

# Numerická lineární algebra

- mnoho úloh ve fyzice (zvláště pokud je systém popsán parciálními diferenciálními rovnicemi) vede nakonec k numerickému řešení jedné ze tří základních úloh lineární algebry

1) řešení soustavy lineárních rovnic  $Ax=b$

2) problém hledání vlastních čísel a vektorů

$$Ax = \lambda x, \text{ nebo hledáme rozklad } A = V \Lambda V^{-1}$$

3) řešení převrácené soustavy  $Ax=b$  vedoucí na metodu nejménších čtverců

- při řešení této úlohy se s výhodou používají různé faktORIZACE (rozklady, dekompozice) příslušné matice A na součin 2-3 speciálních matic, pomocí kterých už pak může být určitá úloha snadno (arychle) řešitelná
- základní rozklady, kterými se budeme podrobnejší zabývat,

jsou a) LU rozklad (dekompozice) používána k řešení 1)

$$\boxed{A} = \boxed{L} \cdot \boxed{U}, \text{ kde } L \text{ je dolní trojúhelníková, } \\ A = L \cdot U \quad \text{a } U \text{ je horní trojúhelníková matice}$$

b) QR rozklad používán pro 2) a 3), ale i pro 1), jen je 2x pomalejší než LU rozklad

$$A = Q \cdot R$$

$$\boxed{A} = \boxed{Q} \cdot \boxed{R}, \text{ kde } Q \text{ je ortogonální (obecně } mxn) \text{ matice} \\ \text{a } R \text{ je horní trojúhelníková matice}$$

c) SVD - singulární rozklad matice (singular value decomposition)

$$\boxed{A} = \boxed{U} \cdot \boxed{\Sigma} \cdot \boxed{V}^T$$

kde  $\Sigma$  je diagonální matice obsahující tzv. singulární hodnoty

a  $U$  a  $V$  jsou ortogonální (unitární) matice

- lze použít téměř na cokoli, jen je mnohem pomalejší pro praktické výpočty než předchozí rozklady, ovšem nejstabilnější

- v praktických problémech rozhoduje především rychlosť (efektivita) určité metody řešení  
a dále stabilita (správnost řešení jde většinou ruku v ruce)  
a přesnost se stabilitou
- bohužel velmi často jsou stabilnější metody méně efektivní  
a je nutný určitý kompromis založený na zkušenosti z praxe
- např. pro řešení  $Ax = b$  je pořadí efektivity  

$$LU < QR < SVD$$

ale pokud jde o stabilitu, je to naopak

v praxi se ale ukazuje, že pro většinu systémů  $Ax = b$   
vzestýlých např. z diskretizace PDR je bezpečně z hlediska  
přesnosti použít LU rozklad
- přestože si ukážeme, jak některé metody fungují a jak je lze využít k řešení problémů 1), 2) a 3), tak v praxi velmi doporučuji použít některou z dostupných knihoven, případně programy jako Mathematica nebo Matlab, kde jsou všechny uvedené metody a problémy vyladěny, z hlediska efektivity a i přesnosti (viz patř odkaz na mé webové stránce)
- zvláště upozorňuji na knihovnu LAPACK a její implementaci v Intel MKL knihovně
  - optimalizace nejen z hlediska algoritmů, ale i z hlediska hardwaru (využití rychlé paréti ne procesorech)
  - též je potřeba uvažit, zda vaš konkrétní problém nevede na jeden z řady speciálních typů matic (tridiagonální, pásové, fáziké apod.)
  - pro které existují specializované metody, často růdově efektivnější než pro obecné matice
  - někdy (zvláště pro tzv. fáziké matice) se s výhodou používají iterativní metody (implementované např. v knihovnách PARDISO a JADAMILU) probíhají v lehčím semestru

