

III. 補注

補注1 3.2 デジタル労働投入量の離散近似について

$$\text{最初に } L = \sum_i A_i B_i \text{ —— (1)}$$

で定義される労働投入コストについて考える。

(A は所定内賃金、 B は労働者数、 i は性、学歴、勤続年数及び年齢階級の組み合わせを表す添え字)

時間微分をドットで表すと

$$\dot{L} = \sum_i (\dot{A}_i B_i + A_i \dot{B}_i) \text{ となり}$$

$$\frac{\dot{L}}{L} = \sum_i \left(\frac{\dot{A}_i B_i}{L} + \frac{A_i \dot{B}_i}{L} \right) = \sum_i \left(\frac{\dot{A}_i B_i}{A_i} \frac{A_i}{L} + \frac{A_i \dot{B}_i}{B_i} \frac{B_i}{L} \right) = \sum_i \left\{ \left(\frac{\dot{A}_i}{A_i} + \frac{\dot{B}_i}{B_i} \right) \left(\frac{A_i B_i}{L} \right) \right\}$$

ここで $\frac{A_i B_i}{L} = \frac{A_i B_i}{\sum_i A_i B_i} = v_i$ と書けば

$$\frac{\dot{L}}{L} = \sum_i v_i \left(\frac{\dot{A}_i}{A_i} + \frac{\dot{B}_i}{B_i} \right) \text{ —— (2) となる。 } (v_i \text{ の定義より } \sum_i v_i = 1)$$

(2)式の右辺のうち、所定内賃金の変化率を表す $\frac{\dot{A}_i}{A_i}$ を無視すれば賃金の変動を取り除くことができ、労働者数の変化の影響のみを分析することができる。

B を $B = \sum_i B_i$ で定義し、 $B_i = b_i B$ と書けば

$$\frac{\dot{B}_i}{B_i} = \frac{\dot{b}_i}{b_i} + \frac{\dot{B}}{B} \text{ となる。}$$

従って、(2)式の右辺の $\frac{\dot{A}_i}{A_i}$ を取り除いた部分については $\sum_i v_i = 1$ を使うと

$$\sum_i v_i \left(\frac{\dot{b}_i}{b_i} + \frac{\dot{B}}{B} \right) = \left(\sum_i v_i \frac{\dot{b}_i}{b_i} \right) + \frac{\dot{B}}{B} \quad (3) \text{ となり、}$$

(3) 式の右辺の第 1 項を労働の質の変化率と本書では呼んでいる。

(3) 式の右辺の第 1 項を用いて (記号の濫用で再び L を使用して) 新たに $\frac{\dot{L}}{L}$ を定義すれば、ディビジア労働投入量 L を微分方程式で定義したことになる。

$$\frac{\dot{L}}{L} = \sum_i v_i \frac{\dot{b}_i}{b_i} \quad (4)$$

(4) の両辺を時間 t で $T - \Delta T$ から T まで積分すると

$$\int_{T-\Delta T}^T \frac{1}{L} \frac{dL}{dt} dt = \int_{T-\Delta T}^T \sum_i v_i \frac{db_i}{b_i} dt = \sum_i \int_{T-\Delta T}^T \frac{v_i}{b_i} \frac{db_i}{dt} dt \quad (5)$$

(5) の右辺の各 i について $\frac{db_i}{dt}$ の被積分区間での定符号性を仮定すると積分の平均値の定理が適用でき、(5) は

$$\ln L(T) - \ln L(T - \Delta T) = \sum_i v_i (T - \theta_i \Delta T) \{ \ln b_i(T) - \ln b_i(T - \Delta T) \} \quad (6)$$

(各 i について $0 \leq \theta_i \leq 1$)

となる。

($v_i(T - \theta_i \Delta T)$ は、 v_i を時間の関数と考えたとき、その関数が区間 $[T - \Delta T, T]$ で取る値のいずれかである。)

