

LINEARE ALGEBRA ROUTINEN

Julia Becker
04.04.2012
Bonn

Inhaltsverzeichnis

■ Notation

- Matrizen
- Vektoren
- Matrizen und Vektoren

■ Basis Routinen

- Skalarprodukt und Saxpy
- Matrix-Vektor Multiplikation und Gaxpy
- Matrizenmultiplikation
- Anmerkung „Level“

■ Matrixstrukturen ausnutzen

- Flops
- Bandmatrizen
- Symmetrische Matrizen
- Anmerkung zum Arbeitsspeicher

- numerische Berechnungen mit Matrizen basieren auf der Analyse der Matrizen-Multiplikation
 - es werden verschiedene Herangehensweisen und Darstellungen vorgestellt
- algebraische Operationen können durch die lineare Algebra sowie numerisch dargestellt werden
- Algorithmen werden in einer stilisierten Form von MATLAB dargestellt, sowie Begriffe der Software LAPACK benutzt
- vorgestellte Algorithmen sollten als zusammenfassende Darstellung der Idee aufgefasst werden und kritisch angewendet werden

Matrizen

■ Matrix-Notation

$$A \in \mathbb{R}^{m \times n} \Leftrightarrow A = (a_{ij}) = \begin{bmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{m1} & \cdots & a_{mn} \end{bmatrix} \quad a_{ij} \in \mathbb{R}$$

■ Matrix-Operationen

- $C = A^T \Rightarrow c_{ij} = a_{ji} \quad (\mathbb{R}^{m \times n} \rightarrow \mathbb{R}^{n \times m})$
- $C = A + B \Rightarrow c_{ij} = a_{ij} + b_{ij} \quad (\mathbb{R}^{m \times n} + \mathbb{R}^{m \times n} \rightarrow \mathbb{R}^{m \times n})$
- $C = \alpha A \Rightarrow c_{ij} = \alpha a_{ij} \quad (\mathbb{R} \times \mathbb{R}^{m \times n} \rightarrow \mathbb{R}^{m \times n})$
- $C = AB \Rightarrow c_{ij} = \sum_{k=1}^r a_{ik} b_{kj} \quad (\mathbb{R}^{m \times p} \times \mathbb{R}^{p \times n} \rightarrow \mathbb{R}^{m \times n})$

Matrizen

- Zerlegung der Matrix in Zeilen und Spalten

$$A \in \mathbb{R}^{m \times n} \Leftrightarrow A = \begin{bmatrix} r_1^T \\ \vdots \\ r_m^T \end{bmatrix}, r_k \in \mathbb{R}^n$$

$$A \in \mathbb{R}^{m \times n} \Leftrightarrow A = [c_1, \dots, c_n], c_k \in \mathbb{R}^m$$

- Doppelpunkt-Notation

- bezeichnet k-te Zeile: $A \in \mathbb{R}^{m \times n}$, $A(k, :) = [a_{k1}, \dots, a_{kn}]$

- bezeichnet k-te Spalte: $A \in \mathbb{R}^{m \times n}$, $A(:, k) = \begin{bmatrix} a_{1k} \\ \vdots \\ a_{mk} \end{bmatrix}$

Vektoren

■ Vektor-Notation

$$x \in \mathbb{R}^{n \times 1} \Leftrightarrow x = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \quad x_i \in \mathbb{R}$$
$$x \in \mathbb{R}^{1 \times n} \Leftrightarrow x = (x_1, \dots, x_n) \quad x_i \in \mathbb{R}$$

■ Vektor-Operationen

$$a \in \mathbb{R}, x \in \mathbb{R}^n, y \in \mathbb{R}^n$$

- $z = \alpha x \Rightarrow z_i = \alpha x_i$
- $z = x + y \Rightarrow z_i = x_i + y_i$
- $c = x^T y \Rightarrow c = \sum_{i=1}^n x_i y_i$

