

It can be easily shown that the trace of  $A$  is also equal to the sum of the eigenvalues of  $A$  counted with their multiplicities as roots of the characteristic polynomial.

**Proposition 1.3.** *If  $\lambda$  is an eigenvalue of  $A$ , then  $\bar{\lambda}$  is an eigenvalue of  $A^H$ . An eigenvector  $v$  of  $A^H$  associated with the eigenvalue  $\bar{\lambda}$  is called a left eigenvector of  $A$ .*

When a distinction is necessary, an eigenvector of  $A$  is often called a right eigenvector. Therefore, the eigenvalue  $\lambda$  as well as the right and left eigenvectors  $u$  and  $v$  satisfy the relations

$$Au = \lambda u, \quad v^H A = \lambda v^H$$

or, equivalently,

$$u^H A^H = \bar{\lambda} u^H, \quad A^H v = \bar{\lambda} v.$$

### 1.3 Types of Matrices

The choice of a method for solving linear systems will often depend on the structure of the matrix  $A$ . One of the most important properties of matrices is symmetry, because of its impact on the eigenstructure of  $A$ . A number of other classes of matrices also have particular eigenstructures. The most important ones are listed below:

- *Symmetric matrices:*  $A^T = A$ .
- *Hermitian matrices:*  $A^H = A$ .
- *Skew-symmetric matrices:*  $A^T = -A$ .
- *Skew-Hermitian matrices:*  $A^H = -A$ .
- *Normal matrices:*  $A^H A = A A^H$ .
- *Nonnegative matrices:*  $a_{ij} \geq 0$ ,  $i, j = 1, \dots, n$  (similar definition for nonpositive, positive, and negative matrices).
- *Unitary matrices:*  $Q^H Q = I$ .

It is worth noting that a unitary matrix  $Q$  is a matrix whose inverse is its transpose conjugate  $Q^H$ , since

$$Q^H Q = I \rightarrow Q^{-1} = Q^H. \quad (1.1)$$

A matrix  $Q$  such that  $Q^H Q$  is diagonal is often called orthogonal.

Some matrices have particular structures that are often convenient for computational purposes. The following list, though incomplete, gives an idea of these special matrices, which play an important role in numerical analysis and scientific computing applications.

- *Diagonal matrices:*  $a_{ij} = 0$  for  $j \neq i$ . Notation:

$$A = \text{diag}(a_{11}, a_{22}, \dots, a_{nn}).$$

- *Upper triangular matrices:*  $a_{ij} = 0$  for  $i > j$ .

- *Lower triangular matrices:*  $a_{ij} = 0$  for  $i < j$ .

- *Upper bidiagonal matrices*:  $a_{ij} = 0$  for  $j \neq i$  or  $j \neq i + 1$ .
- *Lower bidiagonal matrices*:  $a_{ij} = 0$  for  $j \neq i$  or  $j \neq i - 1$ .
- *Tridiagonal matrices*:  $a_{ij} = 0$  for any pair  $i, j$  such that  $|j - i| > 1$ . Notation:  

$$A = \text{tridiag}(a_{i,i-1}, a_{ii}, a_{i,i+1}).$$
- *Banded matrices*:  $a_{ij} \neq 0$  only if  $i - m_l \leq j \leq i + m_u$ , where  $m_l$  and  $m_u$  are two nonnegative integers. The number  $m_l + m_u + 1$  is called the bandwidth of  $A$ .
- *Upper Hessenberg matrices*:  $a_{ij} = 0$  for any pair  $i, j$  such that  $i > j + 1$ . Lower Hessenberg matrices can be defined similarly.
- *Outer product matrices*:  $A = uv^H$ , where both  $u$  and  $v$  are vectors.
- *Permutation matrices*: the columns of  $A$  are a permutation of the columns of the identity matrix.
- *Block diagonal matrices*: generalizes the diagonal matrix by replacing each diagonal entry with a matrix. Notation:

$$A = \text{diag}(A_{11}, A_{22}, \dots, A_{nn}).$$

- *Block tridiagonal matrices*: generalizes the tridiagonal matrix by replacing each nonzero entry with a square matrix. Notation:

$$A = \text{tridiag}(A_{i,i-1}, A_{ii}, A_{i,i+1}).$$

The above properties emphasize structure, i.e., the positions of the nonzero elements with respect to the zeros. Also, they assume that there are many zero elements or that the matrix is of low rank. This is in contrast with the classifications listed earlier, such as symmetry and normality.