## Gaussova eliminace a LU dekompozice (rozklad)

- Gauss. eliminace převádí systém  $Ax=b$ , kde  $A \in \mathbb{C}^{m \times m}$  na systém  $Ux=\bar{b}$ , kde  $U$  je horní Δ matici a  $\bar{b}$  je modifikované  $b$ , pomocí operací eliminujících průkly pod diagonálou
- postupně řádkové eliminace v jednom sloupci jsou ovšem ekvivalentní násobení matice  $A$  dolní Δ maticí:

$$A^{(1)} = L_1 A$$

neboli

$$\begin{pmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \vdots & \ddots & \ddots & \vdots \\ a_{m1} & \dots & a_{mm} \end{pmatrix} \xrightarrow{L_1} \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ 0 & \tilde{a}_{22} & \dots & \tilde{a}_{2m} \\ \vdots & \ddots & \ddots & \vdots \\ 0 & \tilde{a}_{m2} & \dots & \tilde{a}_{mm} \end{pmatrix}, \text{ kde } L_1 = \begin{pmatrix} 1 & 0 & \dots & 0 \\ -l_{21} & 1 & \dots & 0 \\ \vdots & 0 & \ddots & \vdots \\ -l_{m1} & 0 & \dots & 1 \end{pmatrix}$$

$$A = A^{(0)}$$

$$A^{(1)}$$

$$l_{j1} = a_{j1}/a_{11}, j > 1$$

a obdobně pro eliminaci  $k$ -tého sloupce použijeme

$$L_k = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & 0 & 1 & \dots & 0 \\ 0 & -l_{kk} & \dots & 0 \\ 0 & 0 & -l_{kk} & \dots & 0 \\ \vdots & & & \ddots & \\ 0 & 0 & \dots & -l_{kk} & 0 & 1 \end{pmatrix} \quad \text{kde } l_{jk} = \frac{a_{jk}}{a_{kk}} \text{ pro } j > k$$

$k$ -tý sloupec

$$\text{a } a_{jk}^{(k-1)} \text{ jsou průkly matice } A^{(k-1)} = L_{k-1} \cdots L_1 A$$

- dostáváme násobek  $L_{m-1} L_{m-2} \cdots L_1 A = U$

neboli

$$A = (L_{m-1} \cdots L_1)^{-1} U = \bar{L}_1^{-1} \cdots \bar{L}_{m-1}^{-1} U = LU$$

kde  $U$  je horní Δ matici a  $L$  je dolní Δ matici, neboť

$$\bar{L}_k^{-1} = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & 0 & 1 & \dots & 0 \\ 0 & 0 & \dots & 1 & 0 \\ 0 & 0 & \dots & 0 & 1 \end{pmatrix} \text{ a navíc } \bar{L}_1^{-1} \bar{L}_2^{-1} = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & 0 & 1 & \dots & 0 \\ 0 & 0 & \dots & 1 & 0 \\ 0 & 0 & \dots & 0 & 1 \end{pmatrix} \text{ atd.}$$

(pouze změna znamének u  $l_{jk}$ )

Pozn: 1) Lze zapsat pomocí „vnějsího součinu“  $\bar{L}_k e_k^T = \begin{pmatrix} 0 \\ \vdots \\ 0 \\ l_{k+1,k} \\ l_{m,k} \end{pmatrix} (0 \dots 0 \ 1 \ 0 \ 0)$  když prvek

$$\bar{L}_k = I - l_k e_k^T$$

a protože skalární součin  $e_k^T \bar{L}_k = 0$ ,

bude  $(I - l_k e_k^T)(I + l_k e_k^T) = I$  atd.,  $\bar{L}_k^{-1} = I + l_k e_k^T$

a dále  $\bar{L}_k^{-1} \bar{L}_{k+1}^{-1} = (I + l_k e_k^T)(I + l_{k+1} e_{k+1}^T) = I + l_k e_k^T + l_{k+1} e_{k+1}^T$  atd.

- 2) protože má  $L$  na diagonále 1, lze  $L$  a  $U$  uložit do jedinečné matici, většinou se nahrazuje přímo matici  $A$  jejím LU rozkladem
- 3) fakt je přímožné nelze použít (nestabilní), možná tzv. pivotizace

## Př. Nestabilita Gaussovy eliminace bez pivotizace

Rеше Ax = b pro  $A = \begin{pmatrix} 10^{-20} & 1 \\ 1 & 1 \end{pmatrix}$  a  $b = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$

Přímo:  $10^{-20}x_1 + x_2 = 1 \Rightarrow x_1 = \frac{1}{10^{-20}-1} = -1, x_2 = -x_1 = 1$   
 $x_1 + x_2 = 0$

LU dekompozice

$$L = \begin{pmatrix} 1 & 0 \\ 10^{-20} & 1 \end{pmatrix}, U = \begin{pmatrix} 10^{-20} & 1 \\ 0 & 1-10^{-20} \end{pmatrix} \Rightarrow L \cdot U = A = \begin{pmatrix} 10^{-20} & 1 \\ 1 & 1 \end{pmatrix}$$