Vektoren

- Vektor-Operationen

- $z = x * y \Rightarrow z_i = x_i y_i$

- Saxpy

- $y = \alpha x + y \Rightarrow y_i = \alpha x_i + y_i$

- „scalar a x plus y“

Vektoren und Matrizen

- Gaxpy, generalized saxpy

$$A \in \mathbb{R}^{m \times n}, x \in \mathbb{R}^n, y \in \mathbb{R}^m$$

$$y = Ax + y \Rightarrow y_i = \sum_{j=1}^n a_{ij}x_j + y_i, i = 1:m$$

Skalarprodukt und Saxpy

- **Algorithmus 1.1.1.** (Skalarprodukt, $x, y \in \mathbb{R}^n$, $c = x^T y$)

- for $i = 1:n$
 $c = c + x(i)y(i)$
end

- **Algorithmus 1.1.2.** (Saxpy; $x, y \in \mathbb{R}^n$; $a \in \mathbb{R}$, $y = ax + y$)

- for $i = 1:n$
 $y(i) = ax(i) + y(i)$
end

Matrix-Vektor Multiplikation und Gaxpy

■ Algorithmus 1.1.3.

(Gaxpy: Zeilenversion, $A \in \mathbb{R}^{m \times n}$, $x \in \mathbb{R}^n$, $y \in \mathbb{R}^m$, $y = Ax + y$)

```
for i = 1:m
    for j = 1:n
        y(i) = A(i,j)x(j) + y(i)
    end
end
```

- innere Schleife stellt eine Saxpy Operation dar

Matrix-Vektor Multiplikation und Gaxpy

■ Algorithmus 1.1.4.

(Gaxpy: Spaltenversion, $A \in \mathbb{R}^{m \times n}$, $x \in \mathbb{R}^n$, $y \in \mathbb{R}^m$, $y = Ax + y$)

```
for j = 1:n
    for i = 1:m
        y(i) = A(i,j)x(j) + y(i)
    end
end
```

- innere Schleife stellt eine Saxpy Operation dar

Matrix-Vektor Multiplikation und Gaxpy

- A als eine Sammlung von Reihen, Algorithmus 1.1.3 :

- for $i = 1:m$

$$y(i) = r_i^T x + y(i)$$

- end

- A als eine Ansammlung von Spalten, Algorithmus 1.1.4. :

- for $j = 1:n$

$$y = x_j c_j + y$$

- end

- y erscheint hier als fortlaufende Vektorsumme, die immer wieder durch Saxpy Updates aktualisiert wird

Matrix-Vektor Multiplikation und Gaxpy

■ Algorithmus 1.1.3. bzw. 1.1.4. in Doppelpunkt-Notation

■ for i = 1:m

$$y(i) = A(i,:)x + y(i)$$

end

■ for j = 1:n

$$y = x(j)A(:,j) + y$$

end

- diese Darstellungsart entfernt sich weiter von der linearen Algebra und fokussiert eher numerische Themen

Matrix-Vektor Multiplikation und Gaxpy

- als weitere Anwendung der Doppelpunkt-Notation, betrachten wir nun das äußere Produkt bzw. Vektorprodukt

$$A \in \mathbb{R}^{m \times n}, x \in \mathbb{R}^{m \times 1}, y \in \mathbb{R}^{1 \times n}$$

$$A = A + xy^T$$

- xy^T ist ein spezielles Matrix-Matrix-Produkt, dessen Einträge sich wie folgt zusammensetzen:

$$a_{ij} = a_{ij} + x_i y_j \text{ mit } i = 1:m \text{ und } j = 1:n$$

Matrix-Vektor Multiplikation und Gaxpy

- daraus ergeben sich die folgenden zwei Algorithmen:

- for $i = 1:m$

$$A(i,:) = A(i,:) + x(i)y^T$$

end

- ein Vielfaches von y^T wird zu jeder Zeile von A addiert

- for $j = 1:n$

$$A(:,j) = A(:,j) + y(i)x$$

end

- ein Vielfaches von y^T wird zu jeder Spalte von A addiert

Matrizenmultiplikation

- nach dem Vorangegangenen gibt es nun 3 verschiedene Herangehensweisen an die Matrizenmultiplikation