(6) 式で $\Delta T = 1$ の時を考えると、時点 $T - \theta_i$ での関数 v_i の値としては実測できる時間 $T - 1$ と T の時点の値の平均を採用することが実際的であるので、結局、離散近似は

$$\ln L(T) - \ln L(T - 1) = \sum_i \frac{v_i(T) + v_i(T - 1)}{2} \{ \ln b_i(T) - \ln b_i(T - 1) \}$$

となる。

補注2 3.2 労働サービスのディブジア指数について

今、 S を S_i ($i = 1, \dots, n$) の関数と考える。

$S = S(S_1, \dots, S_n)$ (この時点では関数形を仮定していない。)

この時 $\ln S$ を $\ln S_i$ ($i = 1, \dots, n$) の関数と考え時間 t で微分すると

$$\frac{d \ln S}{dt} = \sum \frac{\partial \ln S}{\partial \ln S_i} \frac{d \ln S_i}{dt}$$

よって時間微分をドットで表せば

$$\frac{\dot{S}}{S} = \sum \frac{\partial \ln S}{\partial \ln S_i} \frac{\dot{S}_i}{S_i} \quad \text{————— (1)}$$

となる。

また、合成関数の微分を考えると

$$\frac{\partial \ln S}{\partial \ln S_i} = \frac{d \ln S}{dS} \frac{\partial S}{\partial S_i} \frac{dS_i}{d \ln S_i} = \frac{\partial S}{\partial S_i} \frac{S_i}{S} \quad \text{————— (2)}$$

となる。ここで労働サービスの投入について、完全競争下の限界生産力の仮定により、偏微分係数は単位労働当たりの賃金 (w) の比で表されるとすると

$$\frac{\partial S}{\partial S_i} = \frac{w_i}{w} \text{ となり (2) により}$$

$$\frac{\partial \ln S}{\partial \ln S_i} = \frac{w_i S_i}{w S} \quad \text{————— (3)}$$

となる。

(3) 式の右辺の分子は労働サービス S_i に必要な労働コストであり、分母は労働サービス S に必要な労働コストであるので、 S_i のコストシェアを表している。

(3) 式の右辺を v_i と書き (1) に代入すると、

$$\frac{\dot{S}}{S} = \sum v_i \frac{\dot{S}_i}{S_i} \quad \text{となる。}$$

補注3 7.6 フロー確率行列の収束について

(本書の範囲では3次の正方行列について収束を示せば事足りるが、一般に成り立つ性質なので、一般の行列について説明する。)

n 次元の正方行列 $A = (a_{ij})$ について $a_{ij} > 0$, $\sum_{i=1}^n a_{ij} = 1$ とする。

1) 正值、列和の継承性

この行列の m 乗を $A^m = (a_{ij}^{(m)})$ と書くことにすれば

$$A^{m+1} = AA^m = A^m A \quad \text{であるので}$$

$$a_{ij}^{(m+1)} = \sum_{k=1}^n a_{ik} a_{kj}^{(m)} = \sum_{k=1}^n a_{ik}^{(m)} a_{kj} \quad \text{となり、}$$

$$a_{ij}^{(m)} > 0, \quad \sum_{i=1}^n a_{ij}^{(m)} = 1 \quad \text{が成立すれば、}$$

$$a_{ij}^{(m+1)} > 0 \quad \text{は明らかであり、}$$

$$\sum_{i=1}^n a_{ij}^{(m+1)} = \sum_{i=1}^n \sum_{k=1}^n a_{ik} a_{kj}^{(m)} = \sum_{k=1}^n \sum_{i=1}^n a_{ik} a_{kj}^{(m)} = \sum_{k=1}^n a_{kj}^{(m)} \left(\sum_{i=1}^n a_{ik} \right) = \sum_{k=1}^n a_{kj}^{(m)} = 1$$