## 1.4 Vector Inner Products and Norms

An inner product on a (complex) vector space  $X$  is any mapping  $s$  from  $X \times X$  into  $\mathbb{C}$ ,

$$x \in X, y \in X \rightarrow s(x, y) \in \mathbb{C},$$

that satisfies the following conditions:

1.  $s(x, y)$  is linear with respect to  $x$ ; i.e.,

$$s(\lambda_1 x_1 + \lambda_2 x_2, y) = \lambda_1 s(x_1, y) + \lambda_2 s(x_2, y) \quad \forall x_1, x_2 \in X, \forall \lambda_1, \lambda_2 \in \mathbb{C}.$$

2.  $s(x, y)$  is Hermitian; i.e.,

$$s(y, x) = \overline{s(x, y)} \quad \forall x, y \in X.$$

3.  $s(x, y)$  is positive definite; i.e.,

$$s(x, x) > 0 \quad \forall x \neq 0.$$

Note that (2) implies that  $s(x, x)$  is real and, therefore, (3) adds the constraint that  $s(x, x)$  must also be positive for any nonzero  $x$ . For any  $x$  and  $y$ ,

$$s(x, 0) = s(x, 0 \cdot y) = 0 \cdot s(x, y) = 0.$$

Similarly,  $s(0, y) = 0$  for any  $y$ . Hence,  $s(0, y) = s(x, 0) = 0$  for any  $x$  and  $y$ . In particular condition (3) can be rewritten as

$$s(x, x) \geq 0 \quad \text{and} \quad s(x, x) = 0 \quad \text{iff} \quad x = 0,$$

as can be readily shown. A useful relation satisfied by any inner product is the so-called Cauchy-Schwarz inequality

$$|s(x, y)|^2 \leq s(x, x) s(y, y). \quad (1.2)$$

The proof of this inequality begins by expanding  $s(x - \lambda y, x - \lambda y)$  using the properties of  $s$ :

$$s(x - \lambda y, x - \lambda y) = s(x, x) - \bar{\lambda} s(x, y) - \lambda s(y, x) + |\lambda|^2 s(y, y).$$

If  $y = 0$  then the inequality is trivially satisfied. Assume that  $y \neq 0$  and take  $\lambda = s(x, y) / s(y, y)$ . Then, from the above equality,  $s(x - \lambda y, x - \lambda y) \geq 0$  shows that

$$\begin{aligned} 0 \leq s(x - \lambda y, x - \lambda y) &= s(x, x) - 2 \frac{|s(x, y)|^2}{s(y, y)} + \frac{|s(x, y)|^2}{s(y, y)} \\ &= s(x, x) - \frac{|s(x, y)|^2}{s(y, y)}, \end{aligned}$$

which yields the result (1.2).

In the particular case of the vector space  $X = \mathbb{C}^n$ , a canonical inner product is the Euclidean inner product. The Euclidean inner product of two vectors  $x = (x_i)_{i=1, \dots, n}$  and  $y = (y_i)_{i=1, \dots, n}$  of  $\mathbb{C}^n$  is defined by

$$(x, y) = \sum_{i=1}^n x_i \bar{y}_i. \quad (1.3)$$

which is often rewritten in matrix notation as

$$(x, y) = y^H x. \quad (1.4)$$

It is easy to verify that this mapping does indeed satisfy the three conditions required for inner products listed above. A fundamental property of the Euclidean inner product in matrix computations is the simple relation

$$(Ax, y) = (x, A^H y) \quad \forall x, y \in \mathbb{C}^n. \quad (1.5)$$

The proof of this is straightforward. The adjoint of  $A$  with respect to an arbitrary inner product is a matrix  $B$  such that  $(Ax, y) = (x, By)$  for all pairs of vectors  $x$  and  $y$ . A matrix is self-adjoint, or Hermitian, with respect to this inner product if it is equal to its adjoint. The following proposition is a consequence of equality (1.5).

## المحاضرة الثانية:

### "نقطة المصفوفة الرابعة"

1.3 أذلي المصفوفات:

إن اختيار الطريقة لحل أنظمة خطية غالباً يعتمد على بنية المصفوفة  $A$ .  
واحدة من أهم مفاهيم المصفوفات هي الخاصية التناظرية وذلك بسبب  
تأثيرها على البنية الذاتية للمصفوفة  $A$ .