- jeder Eintrag als **Skalarprodukt** interpretiert

- $$\begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix} \begin{bmatrix} 5 & 6 \\ 7 & 8 \end{bmatrix} = \begin{bmatrix} 1 * 5 + 2 * 7 & 1 * 6 + 2 * 8 \\ 3 * 5 + 4 * 7 & 3 * 6 + 4 * 8 \end{bmatrix}$$

- **Linearkombinationen der Spalten: Saxpy**

- $$\begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix} \begin{bmatrix} 5 & 6 \\ 7 & 8 \end{bmatrix} = \left[5 \begin{bmatrix} 1 \\ 3 \end{bmatrix} + 7 \begin{bmatrix} 2 \\ 4 \end{bmatrix}, 6 \begin{bmatrix} 1 \\ 3 \end{bmatrix} + 8 \begin{bmatrix} 2 \\ 4 \end{bmatrix} \right]$$

- **Summe von Vektorprodukten**

- $$\begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix} \begin{bmatrix} 5 & 6 \\ 7 & 8 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix} \begin{bmatrix} 5 & 6 \end{bmatrix} + \begin{bmatrix} 2 \\ 4 \end{bmatrix} \begin{bmatrix} 7 & 8 \end{bmatrix}$$

- numerisch gesehen gibt es einige Unterschiede zwischen den Verfahren z.B. bezüglich des Zugriffs auf Daten bzw. des Speicherplatzbedarfs

Matrizenmultiplikation

- Matrizenmultiplikation: $A \in \mathbb{R}^{m \times p}$, $B \in \mathbb{R}^{p \times n}$, $C \in \mathbb{R}^{m \times n}$ $C = AB + C$
- gewöhnlich Interpretation als Array von Skalarprodukten, wobei Einträge nacheinander von rechts nach links, von oben nach unten berechnet werden
- dafür wird klassisch ein triple loop benötigt, diese können auf $3!=6$ Varianten angeordnet werden

Loop Order	Inner Loop	Middle Loop	Inner Loop Data Access
ijk	Skalarprodukt	Vektor x Matrix	A Zeile, B Spalte
jik	Skalarprodukt	Matrix x Vektor	A Zeile, B Spalte
ikj	Saxpy	Gaxpy Zeile	B Zeile, C Zeile
jki	Saxpy	Gaxpy Spalte	A Spalte, C Spalte
kij	Saxpy	Vektorprodukt Zeile	B Zeile, C Zeile
kji	Saxpy	Vektorprodukt Spalte	A Spalte, C Spalte

Matrizenmultiplikation

■ Algorithmus 1.1.5.

(Matrixmultiplikation: ijk-Variante)

```
for i = 1:m
    for j = 1:n
        for k = 1:p
            C(i,j) = A(i,k)B(k,j) + C(i,j)
        end
    end
end
end
```

- innere Schleife: Skalarprodukt
- mittlere Schleife: Matrix x Vektor
- Datenzugriff: A als Zeile, B als Spalte

Matrizenmultiplikation

■ Algorithmus 1.1.5.

(Matrixmultiplikation: jki-Variante)

```
for j = 1:n
    for k = 1:p
        for i = 1:m
            C(i,j) = A(i,k)B(k,j) + C(i,j)
        end
    end
end
end
```

- innere Schleife: Saxpy
- mittlere Schleife: Gaxpy Spalte
- Datenzugriff: A als Spalte, C als Spalte

Matrizenmultiplikation

- jede Variante benötigt den gleichen Aufwand an Gleitkommaarithmetik, greift jedoch auf die Daten von A, B und C unterschiedlich zu