となる。

従って、数学的帰納法により、全ての m について $a_{ij}^{(m)} > 0$, $\sum_{i=1}^n a_{ij}^{(m)} = 1$ と

なる。

2) 各行の最大値、最小値の評価

行列 A の要素 a_{ij} の最小値を γ とする。

$$A \text{ の列和が } 1 \text{ であるので、} \quad 0 < \gamma \leq \frac{1}{n} \quad \text{———— (1)}$$

が成立する。また、 A^m の i 行 $a_{ik}^{(m)}$ ($k = 1, 2, \dots, n$) の最大値を $g_i^{(m)}$ 、最小値を $l_i^{(m)}$ とし、この時実際に最大値、最小値を取る k の値 (の代表) をそれぞれ k_g 、 k_l とする。

$A^{m+1} = A^m A$ における i 行を考えてみる。

$$\begin{pmatrix} \dots\dots\dots \\ \vdots & \vdots & \vdots \\ a_{i1}^{(m)} & a_{i2}^{(m)} & \dots & a_{in}^{(m)} \\ \vdots & \vdots & \vdots \\ \dots\dots\dots \end{pmatrix} \begin{pmatrix} a_{11} \cdots a_{1j} \cdots a_{1n} \\ \vdots & \vdots & \vdots \\ a_{k1} \cdots a_{kj} \cdots a_{kn} \\ \vdots & \vdots & \vdots \\ a_{n1} \cdots a_{nj} \cdots a_{nn} \end{pmatrix}$$

$$a_{ij}^{(m+1)} = \sum_{k=1}^n a_{ik}^{(m)} a_{kj} = a_{ik_l}^{(m)} a_{k_l j} + \sum_{k \neq k_l} a_{ik}^{(m)} a_{kj} = l_i^{(m)} a_{k_l j} + \sum_{k \neq k_l} a_{ik}^{(m)} a_{kj}$$

右辺の第 2 項を $g_i^{(m)}$ で評価すると

$$a_{ij}^{(m+1)} \leq l_i^{(m)} a_{k_l j} + \sum_{k \neq k_l} g_i^{(m)} a_{kj} = (l_i^{(m)} - g_i^{(m)}) a_{k_l j} + \sum_{k=1}^n g_i^{(m)} a_{kj} =$$

$$(l_i^{(m)} - g_i^{(m)}) a_{k_l j} + g_i^{(m)} = g_i^{(m)} - a_{k_l j} (g_i^{(m)} - l_i^{(m)}) \leq g_i^{(m)} - \gamma (g_i^{(m)} - l_i^{(m)}) \text{--- (2)}$$

同様にして $l_i^{(m)}$ で評価すると、

$$a_{ij}^{(m+1)} = \sum_{k=1}^n a_{ik}^{(m)} a_{kj} = a_{ik_g}^{(m)} a_{k_g j} + \sum_{k \neq k_g} a_{ik}^{(m)} a_{kj} = g_i^{(m)} a_{k_g j} + \sum_{k \neq k_g} a_{ik}^{(m)} a_{kj}$$

$$\geq g_i^{(m)} a_{k_g j} + \sum_{k \neq k_g} l_i^{(m)} a_{kj} = (g_i^{(m)} - l_i^{(m)}) a_{k_g j} + \sum_{k=1}^n l_i^{(m)} a_{kj} =$$

$$(g_i^{(m)} - l_i^{(m)})a_{k_g j} + l_i^{(m)} \geq l_i^{(m)} + \gamma(g_i^{(m)} - l_i^{(m)}) \quad \text{———— (3)}$$

(2)、(3) は、 A^m の各 i 行を (n 個の個別ウェイトで) 加重平均したものととなっている A^{m+1} の各 i 行は、① A^m の i 行の最大値、② A^m の i 行の最小値及び③ (ウェイトである) A の最小値という (i に依存する) 3つの要素のみで評価できることを表している。

3) 各行の最大値、最小値の収束

(2)、(3) により A^{m+1} の各 i 行の $a_{ij}^{(m+1)}$ ($j = 1, 2, \dots, n$) について以下の不等式が成立する。

$$l_i^{(m)} + \gamma(g_i^{(m)} - l_i^{(m)}) \leq a_{ij}^{(m+1)} \leq g_i^{(m)} - \gamma(g_i^{(m)} - l_i^{(m)})$$