Ovšem v double precision:

$$\tilde{L} = \begin{pmatrix} 1 & 0 \\ 10^{-20} & 1 \end{pmatrix}, \tilde{U} = \begin{pmatrix} 10^{-20} & 1 \\ 0 & -10^{20} \end{pmatrix} \Rightarrow \tilde{L} \tilde{U} = \begin{pmatrix} 10^{-20} & 1 \\ 1 & 0 \end{pmatrix} \neq A$$

Pro některé pravé strany (např.  $b = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ ) to stále dá správné řešení;

ale ne vždy! Pravé pro  $b = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$  dostaneš:

$$\tilde{L}^{-1} = \begin{pmatrix} 1 & 0 \\ -10^{-20} & 1 \end{pmatrix}, \tilde{U}^{-1} = \begin{pmatrix} 10^{20} & 1 \\ 0 & -10^{-20} \end{pmatrix} \Rightarrow \tilde{x} = \tilde{U}^{-1} \tilde{L}^{-1} b = \tilde{U}^{-1} \begin{pmatrix} 1 \\ -10^{20} \end{pmatrix} = \begin{pmatrix} 0 \\ 1 \end{pmatrix} \neq \begin{pmatrix} -1 \\ 1 \end{pmatrix}$$

neboť Gauss. eliminace dělá něco jiného než dosazení zn  $x_2 = -x_1$ :

$$\begin{array}{r} -10^{-20} | \quad 10^{-20}x_1 + x_2 = 1 \\ \hline x_1 + x_2 = 0 \\ \hline \end{array} \quad \begin{array}{l} \text{zadružení} \\ \downarrow \\ 10^{-20}x_1 + x_2 = 1 \\ (1-10^{-20})x_2 = -10^{-20} \Rightarrow x_2 = 1 \\ \hline \end{array} \quad \begin{array}{l} -10^{-20}x_2 = -10^{-20} \Rightarrow x_2 = 1 \\ x_1 = 0 \end{array}$$

a tedy  $10^{-20}x_1 + 1 = 1 \Rightarrow$

Ovšem pivotizaci bude:

$$\begin{array}{r} -10^{-20} | \quad x_1 + x_2 = 0 \\ \hline 10^{-20}x_1 + x_2 = 1 \\ \hline x_1 + x_2 = 0 \\ 0 + (1-10^{-20})x_2 = 1 \end{array} \quad \begin{array}{l} \text{zadružení} \\ \downarrow \\ \cancel{x_1 = 1} \end{array} \quad \begin{array}{l} x_2 = 1 \\ x_1 = -x_2 = -1 \end{array}$$

## • pivotizace - výběr největšího pruhu, který - délka

- nejen pokud se na diagonále objeví nula, ale i tehdy

když je tam velmi malé číslo relativně k ostatním,

je nutné kvůli stabilitě přehodit řádky (a případně i sloupce) a pak pokračovat v Gauss. eliminaci

- řádková pivotizace = hledáme největší  $a_{jk}^{(k-1)}$  pro  $j \geq k$   
vs.  
a přehazujeme řádky

plná pivotizace = hledáme největší  $a_{je}^{(k-1)}$  pro  $j \geq k$  a  $e \geq k$   
a přehazujeme nejen řádky, ale i sloupce

- ovšem plná pivotizace potřebuje  $\Theta(m^3)$  operací porovnání  
oproti  $\Theta(m^2)$  operací u řádkové pivotizace, proto  
se používá řádková pivotizace

Pozn: zde  $\Theta(m^3)$  je celkový počet operací u průběhu celej  
Gaussovy eliminace

## • řádková pivotizace a LU rozklad

- prohazování řádků lze provést pomocí permutačních

matic, např.  $P = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \end{pmatrix}$  přehodi 2. a 4. řádek matice  $4 \times 4$

- lze tedy psát  $L_{m-1}P_{m-1}L_{m-2}P_{m-2} \dots L_1P_1A = U$

s příslušnými permutačními maticemi  $P_k$  pro řádkovou pivotizaci v každém kroku

avšak toto lze přepsat pomocí

$$L'_k = P_{m-1} \dots P_{k+1} L_k \bar{P}'_{k+1} \dots \bar{P}'_{m-1}, \quad L'_{m-1} = L_{m-1}$$

jako 
$$\underbrace{(L'_{m-1} L'_{m-2} \dots L'_1)}_{L'} \underbrace{(P_{m-1} P_{m-2} \dots P_1)}_P A = U$$

neboli  $PA = LU$  a kromě matic  $L$  a  $U$  je nutné ještě uložit  
celkovou permutační matici  $P$  (lze jí také uvažovat)