Loop Order	Inner Loop	Middle Loop	Inner Loop Data Access
ijk	Skalarprodukt	Vektor x Matrix	A Zeile, B Spalte
jik	Skalarprodukt	Matrix x Vektor	A Zeile, B Spalte
ikj	Saxpy	Gaxpy Zeile	B Zeile, C Zeile
jki	Saxpy	Gaxpy Spalte	A Spalte, C Spalte
kij	Saxpy	Vektorprodukt Zeile	B Zeile, C Zeile
kji	Saxpy	Vektorprodukt Spalte	A Spalte, C Spalte

Matrizenmultiplikation

- Skalarproduktversion, verschiedene Interpretationen

- **Algorithmus 1.1.6**

- for i = 1:m
 - for j = 1:n
 - $C(i,j) = A(i,:)B(:,j) + C(i,j)$
 - end
- end

- for i = 1:m
 - for j = 1:n
 - $C_{ij} = a_i^T b_j + c_j$
 - end
- end

Matrizenmultiplikation

■ Algorithmus 1.1.6

- for $i = 1:m$

$$c_i^T = a_i^T B + c_i^T$$

- end

- for $i = 1:m$

$$C(i,:) = A(i,:)B + C(i,:)$$

- end

Matrizenmultiplikation

- Saxpy Darstellung, A und C sind in Spalten aufgeteilt

- $C = AB + C \Rightarrow c_j = \sum_{k=1}^p b_{kj} a_k + c_j, j = 1:n$

- dies kann mit einer Abfolge von Saxpy Updates zusammengefasst werden

- **Algorithmus 1.1.7**

- for j = 1:n

- for k = 1:p

- $C(:,j) = A(:,k)B(k,j) + C(:,j)$

- end

- end

- for j = 1:n

- $C(:,j) = AB(:,j) + C(:,j)$

- end

Matrizenmultiplikation

■ Vektorprodukt Darstellung

- A wird als Ansammlung von Spalten und B als Sammlung von Zeilen betrachtet
- interpretiert man AB als Summe von p äußeren Produkten ergibt sich:

■ **Algorithmus 1.1.8.**

- for k = 1:p
 $C = A(:,k)B(k,:) + C$
end

Matrizenmultiplikation

■ Komplexe Matrizen

- Vektor/Matrix Addition und Multiplikation sind im Komplexen identisch zum Realen
- transponieren wird zu konjugiert transponieren
 - $C = A^H \implies c_{ij} = \bar{a}_{ji}, C \in \mathbb{C}^{m \times n}$
- Skalarprodukt
 - $s = x^H y = \sum_{i=1}^n \bar{x}_i y_i$
- $A = B + iC \in \mathbb{C}^{m \times n}$, dann bezeichnet $\text{Re}(A)=B$ den Realteil von A, sowie $\text{Im}(A)=C$ den Imaginärteil von A

Matrizenmultiplikation

■ „Level“

■ Level-1 Operation:

- Komplexität linear, d.h. arithmetischer Aufwand, sowie Datenmenge linear
- Beispiele: Skalarprodukt, Saxpy $\rightarrow je \mathcal{O}(n)$

■ Level-2 Operation:

- Komplexität quadratisch, Arbeitsaufwand sowie Datenmenge quadratisch
- Beispiele: äußeres Produkt, Gaxpy $\rightarrow je \mathcal{O}(mn)$

Matrizenmultiplikation

- „Level“

- Level-3 Operation:

- Speicherplatz für die Daten ist quadratisch, Arbeitsaufwand jedoch kubisch
 - Beispiel: Matrixupdate ($C=AB+C$) \rightarrow für $n \times n$ Matrizen:
 $\mathcal{O}(n^2)$ Matrixeinträge, $\mathcal{O}(n^3)$ arithmetische Operationen

Matrixstrukturen ausnutzen

- Effizienz bzw. Leistungsfähigkeit eines Algorithmus hängt von vielen Dingen ab
 - die zwei wichtigsten Punkte sind jedoch:
 - Menge an arithmetischen Operationen
 - Speicherplatzbedarf
- als Beispiele zur Effizienzsteigerung dieser zwei Argumente werden Bandmatrizen sowie symmetrische Matrizen betrachtet