これにより、最大値、最小値の定義から直ちに以下の不等式が成り立つ。

$$l_i^{(m)} + \gamma(g_i^{(m)} - l_i^{(m)}) \leq l_i^{(m+1)} \leq a_{ij}^{(m+1)} \leq g_i^{(m+1)} \leq g_i^{(m)} - \gamma(g_i^{(m)} - l_i^{(m)})$$

———— (4)

また、 $g_i^{(m)} - l_i^{(m)} \geq 0$ より

$$l_i^{(m)} \leq l_i^{(m)} + \gamma(g_i^{(m)} - l_i^{(m)}) \quad \text{と}$$

$g_i^{(m)} - \gamma(g_i^{(m)} - l_i^{(m)}) \leq g_i^{(m)}$ は明らかである。

従って、数列 $g_i^{(m)}$ と $l_i^{(m)}$ とはそれぞれ単調有界数列となり極限が存在する。

4) 行列の収束

上記で存在が確認できた数列 $g_i^{(m)}$ と $l_i^{(m)}$ の極限をそれぞれ g_i 、 l_i とする。

この時 $g_i = l_i$ となることが以下のようにして示される。

(4) 式により、

$$g_i^{(m+1)} \leq g_i^{(m)} - \gamma(g_i^{(m)} - l_i^{(m)})$$

$$-l_i^{(m+1)} \leq -l_i^{(m)} - \gamma(g_i^{(m)} - l_i^{(m)})$$

辺々をそれぞれ足し合わせれば

$$g_i^{(m+1)} - l_i^{(m+1)} \leq g_i^{(m)} - l_i^{(m)} - 2\gamma(g_i^{(m)} - l_i^{(m)}) = (1 - 2\gamma)(g_i^{(m)} - l_i^{(m)})$$

よって

$$0 \leq g_i^{(m+1)} - l_i^{(m+1)} \leq (1 - 2\gamma)^m (g_i^{(1)} - l_i^{(1)}) \quad \text{————— (5)}$$

(1) により、 $n \geq 2$ であれば $0 \leq 1 - 2\gamma < 1$ となるので、
 $m \rightarrow \infty$ の時 (5) 式の右辺 $\rightarrow 0$ となり、 $g_i = l_i$ となる。

($n = 1$ の場合は $A = (\mathbf{1})$ となり、自明。)

この極限値を改めて α_i と書けば、(4) 式は i 行の各要素 $a_{ij}^{(m+1)}$ が全て α_i に収束することを表している。

従って $m \rightarrow \infty$ の時の A^m の極限を A^* と書けば

$$A^* = \begin{pmatrix} \alpha_1 \cdots \alpha_1 \\ \alpha_2 \cdots \alpha_2 \\ \vdots \cdots \vdots \\ \alpha_n \cdots \alpha_n \end{pmatrix} \quad \text{となり、} \alpha_i > 0 \text{ かつ } \sum_{i=1}^n \alpha_i = 1.$$

さらに、 $a_{ij}^{(m+1)} = \sum_{k=1}^n a_{ik} a_{kj}^{(m)}$ の極限を考えると

$$\alpha_i = \sum_{k=1}^n a_{ik} \alpha_k \quad \text{————— (6)}$$

となる。

5) 状態ベクトルの極限

状態ベクトルをフロー確率行列 A を用いて $X(t) = A^t X(0)$ ($t = 1, 2, \dots$)

で定義すれば、その初期値 $X(0)$ に依存する極限 $X^* \Big|_{X(0)}$ は

$X^*|_{X(0)} = \lim_{t \rightarrow \infty} X(t) = \lim_{t \rightarrow \infty} A^t X(0) = (\lim_{t \rightarrow \infty} A^t) X(0) = A^* X(0)$ となる。