العدد من مصنفات المصفوفات هناك أيضاً فهناك بنية ذاتية خاصة أهمها  
في القائمة التالية في الإيجاز:

• مصفوفة تناظرية  $A^T = A$

• مصفوفة هرمسية  $A^H = A$

• مصفوفة تناظرية متخالفة  $A^T = -A$

• مصفوفة هرمسية متخالفة  $A^H = -A$

• مصفوفة نقية  $A^H A = A A^H$

• المصفوفات المربعة  $n \times n$  حيث  $n > 0$  تعرف بشكل مشابه المصفوفات المربعة  
موجبة والموجبة والسالبة)

• المصفوفات الواحدة  $Q^H Q = I$

إلا ملاحظة هامة أن المصفوفة الواحدة  $Q$  هي مصفوفة كويرتة قطرية هو منقول  
المصفوفة المرافقة.

إن المصفوفة  $Q$  التي تحقده  $Q^H Q$  هي مصفوفة قطرية لست  $Q$  مصفوفة  
معامدة.

لعبنا المصفوفات لإنبية خاصة غالباً ما تكون ملائمة للأغراض الحاسوبية.  
القائمة التالية ولو أن غير كاملة تظهر فكرة على هذه المصفوفات والتي تكاد  
هناك في التحليل العددي والقياسات الحاسوبية العلمية.  
• المصفوفة القطرية:

$$a_{ij} = 0 \quad \text{for } i \neq j$$

ترميز

$$A = \text{diag}(a_{11}, a_{22}, \dots, a_{nn})$$

المصفوفة المثلثة العليا

$$a_{ij} = 0 \text{ for } i > j$$

المصفوفة المثلثة الدنيا

$$a_{ij} = 0 \text{ for } j > i$$

المصفوفة الخماسية

المصفوفة الثرية العليا

$$a_{ij} = 0 \text{ for } j \neq i \text{ or } j \neq i+1$$

المصفوفة الثرية الدنيا

$$a_{ij} = 0 \text{ for } j \neq i \text{ or } j \neq i-1$$

المصفوفة مثلثة 3 فقط

$$a_{ij} = 0 \text{ for any pair } i, j \text{ such that } |i-j| > 1$$

الترميز:

$$A = \text{tridiag}(a_{i,i-1}, a_{ii}, a_{i,i+1})$$

- المصفوفات المثلثة، كل عدد ليليه  $i, j$  يجب ان العلاقة السابقة يكون لها
- مصفوفة  $n \times m$  أعداد مربعة مربعة.

العدد  $m+1+m+1$  درجة المصفوفة  $A$

upper Hessenberg matrices and lower Hessenberg matrices

مصفوفات الجراد الخارجي  $A = U$  عند ما يكون  $u$  و  $u$  أسفلة

مصفوفات الانتقال: أعمدة  $A$  هي انتقال لأعمدة المصفوفة اللاحقة

المصفوفة الكتلية القطرية: رقم المصفوفة القطرية باختيار كل عنصر في القطر

مصفوفة

المصفوفة tridiagonal: هي رقم للمصفوفات tridiagonal باستبدال الأعمدة

مصفوفة مربعة

الخصائص التي في الأعلى تؤكد النتيجة

تصبح مواقع العناصر غير صفرية بالنسبة للعناصر الصفرية

أيضاً،  $m$  صفير لهن أن هناك العديد من العناصر الصفرية أو المصفوفة ذات

رتبة منخفضة

هذه المقارنة مع التطبيقات السابقة كالتأخرية والناظرية.