Flops

- floating point operations per second
 - Anzahl der Gleitkommaoperationen, die von Rechnersystemen oder Prozessoren pro Sekunde ausgeführt werden können
 - dienen hier als Maß für die Effizienz eines Algorithmus
- aber: Flops sind nur eine kurze Bilanz, die nur einen Aspekt der Effizienz aufgreifen

Flops

- Anzahl der Flops berechnet man durch Aufsummieren der arithmetischen Operationen zusammen mit dem meist verschachtelten Befehl im Algorithmus
 - Beispiel: Matrixmultiplikation
 - Befehl: $C(i,j) = A(i,k)B(k,j) + C(i,j)$
 - beinhaltet 2 Flops, die mnp mal ausgeführt werden → normale Matrixmultiplikation benötigt $2mnp$ Flops

Bandmatrizen

- gehören zu den dünnbesetzten Matrizen: neben Hauptdiagonale nur bestimmte Anzahl an Nebendiagonalen ungleich Null
 - $A \in \mathbb{R}^{m \times n}$, dann bezeichnet man mit der Bandbreite folgendes:
 - p ist untere Bandbreite, wenn $a_{ij} = 0$ für $i > j + p$
 - q ist obere Bandbreite, wenn $a_{ij} = 0$ für $j > i + q$
- Bandstrukturen von häufig auftretenden $m \times n$ Matrizen

Matrixart	Untere Bandb.	Obere Bandb.
Diagonalm.	0	0
obere Dreiecksm.	0	n-1
obere Bidiagonalm.	0	1
untere Hessenbergm.	m-1	1

Bandmatrizen

- x-0 Notation: $A = \begin{bmatrix} x & x & 0 \\ 0 & x & x \\ 0 & 0 & x \end{bmatrix}, x \in \mathbb{R}, A \in \mathbb{R}^{3 \times 3}$

- Diagonalmatrizen multiplizieren

- $D \in \mathbb{R}^{m \times n}$, dann $D = \text{diag}(d_1, \dots, d_q)$, $q = \min(m, n) \Leftrightarrow d_i = d_{ii}$
- $D \in \mathbb{R}^{m \times n}$ diagonal, $A \in \mathbb{R}^{m \times n}$, dann ist DA ein row scaling von A und AD ein column scaling von A

Bandmatrizen

■ Dreiecksmatrizen multiplizieren

- **Beispiel:** A, B Dreiecksmatrizen $\in \mathbb{R}^{3 \times 3}$, dann ist $C = AB$

- $$C = \begin{bmatrix} a_{11}b_{11} & a_{11}b_{11} + a_{12}b_{22} & a_{11}b_{13} + a_{12}b_{23} + a_{13}b_{33} \\ 0 & a_{22}b_{22} & a_{22}b_{23} + a_{23}b_{33} \\ 0 & 0 & a_{33}b_{33} \end{bmatrix}$$

- es ist $a_{ik}b_{kj} = 0$, wenn $k < i$ oder $j < k$, damit erhalten wir:

$$c_{ij} = \sum_{k=i}^j a_{ik}b_{kj}$$

Bandmatrizen

■ Algorithmus 1.2.1.

(Dreiecksmatrixmultiplikation, $A, B \in \mathbb{R}^{n \times n}$, $C = AB$)

■ $C=0$

for $i=1:n$

for $j=i:n$

for $k=i:j$

$$C(i,j) = A(i,k)B(k,j) + C(i,j)$$

end

end

end

- dieser Algorithmus benötigt nur $1/6$ des Arbeitsaufwandes einer normalen Matrizenmultiplikation

Bandmatrizen

- erweitert man die Doppelpunktnotation, lässt sich der Algorithmus weiter verkürzen