$X(0)$ の成分について $\sum_{j=1}^n x_j(0) = 1$ が成り立っているので、

$X^*|_{X(0)} = A^* X(0)$ の各成分 $x_j^*|_{X(0)}$ は

$$x_j^*|_{X(0)} = \sum_{i=1}^n \alpha_j x_i(0) = \alpha_j \sum_{i=1}^n x_i(0) = \alpha_j \text{ となり、}$$

実は初期値に関係なく一定の状態に収束する。

その初期値 $X(0)$ に依存しない極限を改めて X^* と書く。

6) 定常状態

$A^* X^*$ の第 i 成分を考えてみると $\sum_{j=1}^n \alpha_i \alpha_j = \alpha_i \sum_{j=1}^n \alpha_j = \alpha_i$ となり

$A^* X^* = X^*$ となっている。

また、同様に $A X^*$ の第 i 成分を考えると $\sum_{j=1}^n a_{ij} \alpha_j$ となり (6) 式によりこ

れは α_i に等しくなり $A X^* = X^*$ となっている。

つまり、 X^* は A と A^* の両方に対応した定常状態となっている。

補注4 7.6 1か月未満の流出入を考慮したフロー確率行列について

「単位期間内の j から i への移動件数は、 j の人数に比例する」を仮定する。
 時点 t から時点 $t + \Delta t$ までの移動件数は、 j から i への変化の比例係数を r_{ij}
 とすると、流出分と流入分を考えることにより、

$$x_j(t + \Delta t) - x_j(t) = \Delta t \cdot \left\{ -\sum_{i \neq j} r_{ij} \cdot x_j(t) + \sum_{i \neq j} r_{ji} \cdot x_i(t) \right\} \quad \text{となる。}$$

ここで $r_{jj} = 1 - \sum_{i \neq j} r_{ij}$ と定義すれば

$$x_j(t + \Delta t) - x_j(t) = \Delta t \cdot \left\{ (r_{jj} - 1) \cdot x_j(t) + \sum_{i \neq j} r_{ji} \cdot x_i(t) \right\} \quad \text{—— (1)}$$

$$R = \begin{pmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{pmatrix} \quad \text{とおけば (1) 式の行列表示は } I \text{ を単位行列として}$$

$$X(t + \Delta t) - X(t) = \Delta t \cdot (R - I)X(t) \quad \text{となる。}$$

$$\text{従って、} \frac{X(t + \Delta t) - X(t)}{\Delta t} = (R - I)X(t)$$

$\Delta t \rightarrow 0$ とすると

$$\frac{dX(t)}{dt} = (R - I)X(t) \quad \text{—— (2)}$$

ここで、一般の正方行列 F に対して、整級数 $\sum_{k=0}^{\infty} c_k x^k$ (収束半径を $\rho > 0$ と

する) が与えられた時に、行列 $\sum_{k=0}^{\infty} c_k F^k$ を各要素ごとの無限級数を要素として持つ行列として定義すれば、 F の固有値の絶対値が全て ρ より小さい時 (すなわち F のノルム $\|F\|$ が ρ より小さい時) この行列 (の要素である各級数) は収束することが知られている。

従って、 $e^x = \sum_{k=0}^{\infty} \frac{x^k}{k!}$ の収束半径は ∞ なので、任意の F に対して

$$e^F = \sum_{k=0}^{\infty} \frac{F^k}{k!} \quad \text{が定義できる。 (ただし、} F^0 = I \text{)} \quad \text{この時 } FG = GF$$

が成り立てば、 $e^{F+G} = e^F e^G$ となることも知られている。
このことを使えば微分方程式 (2) の基本解は

$$e^{t(R-I)} = \sum_{k=0}^{\infty} \frac{t^k}{k!} (R-I)^k \quad (\text{ただし、任意の } t \text{ について } t^0 = 1)$$

