) \end{bmatrix} \begin{bmatrix} a_{M,M}^* \\ a_{M,1}^* \\ \cdot \\ \cdot \\ a_{M,0}^* \end{bmatrix}$$

$$= \begin{bmatrix} 0 \\ P_M \end{bmatrix}$$

Se tiene un sistema de $(M + 1)$ ecuaciones

$$\sum_{l=0}^M a_{M,m-l} r(l-i) = \begin{cases} 0, & i = 0, 1, \dots, M-1 \\ P_M & i = M \end{cases}$$

Sea a_M (de tamaño $M + 1$) el vector de coeficientes del filtro de predicción de error hacia adelante. Sea a_M^{B*} el vector de coeficientes del filtro de predicción de error hacia atrás, el cual puede ser obtenido reordenando al contrario los elementos del vector a_M y obteniendo su conjugado complejo.

$$\underline{a}_M = \begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ a_M \end{bmatrix}; \quad \underline{a}_M^{B*} = \begin{bmatrix} a_M^* \\ a_{M-1}^* \\ \vdots \\ a_0^* \end{bmatrix}$$

Recursión de Levison-Durbin

1.-Predicción hacia adelante:

$$\underline{a}_m = \begin{bmatrix} \underline{a}_{m-1} \\ 0 \end{bmatrix} + \Gamma_m \begin{bmatrix} 0 \\ \underline{a}_{m-1}^{B*} \end{bmatrix} = \begin{bmatrix} a_{m-1,0} \\ a_{m-1,1} \\ \vdots \\ a_{m-1,m-k} \\ \vdots \\ a_{m-1,m-1} \\ 0 \end{bmatrix} + \Gamma_m \begin{bmatrix} 0 \\ a_{m-1,m-1}^* \\ \vdots \\ a_{m-1,m-k}^* \\ \vdots \\ a_{m-1,1}^* \\ a_{m-1,0}^* \end{bmatrix}$$

Γ_M es una constante escalar.

$$a_{m,k} = a_{m-1,k} + \Gamma_m a_{m-1,m-k}^* \quad ; \quad k = 0, 1, \dots, m$$

$$a_{m-1,0} = 1 \quad y \quad a_{m-1,m} = 0$$

2.- Predicción hacia atrás

$$\underline{a}_m^{B*} = \begin{bmatrix} 0 \\ \underline{a}_{m-1}^{B*} \end{bmatrix} + \Gamma_m^* \begin{bmatrix} \underline{a}_{m-1} \\ 0 \end{bmatrix}$$

$$a_{m,m-k}^* = a_{m-1,m-k}^* + \Gamma_m^* a_{m-1,k} \quad , \quad k = 0, 1, \dots, m$$

Justificación de la constante Γ_m

$$\underline{a}_m = \begin{bmatrix} \underline{a}_{m-1} \\ 0 \end{bmatrix} + \Gamma_m \begin{bmatrix} 0 \\ \underline{a}_{m-1}^{B*} \end{bmatrix}$$

Multiplicando por R_{m+1} la matriz de correlación de las entradas en el filtro de predicción-error hacia adelante de orden m .

$$R_{m+1} \underline{a}_m = \begin{bmatrix} P_m \\ \underline{0} \end{bmatrix} = R_{m+1} \begin{bmatrix} \underline{a}_{m-1} \\ 0 \end{bmatrix} + \Gamma_m R_{m+1} \begin{bmatrix} 0 \\ \underline{a}_{m-1}^{B*} \end{bmatrix}$$

Particionando R_{m+1}

$$R_{m+1} = \begin{bmatrix} r(0) & r(1) & r(2) & \dots & r(M) \\ r(-1) & r(0) & r(1) & \dots & r(M-1) \\ r(-2) & r(-1) & r(0) & \dots & r(M-2) \\ \vdots & \vdots & \ddots & \vdots & \\ r(-M) & r(-M+1) & r(-M+2) & \dots & r(0) \end{bmatrix} = \begin{bmatrix} R_m & \underline{r}_m^{B*} \\ \underline{r}_m^{BT} & r(0) \end{bmatrix}$$