- matice  $L'_k$  má oproti  $L_k$  pouze přešporádane pruhky dlej,  
neboť  $\bar{P}'_k = P_k$  a  $P_k$  násobíci  $A$  zprava přehazuje místo řádků  
příslušné sloupce, ovšem  $L_k$  násobíme pouze  $P_j$  pro  $j > k$ ,  
takže se přehodí sloupce jednotkové podmatice, a pak to přehození řádků  
vrati

[ Pozn: obdobně lze přepsat i úplnou pivotizaci  
 jako  $PAQ = LU$ , kde  $P$  i  $Q$  jsou permutační matice  
 avšak v praxi se nepoužívá kvůli efektivitě ]

- algoritmus LU rozkladu s řádkovou pivotizací

$$U = A, L = I, P = I \quad (\text{ inicializace})$$

$$\text{pro } k=1, m-1 \quad (\text{ eliminujeme } m-1 \text{ sloupce})$$

najdi  $i \geq k$ , pro které je lvič. maximální (pivotizace)

$$\begin{aligned} U_{k,k:m} &\leftrightarrow U_{i,k:m} \\ L_{k,1:k-1} &\leftrightarrow L_{i,1:k-1} \\ P_{k,:} &\leftrightarrow P_{i,:} \end{aligned} \quad \left. \begin{array}{l} (\text{ přehození řádků, pokud } i \neq k) \\ (\text{ odčtení druhého řádku, } \\ \text{ časově nejnadročnejší}) \end{array} \right\}$$

$$\text{pro } j=k+1, m$$

$$l_{jk} = u_{jk} / u_{kk}$$

$$u_{j,k:m} = u_{j,k:m} - l_{jk} u_{k,k:m}$$

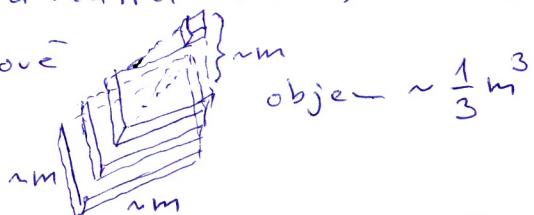
$\left. \begin{array}{l} (\text{ odečtení druhého řádku, } \\ \text{ časově nejnadročnejší}) \end{array} \right\}$

- pocet operací ( $+, -, *, /$  uvažujeme na stejné úrovni)

- když eliminujeme jeden sloupec ( $k+1$ ), tak musíme

upravit pod matici  $(m-k) \times (m-k)$  a sloupců je  $m-1$

tedy obrazové



$$\text{objem } \sim \frac{1}{3} m^3$$

orsm vždy musíme  
dělat 2 operace ( $-, *$ )  
viz post. řádek

takže celkem je potřeba  $\sim \frac{2}{3} m^3$  operací (tzv. flops = floating point operations)

- řádková pivotizace je  $\sim m^2$

$\lim_{m \rightarrow \infty} \frac{\text{počet operací}}{\frac{2}{3} m^3} = 1$

- řešení soustavy  $Ax=b$  pomocí LU rozkladu

- jakmile máme rozklad  $PA=LU$ , můžeme řešit

ekvivalentní soustavu  $PAx=Pb$  (tj. přesporádání pravou stranu)

a řešit Ly = Pb a pak Ux = y přímo, neboť jde  
o trojúhelníkové matice (tzv. zpětná substituce)

- obě rovnice mají náročnost  $\sim m^2$ ,

proto se uplatí udělat LU rozklad zvláště tehdy, pokud  
se matice A nemění, ale máme různé pravé strany