- $A \in \mathbb{R}^{m \times n}$, $p, q, r \in \mathbb{Z}$ mit $1 \leq p \leq q \leq n$ und $1 \leq r \leq m$

- $A(r, p: q) = [a_{rp} \quad \dots \quad a_{rq}] \in \mathbb{R}^{1 \times (q - p + 1)}$

- $A \in \mathbb{R}^{m \times n}$, $p, q, c \in \mathbb{Z}$ mit $1 \leq p \leq q \leq m$ und $1 \leq c \leq n$

- $A(p: q, c) = \begin{bmatrix} a_{pc} \\ \vdots \\ a_{qc} \end{bmatrix} \in \mathbb{R}^{(q - p + 1)}$

Bandmatrizen

■ Algorithmus 1.2.1. (verkürzt)

■ $C(1:n, 1:n) = 0$

for $i = 1:n$

for $j = 1:n$

$$C(i,j) = A(i,i:j)B(i:j,j) + C(i,j)$$

end

end

Bandmatrizen

■ Bandspeicherung

- $A \in \mathbb{R}^{n \times n}$ mit unterer Bandbreite p und oberer Bandbreite q , mit $p, q \ll n$
- solche Matrizen können in einem $(p + q + 1) \times n$ -Array gespeichert werden
 - $a_{ij} = A.band(i - j + q + 1, j)$
- Beispiel:

$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & 0 & 0 & 0 \\ a_{21} & a_{22} & a_{23} & a_{24} & 0 & 0 \\ 0 & a_{32} & a_{33} & a_{34} & a_{35} & 0 \\ 0 & 0 & a_{43} & a_{44} & a_{45} & a_{46} \\ 0 & 0 & 0 & a_{54} & a_{55} & a_{56} \\ 0 & 0 & 0 & 0 & a_{65} & a_{66} \end{bmatrix} \quad A = \begin{bmatrix} 0 & 0 & a_{13} & a_{24} & a_{35} & a_{46} \\ 0 & a_{12} & a_{23} & a_{34} & a_{45} & a_{56} \\ a_{11} & a_{22} & a_{33} & a_{44} & a_{55} & a_{66} \\ a_{21} & a_{32} & a_{43} & a_{54} & a_{65} & 0 \end{bmatrix}$$

Bandmatrizen

■ Algorithmus 1.2.2.

(Band Gaxpy, $A \in \mathbb{R}^{n \times n}$ mit unterer Bandbreite p und oberer Bandbreite q , gespeichert als $A.\text{band}$, $x, y \in \mathbb{R}^n$, $y = Ax + y$)

■ for $j = 1:n$

$$y_{\text{top}} = \max(1, j-q)$$

$$y_{\text{bot}} = \min(n, j+p)$$

$$a_{\text{top}} = \max(1, q+2-j)$$

$$a_{\text{bot}} = a_{\text{top}} + y_{\text{bot}} - y_{\text{top}}$$

$$y(y_{\text{top}}:y_{\text{bot}}) = x(j)A.\text{band}(a_{\text{top}}:a_{\text{bot}}, j) + y(y_{\text{top}}:y_{\text{bot}})$$

end

■ benötigt $2n(p+q+1)$ Flops

Symmetrische Matrizen

- eine Matrix ist symmetrisch, falls $A^T = A, A \in \mathbb{R}^{n \times n}$
 - Speicherbedarf kann halbiert werden, indem nur das untere Dreieck gespeichert wird
 - $a_{ij} = A.\text{vec} \left((j-1)n - \frac{j(j-1)}{2} + i \right) \quad (i \geq j)$
 - Beispiel: $A = \begin{bmatrix} 1 & 2 & 3 \\ 2 & 4 & 5 \\ 3 & 5 & 6 \end{bmatrix} \rightarrow A.\text{vec} = [1 \ 2 \ 3 \ 4 \ 5 \ 6]$

Symmetrische Matrizen

■ Algorithmus 1.2.3.