Entonces:

$$\begin{aligned} R_{m+1} \begin{bmatrix} \underline{a}_{m-1} \\ 0 \end{bmatrix} &= \begin{bmatrix} R_m & \underline{r}_m^{B*} \\ \underline{r}_m^{BT} & r(0) \end{bmatrix} \begin{bmatrix} \underline{a}_{m-1} \\ 0 \end{bmatrix} \\ &= \begin{bmatrix} R_m & \underline{a}_{m-1} \\ \underline{r}_m^{BT} & \underline{a}_{m-1} \end{bmatrix} \end{aligned}$$

$$R_m \underline{a}_{m-1} = \begin{bmatrix} P_{m-1} \\ \underline{0}_{m-1} \end{bmatrix}$$

Definase el escalar

$$\Delta_{m-1} = \underline{r}_m^{BT} \underline{a}_{m-1} = [r(-m), \quad r(1-m), \quad \dots \quad r(-1)] \begin{bmatrix} a_{m-1,0} \\ a_{m-1,1} \\ \vdots \\ a_{m-1,m-1} \end{bmatrix}$$

$$= \sum_{k=0}^{m-1} a_{m-1} r(k-m)$$

entonces

$$R_{m+1} \begin{bmatrix} \underline{a}_{m-1} \\ 0 \end{bmatrix} = \begin{bmatrix} R_m & \underline{a}_{m-1} \\ \underline{r}_m^{BT} & \underline{a}_{m-1} \end{bmatrix} = \begin{bmatrix} P_{m-1} \\ \underline{0}_{m-1} \\ \Delta_{m-1} \end{bmatrix}$$

Por otra parte

$$R_{m+1} = \begin{bmatrix} r(0) & \underline{r}_m^H \\ \underline{r}_m & R_m \end{bmatrix}$$

$$R_{m+1} \begin{bmatrix} 0 \\ \underline{a}_{m-1}^{B*} \end{bmatrix} = \begin{bmatrix} r(0) & \underline{r}_m^H \\ \underline{r}_m & R_m \end{bmatrix} \begin{bmatrix} 0 \\ \underline{a}_{m-1}^{B*} \end{bmatrix}$$

$$= \begin{bmatrix} \underline{r}_m^H \underline{a}_{m-1}^H \\ R_m \underline{a}_{m-1}^H \end{bmatrix}$$

$$\underline{r}_m^H \underline{a}_{m-1}^H = [r(1) \quad r(2) \quad \dots \quad r(m)] \begin{bmatrix} a_{m-1,m-1}^* \\ a_{m-1,m-2}^* \\ \vdots \\ a_{m-1,0}^* \end{bmatrix}$$

$$= \sum_{k=1}^m a_{m-1, m-k}^* r(k) = \Delta_{m-1}^*$$

Por otra parte

$$R_m \underline{a}_{m-1}^{B^*} = \begin{bmatrix} \underline{0}_{m-1} \\ P_{m-1} \end{bmatrix}$$

$$R_{m+1} \begin{bmatrix} 0 \\ \underline{a}_{m-1}^{B^*} \end{bmatrix} = \begin{bmatrix} \Delta_{m-1}^* \\ \underline{0}_{m-1} \\ P_{m-1} \end{bmatrix}$$

Regresando al principio

$$\underline{a}_m = \begin{bmatrix} \underline{a}_{m-1} \\ 0 \end{bmatrix} + \Gamma_m \begin{bmatrix} 0 \\ \underline{a}_{m-1}^{B^*} \end{bmatrix}$$

Multiplicando por R_{m+1}

$$\begin{aligned} R_{m+1}\underline{a}_m &= R_{m+1} \begin{bmatrix} \underline{a}_{m-1} \\ 0 \end{bmatrix} + R_{m+1}\Gamma_m \begin{bmatrix} 0 \\ \underline{a}_{m-1}^{B*} \end{bmatrix} \\ &= \begin{bmatrix} P_m \\ \underline{0}_m \end{bmatrix} = \begin{bmatrix} P_{m-1} \\ \underline{0}_{m-1} \\ \Delta_{m-1} \end{bmatrix} + \Gamma_m \begin{bmatrix} \Delta_{m-1}^* \\ \underline{0}_{m-1} \\ P_{m-1} \end{bmatrix} \end{aligned}$$