で与えられる。

(項別微分すれば

$$\frac{de^{t(R-I)}}{dt} = \sum_{k=1}^{\infty} \frac{t^{k-1}}{(k-1)!} (R-I)^k = (R-I) \sum_{k=1}^{\infty} \frac{t^{k-1}}{(k-1)!} (R-I)^{k-1} = (R-I) \sum_{k=0}^{\infty} \frac{t^k}{k!} (R-I)^k$$

となることがわかる。)

従って、 $X(0)$ を初期ベクトルとすれば、 $t = 0$ の時

$$e^{t(R-I)} = \sum_{k=0}^{\infty} \frac{t^k}{k!} (R-I)^k \text{ は } I \text{ となるので、}$$

$$X(t) = e^{t(R-I)} X(0) \quad \text{—————} \quad (3)$$

は初期条件を満たす (2) の解であることが確認できる。

(3) で $t = T+1$ とすれば

$$X(T+1) = e^{(T+1)(R-I)} X(0) = e^{(R-I)+T(R-I)} X(0) = e^{R-I} e^{T(R-I)} X(0) = e^{R-I} X(T)$$

$X(T+1) = AX(T)$ であったので

$$A = e^{(R-I)} \quad \text{—————} \quad (4)$$

となる。

ここで対数関数のマクローリン展開

$$\log(1+x) = \sum_{k=1}^{\infty} \frac{(-1)^{k-1}}{k} x^k \quad (|x| < 1) \text{ を考えると、対応する行列 } F \text{ の級}$$

数表現は

$$\log(I+F) = \sum_{k=1}^{\infty} \frac{(-1)^{k-1}}{k} F^k \quad (\|F\| < 1) \text{ となり、この行列は}$$

$e^{\log(I+F)} = I+F$ を満たす。

$$F \text{ のノルム } \|F\| \text{ の評価は } \|F\| = \max_{1 \leq i \leq n} \sum_{j=1}^n |f_{ij}| \quad (f_{ij} \text{ は } F \text{ の要素}) \text{ となる}$$

ので、

A がマルコフ行列であること (要素の非負性及び行和が 1 となること) を考慮すれば

$$|a_{jj} - 1| + \sum_{i \neq j} |a_{ij}| = 1 - a_{jj} + \sum_{i \neq j} a_{ij} = 1 - a_{jj} + 1 - a_{jj} = 2 \cdot (1 - a_{jj}) < 1$$

であれば上記のノルムの条件を満たす。従って、例えば A の対角成分が全て 0.5 より大きい時に

$$\log(A) \text{ は } \log(A) = \log(I + (A - I)) = \sum_{k=1}^{\infty} \frac{(-1)^{k-1}}{k} (A - I)^k$$

により定義できることがわかる。

従って、行列 R は (4) 式より

$$R - I = \log(A) \quad \text{すなわち}$$

$$R = I + \log(A) \quad \text{————— (5)}$$

と表せる。

次に、 B の定常状態について考える。

期間 T から期間 $T+1$ までの j から i への移動総件数は r_{ij} と $x_j(t)$ を使って

$\int_T^{T+1} r_{ij} x_j(t) dt$ と表せるので B の (i, j) 成分 ($i \neq j$) は、

$$b_{ij} = \frac{\int_T^{T+1} r_{ij} x_j(t) dt}{x_j(T)} = r_{ij} \frac{\int_T^{T+1} x_j(t) dt}{x_j(T)} \text{ となる。}$$

積分の平均値の定理を使えば $\int_T^{T+1} x_j(t) dt = x_j(T + \theta_T)$ ($0 < \theta_T < 1$) と

評価できるので、状態ベクトル $X(t)$ が定常状態に近づけば $b_{ij} \rightarrow r_{ij}$ となる。

また、この時 r_{jj} の定義より $b_{jj} \rightarrow r_{jj}$ は明らかで、結局 $B \rightarrow R$ となる。従って定常状態においては $B = R$ となる。