## Choleského rozklad

- jde o obdobu LU rozkladu, ale pro hermitovské, pozitivně definitní matice  $A$ , tj.  $A = A^T$  a  $x^T A x > 0$  pro lib.  $x \neq 0$   
(z pozitivní definitnosti např. plyne, že všechna vlastní čísla jsou kladná a tež diagonální průkly)
- díky hermitovosti můžeme nejen nulovat při Gaußově eliminaci první sloupec násobením dolní  $\Delta$  matice zleva, ale také první řádek násobením herm. sdružené matice zprava tj.  $A$  lze rozložit takto ( $a_{11} > 0$ )

$$A = \begin{pmatrix} a_{11} & w^T \\ w & K \end{pmatrix} = \begin{pmatrix} \alpha & 0 \\ w & 1 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & K - \frac{ww^T}{\alpha} \end{pmatrix} \begin{pmatrix} \alpha & w^T/\alpha \\ 0 & 1 \end{pmatrix} = R_1^T A_1 R_1, \text{ kde } \alpha = \sqrt{a_{11}}$$

opět pozitivně definitní, hermitovská matice

$$\left( \begin{array}{l} A_1 = (R_1^T)^{-1} A R_1^{-1} \text{ je též pozitivně definitní, herm. matice} \\ \text{a navíc platí, že lib. podmatice obsahující levý horní, nebo} \\ \text{pravý dolní roh takovéto matice je též hermit., pozit. definitní} \\ \text{— násobení } X^T A_1 X, \text{ kde } X = \begin{pmatrix} 0 \\ 1_{n \times n} \end{pmatrix}, \text{ vyberene takovou pod-matici} \end{array} \right)$$

a fakt to můžeme pokračovat dále rozklady podmatic až zůstane uprostřed jednočlánková matice, tj. máme

$$A = R_1^T R_2^T \dots R_m^T R_m \dots R_2 R_1 = R^T R, \text{ kde } r_{jj} > 0$$

a  $R$  je horní  $\Delta$  matice

- tento rozklad je jednoznačný
- díky hermitovnosti matice  $A$  stačí uložit jen  $\Delta$  až
- upravovat ji na  $R$

$$R = A$$

pro  $k=1, m$

pro  $j=k+1, m$

$$R_{j,j:m} = R_{j,j:m} - R_{k,j:m} R_{kj}^* / R_{kk}$$

$$R_{k,k:m} = R_{k,k:m} / \sqrt{R_{kk}}$$

toto se vypočítá uložit do pomocné proměnné, pak jen 2 operace, ale nyní je „objem“ pouze  $\frac{1}{6} m^3$

takže celkem  $\sim \frac{1}{3} m^3$

## • stabilita Gaussovy eliminace, a LU rozkladu

- bez pivotizace: lze ukázat, že spečene'  $\tilde{L}$  a  $\tilde{U}$

splňují'  $\tilde{L}\tilde{U} = A + \delta A$ , kde avšen  $\frac{\|\delta A\|}{\|L\|\|U\|} = O(\epsilon_M)$ ,  
pro určité'  $\delta A$

tj. není zde  $\frac{\|\delta A\|}{\|A\|}$ , ale záleží na velikosti L a U

pokud  $\|A\| \ll \|L\|$  nebo  $\|U\|$ , pak může být  $\|\delta A\|$  počerně  
velké a spečene'  $\tilde{L}\tilde{U}$  se může dost lišit od původní A

- říkáme, že LU rozklad není zpětně stabilní

a důsledkem je, že řešení  $\tilde{L}\tilde{U}x = b$  pak může být  
velmi nepřesné

- pro LU rozklad s pivotizací lze ukázat, že je zpětně stabilní,

tj.  $\tilde{L}\tilde{U} = \tilde{P}A + \delta A$ , kde  $\frac{\|\delta A\|}{\|A\|} = O(g\epsilon)$

↑  
kde už záckrouhloucím chybám nemusí jít nutně o P

- nyní již  $\|\delta A\|$  porovnáváme s  $\|A\|$ , ale objevuje se

tzv. růstový faktor  $g = \frac{\max_{i,j} |U_{ij}|}{\max_{i,j} |A_{ij}|}$   
(growth factor)

který může být ve výjimečných případech až  $2^m$

(viz ukázka v Mathematice), ale v praxi se stíráto

případem s velkou pravděpodobností nesetkáte,

v náhodně generovaných matic je spíše řádu  $\sqrt{m}$

Pozn: Algoritmus  $\tilde{f}$  je pro problém  $f=f(x)$  zpětně stabilní,

pokud pro  $\forall x$  platí  $\tilde{f}(x) = f(\tilde{x})$  pro určité'  $\tilde{x}$  splňující'  $\frac{\|\tilde{x}-x\|}{\|x\|} = O(\epsilon_M)$

neboli „zpětně stabilní“ algoritmus dá správnou odpověď na  
skoro správnou otázku.“