1.4 مصادرات الجداء الداخلي والنتيم:

الجداء الداخلي  $S$  مصادر شعاعى محدد  $X$  هو ان  $S$  تصبى  $S$  من الجداء الداخلي ليكارتى  $X \times X$  الى  $X$

$$x \in X, y \in X \longrightarrow S(x, y) \in X$$

والذى كصية الشرط التالية:

1-  $S(x, y)$  خطى بالنسبة للركبة الاولى:

$$S(\lambda_1 x_1 + \lambda_2 x_2, y) = \lambda_1 S(x_1, y) + \lambda_2 S(x_2, y) \quad \forall x_1, x_2 \in X \quad \forall \lambda_1, \lambda_2 \in K$$

2-  $S(x, y)$  هرمى للركبة الثانية تصبى:

$$S(y, x) = \overline{S(x, y)} \quad \forall x, y \in X$$

3-  $S(x, y)$  مصعب تماما: تصبى:

$$S(x, x) > 0 \quad \forall x \neq 0$$

الصفة السابقة:

د عطان الشرط الثاني يدل على ان المصعب  $S(x, x)$  هو مصعب حقيقى ولذا الشرط الثالث اذا رضين ان المصعب  $S(x, x)$  كيب ان يكون ارضيا مصعب تماما من اجل اى كمبر غير صفرى  $x$  من اجل اى  $x$  و  $y$ .

$$S(x, 0) = S(x, 0 \cdot y) = 0 \cdot S(x, y) = 0$$

$$S(0, y) = S(0 \cdot x, y) = 0 \cdot S(x, y) = 0 \quad \text{من هنا } S(x, 0) = S(0, y) = 0$$

من اجل اى  $x$  و  $y$  في الحالة (3) نكن ان ريكبة

$$S(x, x) \geq 0 \quad \text{and} \quad S(x, x) = 0 \quad \text{iff} \quad x = 0$$

كما انه من الواضح بسهولة، علاقة منية حقيقة من اجل اى  $x$  و  $y$  داخلى ترى صفة كوجبة شعاعية.

$$|S(x, y)|^2 \leq S(x, x) \cdot S(y, y)$$

اثبات هذه المتراجحة تبعا لتوزيع المصعب  $S(x - \lambda y, x - \lambda y)$  باستخدام خاصية التصبى  $S$ .

$$S(x - \lambda y, x - \lambda y) = S(x, x) - \bar{\lambda} S(x, y) - \lambda S(y, x) + |\lambda|^2 S(y, y)$$

اذا كان  $y = 0$  عندها المتراجحة حقيقة رصفا.

امتزجنا أنه  $\lambda = \frac{S(x, y)}{S(y, y)}$  عندنا هنا بسادة في الزميل

$$S(x - \lambda y, x - \lambda y) \geq 0$$

تنبه أن:

$$\begin{aligned} S(x - \lambda y, x - \lambda y) &= S(x, x) - \frac{2|S(x, y)|^2}{S(y, y)} + \frac{|S(y, y)|^2}{S(y, y)} \\ &= S(x, x) - \frac{|S(x, y)|^2}{S(y, y)} \end{aligned}$$

والذي يعطيه النتيجة 1.2. عند الحالة الخاصة التي تكون فيها الفضاء السامير هو  $\mathbb{R}^n$  فإننا نجد أن هذا هو الحد الأدنى أو الأعلى.

الحد الأدنى أو الأعلى الرقابي للفضاء السامير هو يعرف بالشكل

$$(1.6) \quad \lambda_1 \leq \lambda \leq \lambda_n$$

والذي غالباً ما يعاين في الحالة  $\mathbb{R}^n$  هو "مصفوفة بالشكل"

$$(1.7) \quad A = (a_{ij})$$

هذا يعني أن نقتصر على هذا الترتيب في المصفوفة وفي الشروط الثلاثة المتصلة عند الحد الأدنى أو الأعلى للمصفوفة في قائمة  $\lambda$  الذي

الخاصة الأساسية للحد الأدنى الرقابي هي المسامات المصفوفة هي العلاقة

$$(1.8) \quad (Ax, y) = (x, A^T y) \quad \forall x, y \in \mathbb{R}^n$$

إثبات هذا يتبع بشكل مباشر.

المصفوفة الأربعة المصفوفة  $A$  ومصفوفة  $A^T$  هي مصفوفة كسبية

$$(Ax, y) = (x, A^T y)$$

هذا هو الحد الأدنى أو الأعلى  $\lambda_1, \lambda_n$ .

تكون المصفوفة متماثلة لأنها مصفوفة بالمتجه لهذا الحد الأدنى أو الأعلى  $\lambda_1, \lambda_n$  متساويين. ملاحظاً أن الحد الأدنى أو الأعلى هو نتيجة المتسلسلة (1.9).

المصفوفة الكسبية المتماثلة