Para que esta recursión se sostenga se necesita que:

$$P_m = P_{m-1} + \Gamma_m \Delta_{m-1}^*$$

$$0 = \Delta_{m-1} + \Gamma_m P_{m-1}$$

$$\Gamma_m = \frac{-\Delta_{m-1}}{\Gamma_m P_{m-1}}$$

$$\Delta_{m-1} = -\Gamma_m P_{m-1}$$

$$\Delta_{m-1}^* = -\Gamma_m^* P_{m-1}$$

Entonces:

$$P_m = P_{m-1} + \Gamma_m(-\Gamma_m^* P_{m-1}) = P_{m-1} - P_{m-1}|\Gamma_m|^2 = P_{m-1}(1 - |\Gamma_m|^2)$$

La forma de aplicar la recursión Levinson- Durbin es la siguiente:

Se cuenta con la función de autocorrelación del proceso de entrada $r(0), r(1), \dots, r(M)$. Función de autocorrelación para retrasos de $0, 1, \dots, M$ respectivamente.

Estimador de la función de autocorrelación:

$$r(k) = \frac{1}{N-1} \sum_{n=1}^{N-k} u(n)u^*(n-k), \quad k = 0, 1, \dots, M$$

en donde N es el número de muestras, con $N \gg M$. Dado $r(0), r(1), \dots, r(M)$

La recursión empieza con:

$$\Delta_{m-1} = \sum_{k=0}^{m-1} a_{m-1,k} r(k-m)$$

y

$$P_m = P_{m-1} + \Gamma_m \Delta_{m-1}^*$$

Se empieza con $m = 0$

$$P_0 = r(0)$$

$$\Delta_0 = r(-1)$$

$$a_{m,0} = 1 \quad \text{para todas las } m_s$$

$$\text{y } a_{m,k} = 0 \quad \text{para } k > m$$

El calculo termina con $m = M$

$$\underline{a}_m = \begin{bmatrix} \underline{a}_{m-1} \\ 0 \end{bmatrix} + \Gamma_m \begin{bmatrix} 0 \\ \underline{a}_{m-1}^{B*} \end{bmatrix}$$

$$\Gamma_m = \frac{-\Delta_{m-1}}{P_{m-1}}$$

Ejemplo:

Considerese un predictor de orden $p = 2$ Asumiendo que se cuenta con las correlaciones $r = (r(0), r(1), r(2))$. Encuentra los coeficientes de LPC.

Solución de Wiener.

$$\begin{bmatrix} r(0) & r(1) \\ r(1) & r(0) \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \end{bmatrix} = \begin{bmatrix} r(1) \\ r(2) \end{bmatrix}$$

Por Kramer:

$$\det = r(0)^2 - r(1)^2$$

$$w_1 = \frac{\begin{vmatrix} r(1) & r(1) \\ r(2) & r(0) \end{vmatrix}}{\det} = \frac{r(1)r(0) - r(2)r(1)}{r(0)^2 - r(1)^2} = -a_1$$

$$w_2 = \frac{\begin{vmatrix} r(0) & r(1) \\ r(1) & r(2) \end{vmatrix}}{\det} = \frac{r(0)r(2) - r(1)^2}{r(0)^2 - r(1)^2} = -a_2$$

Solución utilizando el algoritmo de Levinson-Durbin

Formulas Recursivas

$$\Delta_{m-1} = \sum_{k=0}^{m-1} a_{m-1,k} r(k-m); a_m = \begin{bmatrix} a_{m-1} \\ 0 \end{bmatrix} + \Gamma_m \begin{bmatrix} 0 \\ a_{B^*}^{m-1} \end{bmatrix}$$

$$\Gamma_m = \frac{-\Delta_{m-1}}{P_{m-1}}$$

$$P_m = P_{m-1} + r_m \Delta_{m-1};$$

$$a_{m,0} = 1, a_{m,k=0}, k > m$$

Ecuación Normal

$$\underline{r} - R\underline{w}_{opt} = 0$$

$$r(0) - \underline{r}^H \cdot \underline{w}_{opt} = P_M$$

$$\begin{bmatrix} r(0) & \underline{r}^H \\ \underline{r} & R \end{bmatrix} \begin{bmatrix} 1 \\ -\underline{w}_{opt} \end{bmatrix} = \begin{bmatrix} P_M \\ 0 \end{bmatrix}$$