Navíc pro přesnost zpětně stab. alg. platí (viz např. Trefethen, Bau III: Numerical linear algebra)

$$\frac{\|\tilde{f}(x) - f(x)\|}{\|f(x)\|} = O(\alpha(x) \epsilon_M)$$

kde  $\alpha(x)$  je číslo podmíněnosti, pro matice  $\alpha(A) = \|A\| \|A^{-1}\|$

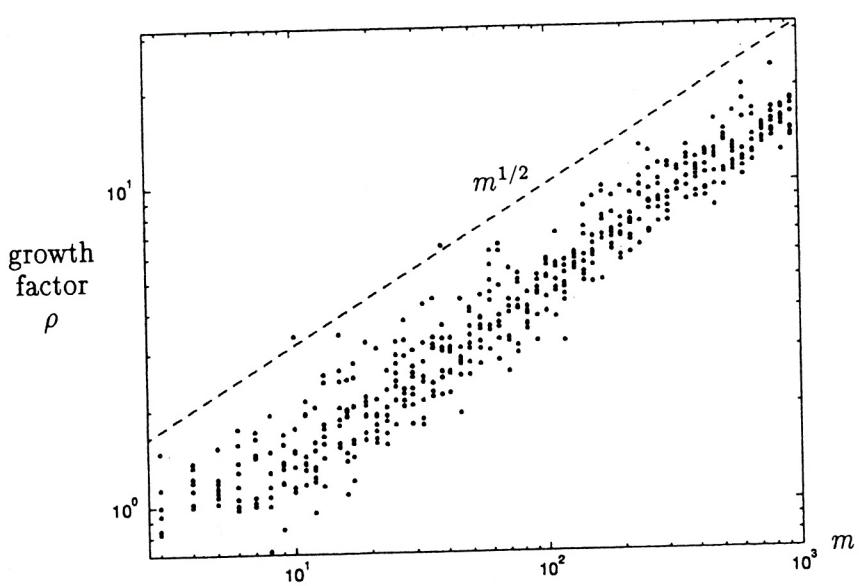


Figure 22.1. Growth factors for Gaussian elimination with partial pivoting applied to 496 random matrices (independent, normally distributed entries) of various dimensions. The typical size of  $\rho$  is of order  $m^{1/2}$ , much less than the maximal possible value  $2^{m-1}$ .

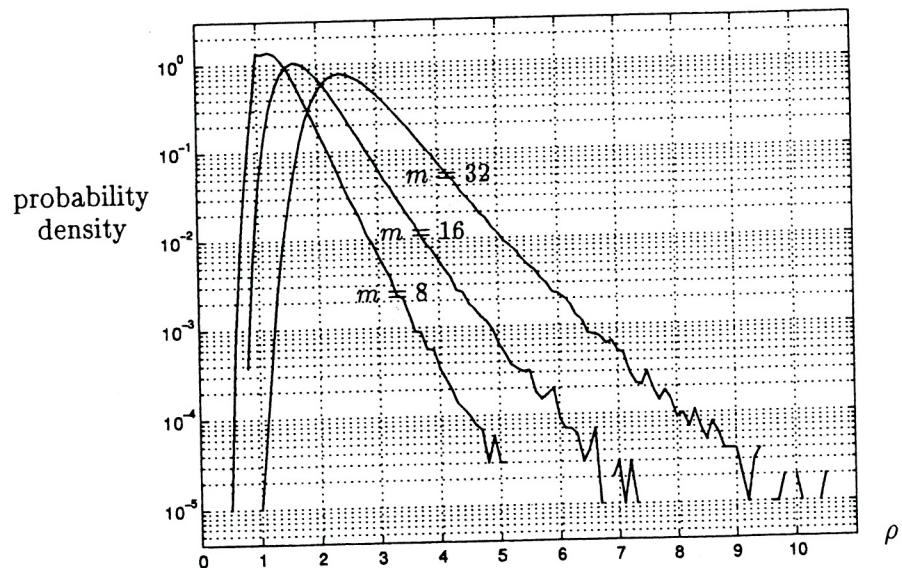


Figure 22.2. Probability density distributions for growth factors of random matrices of dimensions  $m = 8, 16, 32$ , based on sample sizes of one million for each dimension. The density appears to decrease exponentially with  $\rho$ . The chatter near the end of each curve is an artifact of the finite sample sizes.