(Symmetric Storage Gaxpy, $A \in \mathbb{R}^{n \times n}$ symmetrisch und als $A.vec$ gespeichert, $x, y \in \mathbb{R}^n$, $y = Ax + y$)

```
■ for j = 1:n
    for i = 1:j-1
        y(i) = A.vec((i-1)n-i(i-1)/2+j)x(j) + y(i)
    end
    for i = j:n
        y(i) = A.vec((j-1)n-j(j-1)/2+i)x(j) + y(i)
    end
end
```

■ benötigt $2n^2$ Flops

Symmetrische Matrizen

- symmetrische Matrizen können auch diagonal gespeichert werden

- $i \geq j, a_{i+k, i} = A.\text{diag}\left(i + nk - \frac{k(k-1)}{2}\right), (k \geq 0)$

- $A \in \mathbb{R}^{m \times n}, D(A, k) \in \mathbb{R}^{m \times n}$, bezeichnet die k -te Diagonale von A :

- $[D(A, k)]_{ij} = \begin{cases} a_{ij} & j = i + k, 1 \leq i \leq m, 1 \leq j \leq n \\ 0 & \text{sonst} \end{cases}$

- Beispiel:

- $A = \begin{bmatrix} 1 & 2 & 3 \\ 2 & 4 & 5 \\ 3 & 5 & 6 \end{bmatrix}, A.\text{diag} = [1 \ 4 \ 6 \ 2 \ 5 \ 3]$

Symmetrische Matrizen

$$A = \begin{bmatrix} 1 & 2 & 3 \\ 2 & 4 & 5 \\ 3 & 5 & 6 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 3 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 0 & 2 & 0 \\ 0 & 0 & 5 \\ 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 6 \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 2 & 0 & 0 \\ 0 & 5 & 0 \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 3 \end{bmatrix}$$

- beim A.diag Schema werden die Diagonalen aufeinanderfolgend gespeichert
- daraus ergibt sich für das Gaxpy $y = Ax + y$
 - $y = D(A, 0)x + \sum_{k=1}^{n-1} (D(A, k) + D(A, k)^T)x + y$

Symmetrische Matrizen

■ Algorithmus 1.2.4.

(Store-By-Diagonal Gaxpy, $A \in \mathbb{R}^{n \times n}$, *symmetrisch, als A.diag gespeichert*, $x, y \in \mathbb{R}^n$, $y = Ax + y$)

```
■ for i = 1:n
    y(i) = A.diag(i)x(i) + y(i)
end
for k = 1:n-1
    t = nk-k(k-1)/2
    {y = D(A,k)x + y}
    for i = 1:n-k
        y(i) = A.diag(i+t)x(i+k) + y(i)
    end
    {y = D(A,k)Tx + y}
    for i = 1:n-k
        y(i+k) = A.diag(i+t)x(i) + y(i+k)
    end
end
end
```

Anmerkung zum Arbeitsspeicher

- andere Möglichkeit den Arbeitsspeicheraufwand bei numerischen Berechnungen von Matrizen zu verringern ist, die zu überschreibenden Input-Daten zu kontrollieren
 - betrachten Matrixmultiplikation $C = AB$ unter Bedingung, dass Eingabematrix B mit Ausgabematrix C überschrieben werden soll
 - **Algorithmus 1.1.7.** kann jedoch nicht folgendermaßen modifiziert werden:
 - for $j = 1:n$
 - for $k = 1:n$
 - $B(:,j) = B(:,j) + A(:,k)B(k,j)$
 - end
 - end

Symmetrische Matrizen

- jedoch reicht ein linearer Arbeitsspeicher, der die j-te Spalte des Produktes sichert, solange sie mit $B(:,j)$ überschrieben werden kann:

```
■ for j = 1:n
    w(1:n) = 0
    for k = 1:n
        w(:) = w(:) + A(:,k)B(k,j)
    end
    B(:,j) = w(:)
end
```

**Vielen Dank für
Eure
Aufmerksamkeit!**