A の定常ベクトル X^* について $(A - I)X^* = O$ (O は零ベクトル) を考慮して BX^* を計算してみると、 B の定常状態では $B = R$ であるので、

$$BX^* = \left(I + \sum_{k=1}^{\infty} \frac{(-1)^{k-1}}{k} (A - I)^k \right) X^* = X^* + \sum_{k=1}^{\infty} \frac{(-1)^{k-1}}{k} (A - I)^k X^* = X^*$$

となり X^* は $B (= R)$ の定常ベクトルともなっていることが確認できる。

補注5 7.6 失業継続期間の推計について

「失業継続期間」とは失業が発生してから失業状態が終了するまでの期間の期待値（平均的な失業期間）である。

失業が発生してから t 期間継続する確率を $P(t)$ 、失業継続期間を \bar{T} とすると、

$$\bar{T} = \int_0^{\infty} P(t) dt \quad \text{となる。}$$

このことは次のようにして確かめられる。

t 期間継続する確率 $P(t)$ とは、失業発生時を時点 0 とし、時点 t で失業が続いているものの割合となる。

一方、失業の終了の確率密度関数を $f(t)$ とすれば、時点 T までに失業が終了する累積確率 $Pob(t \leq T)$ は

$$Pob(t \leq T) = \int_0^T f(t) dt \quad \text{で与えられる。}$$

この時 $\frac{dPob(t \leq T)}{dT} = f(T)$ となり、 \bar{T} は確率変数の期待値の定義に

従うと $\bar{T} = \int_0^{\infty} tf(t) dt$ となる。

また、 $P(t)$ と $Pob(t \leq T)$ の関係を考えると、

$$P(T) = 1 - Pob(t \leq T) = 1 - \int_0^T f(t) dt = \int_0^{\infty} f(t) dt - \int_0^T f(t) dt = \int_T^{\infty} f(t) dt$$

となり ($\because \int_0^{\infty} f(t) dt = 1$)、 $\frac{dP(t)}{dt} = -f(t)$ となる。

上記の準備の下で、 $\int_0^{\infty} P(t) dt$ について考える。

$\int_0^{\infty} P(t) dt = \lim_{S \rightarrow \infty} \int_0^S P(t) dt$ であるので、 $\int_0^S P(t) dt$ について考えてみる。部分積分すれば

$$\int_0^S P(t)dt = [tP(t)]_0^S - \int_0^S t \frac{dP(t)}{dt} dt = S \int_S^\infty f(t)dt + \int_0^S tf(t)dt$$

ここで、被積分区間では $S \leq t$ であることに注意して $S \int_S^\infty f(t)dt$ を評価

すると $(\bar{T} = \int_0^\infty tf(t)dt$ の収束を仮定して)

$$0 \leq S \int_S^\infty f(t)dt \leq \int_S^\infty tf(t)dt = \int_0^\infty tf(t)dt - \int_0^S tf(t)dt \rightarrow 0 \quad (S \rightarrow \infty)$$

従って、 $S \rightarrow \infty$ の時 $\int_0^S P(t)dt \rightarrow \int_0^\infty tf(t)dt = \bar{T}$ を得る。

一方、失業からの流出率が一定だと仮定すると、継続失業者についても流出率は等しいという自然な仮定の下で、 t 時点での継続失業者数を $u(t)$ 、(共通の) 流出率を r とすれば微分方程式

$$\frac{du(t)}{dt} = -ru(t) \quad \text{が成り立つ。}$$

これを解けば $u(t) = \exp(-rt)u(0)$ となる。

定義を考えれば $P(t) = \frac{u(t)}{u(0)}$ であるので、結局、

$$P(t) = \exp(-rt) \quad \text{となり、}$$

$$\int_0^\infty P(t)dt = \int_0^\infty \exp(-rt)dt = \left[-\frac{\exp(-rt)}{r} \right]_0^\infty = \frac{1}{r} \quad \text{となる。}$$

流出先を考えると流出率は $r = b_{12} + b_{32}$ となるので

$$\bar{T} = \frac{1}{b_{12} + b_{32}} = \frac{u}{b_{12}u + b_{32}u} \quad \text{を得る。}$$