$$\underline{a}_M = \begin{bmatrix} 1 \\ -\underline{w}_{opt} \end{bmatrix}$$

\underline{a}_M es un vector de $M + 1$ elementos Para $M = 0$

$$\Rightarrow \underline{a}_M = [1]$$

Por lo tanto:

$$r(0) = P_M$$

$$m = 0$$

$$a_{0,0} = 1$$

$$m = 1$$

$$\Delta_{1-1} = \Delta_0 = \sum_{k=0}^0 r(k-1) = r(-1) = r(1)$$

$$P_0 = r(0)$$

$$r_1 = \frac{-\Delta_0}{P_0} = \frac{-r(1)}{r(0)}$$

$$\underline{a}_1 = \begin{bmatrix} 1 \\ 0 \end{bmatrix} + \left(\frac{-r(1)}{r(0)} \right) \begin{bmatrix} 0 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 \\ \frac{-r(1)}{r(0)} \end{bmatrix}$$

$$\underline{a}_1^{B*} = \begin{bmatrix} \frac{-r(1)}{r(0)} \\ 1 \end{bmatrix}$$

$$\begin{aligned}
 P_1 &= P_0 + \Gamma_1 A_0 = r(0) + \frac{-r(1)}{r(0)} \cdot r(1) = r(0) - \frac{r(1)^2}{r(0)} \\
 &= \frac{r(0)^2 - r(1)^2}{r(0)}
 \end{aligned}$$

$m = 2$

$$\Delta_1 = \sum_{k=0}^1 a_{1,k} r(k-2) = a_{1,0} r(-2) + a_{1,1} r(-1)$$

$$= r(2) - \frac{r(1)}{r(0)} r(1) = \frac{r(0)r(2) - r(1)^2}{r(0)}$$

$$\Gamma_2 = \frac{-\Delta_1}{P_1} = \frac{-\frac{r(0)r(2) - r(1)^2}{r(0)}}{\frac{r(0)^2 - r(1)^2}{r(0)}} = \frac{-r(0)r(2) + r(1)^2}{r(0)^2 - r(1)^2}$$

$$a_2 = \begin{bmatrix} 1 \\ \frac{-r(1)}{r(0)} \\ 0 \end{bmatrix} + \frac{-r(0)r(2) + r(1)^2}{r(0)^2 - r(1)^2} \begin{bmatrix} 0 \\ \frac{-r(1)}{r(0)} \\ 1 \end{bmatrix}$$

$$\begin{bmatrix} 1 \\ \frac{-r(1)}{r(0)} + \left(\frac{-r(0)r(2) + r(1)^2}{r(0)^2 - r(1)^2} \right) \left(\frac{-r(1)}{r(0)} \right) \\ \frac{-r(0)r(2) + r(1)^2}{r(0)^2 - r(1)^2} \end{bmatrix}$$

$$\begin{aligned} a_{2,1} &= \frac{-r(1)}{r(0)} + \frac{r(1)r(0)r(2) - r(1)^3}{r(0)^3 - r(1)^2r(0)} \\ &= \frac{-r(1) \cdot (r(0)^3 - r(1)^2r(0)) + r(0)^2r(1)r(2) - r(1)^3r(0)}{r(0)(r(0)^3 - r(1)^2r(0))} \end{aligned}$$

$$\begin{aligned}
&= \frac{-r(1)r(0)^3 - r(1)^3r(0) + r(0)^2r(1)r(2) - r(1)^3r(0)}{r(0)(r(0)^3 - r(1)^2r(0))} \\
&= \frac{-r(1)r(0)^3 + r(0)^2r(1)r(2)}{r(0)(r(0)^3 - r(1)^2r(0))} = \frac{-r(1)r(0)^3 + r(0)^2r(1)r(2)}{r(0)^2(r(0)^2 - r(1)^2)} \\
&= \frac{-r(1)r(0) + r(1)r(2)}{r(0)^2 - r(1)^2} = a_{2,1} = -w_1 \\
a_{2,2} &= \frac{-r(0)r(2) + r(1)^2}{r(0)^2 - r(1)^2} = -w_2
\end{aligned}$$