


د. غصون حيدر



Chapter 1

Background in Linear Algebra

بخصوص: يعني انه يتم صدور مستم آخر اورد كمنه
هكذا القدر فقط.
الخط

This chapter gives an overview of the relevant concepts in linear algebra that are useful in later chapters. It begins with a review of basic matrix theory and introduces the elementary notation used throughout the book. The convergence analysis of iterative methods requires a good level of knowledge in mathematical analysis and in linear algebra. Traditionally, many of the concepts presented specifically for these analyses have been geared toward matrices arising from the discretization of partial differential equations (PDEs) and basic relaxation-type methods. These concepts are now becoming less important because of the trend toward projection-type methods, which have more robust convergence properties and require different analysis tools. The material covered in this chapter will be helpful in establishing some theory for the algorithms and defining the notation used throughout the book.

1.1 Matrices

For the sake of generality, all vector spaces considered in this chapter are complex, unless otherwise stated. A complex $n \times m$ matrix A is an $n \times m$ array of complex numbers

$$a_{ij}, \quad i = 1, \dots, n, \quad j = 1, \dots, m.$$

The set of all $n \times m$ matrices is a complex vector space denoted by $C^{n \times m}$. The main operations with matrices are the following:

- Addition: $C = A + B$, where A , B , and C are matrices of size $n \times m$ and

$$c_{ij} = a_{ij} + b_{ij}, \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, m.$$

- Multiplication by a scalar: $C = \alpha A$, where

$$c_{ij} = \alpha a_{ij}, \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, m.$$

• Multiplication by another matrix:

$$C = AB,$$

where $A \in \mathbb{C}^{m \times n}$, $B \in \mathbb{C}^{n \times p}$, $C \in \mathbb{C}^{m \times p}$, and

$$c_{ij} = \sum_{k=1}^n a_{ik} b_{kj}.$$

Sometimes, a notation with column vectors and row vectors is used. The column vector $a_{\cdot j}$ is the vector consisting of the j th column of A :

$$a_{\cdot j} = \begin{pmatrix} a_{1j} \\ a_{2j} \\ \vdots \\ a_{mj} \end{pmatrix}.$$

Similarly, the notation $a_{i\cdot}$ will denote the i th row of the matrix A :

$$a_{i\cdot} = (a_{i1}, a_{i2}, \dots, a_{in}).$$

For example, the following could be written:

$$A = (a_{\cdot 1}, a_{\cdot 2}, \dots, a_{\cdot n})$$

or

$$A = \begin{pmatrix} a_{1\cdot} \\ a_{2\cdot} \\ \vdots \\ a_{m\cdot} \end{pmatrix}.$$

The transpose of a matrix A in $\mathbb{C}^{m \times n}$ is a matrix C in $\mathbb{C}^{n \times m}$ whose elements are defined by $c_{ij} = a_{ji}$, $i = 1, \dots, n$, $j = 1, \dots, m$. It is denoted by A^T . It is often more relevant to use the transpose conjugate matrix denoted by A^H and defined by

$$A^H = \bar{A}^T = \overline{A^T},$$

in which the bar denotes the (element-wise) complex conjugation.

Matrices are strongly related to linear mappings between vector spaces of finite dimension. This is because they represent these mappings with respect to two given bases: one for the initial vector space and the other for the image vector space, or range, of A .

1.2 Square Matrices and Eigenvalues

A matrix is square if it has the same number of columns and rows, i.e., if $m = n$. An important square matrix is the identity matrix

$$I = (I_{ij})_{i,j=1,\dots,n}$$

where I_{ij} is the Kronecker symbol. The identity matrix satisfies the equality $AI = IA = A$ for every matrix A of size n . The inverse of a matrix, when it exists, is a matrix C such that

$$CA = AC = I.$$

The inverse of A is denoted by A^{-1} .

The *determinant* of a matrix may be defined in several ways. For simplicity, the following recursive definition is used here. The determinant of a 1×1 matrix (a) is defined as the scalar a . Then the determinant of an $n \times n$ matrix is given by

$$\det(A) = \sum_{j=1}^n (-1)^{j+1} a_{1j} \det(A_{1j}),$$

where A_{1j} is an $(n-1) \times (n-1)$ matrix obtained by deleting the first row and the j th column of A . A matrix is said to be *singular* when $\det(A) = 0$ and *nonsingular* otherwise. We have the following simple properties:

- $\det(AB) = \det(A)\det(B)$.
- $\det(A^T) = \det(A)$.
- $\det(\alpha A) = \alpha^n \det(A)$.
- $\det(\bar{A}) = \overline{\det(A)}$.
- $\det(I) = 1$.

From the above definition of determinants it can be shown by induction that the function that maps a given complex value λ to the value $p_A(\lambda) = \det(A - \lambda I)$ is a polynomial of degree n ; see Exercise 8. This is known as the *characteristic polynomial* of the matrix A .

Definition 1.1. A complex scalar λ is called an *eigenvalue* of the square matrix A if a nonzero vector u of \mathbb{C}^n exists such that $Au = \lambda u$. The vector u is called an *eigenvector* of A associated with λ . The set of all the eigenvalues of A is called the *spectrum* of A and is denoted by $\sigma(A)$.

A scalar λ is an eigenvalue of A if and only if (iff hereafter) $\det(A - \lambda I) \equiv p_A(\lambda) = 0$. That is true iff λ is a root of the characteristic polynomial. In particular, there are at most n distinct eigenvalues.

It is clear that a matrix is singular iff it admits zero as an eigenvalue. A well-known result in linear algebra is stated in the following proposition.

Proposition 1.2. A matrix A is nonsingular iff it admits an inverse.

Thus, the determinant of a matrix determines whether or not the matrix admits an inverse.

The maximum modulus of the eigenvalues is called the *spectral radius* and is denoted by $\rho(A)$:

$$\rho(A) = \max_{\lambda \in \sigma(A)} |\lambda|.$$

The *trace* of a matrix is equal to the sum of all its diagonal elements:

$$\text{tr}(A) = \sum_{i=1}^n a_{ii}.$$

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 λ 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 λ 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 $i < j$.

المحاكمة الأولى
"المصنفات الأولى"

يعني هذا الفصل لوجه عام عن مفهوم ذات ملاحظة الجبر الخطي التي هي مفيدة في فصل لا قدر

إنه يبدأ بمراجعة للنظرية الأساسية للمصفوفة ولقد تم التمييز بين الأجزاء المتضمنة لذلك الكتاب

التحليل العددي للفرق التكرارية لتبسيط عملية التحليل الرياضي والجبر الخطي
تقليدياً إن العددين من المفاهيم المقدمة مثلاً عددي هذه التحليلات تتكون من أهل الارتقاء بالمصفوفات عند المعادلات المقابلة الجبرية ومسائل الشروط المحفظة الأساسية

هذه المفاهيم أصبحت الآن أقل أهمية بسبب التزوية نحو المسائل الاستنتاجية والتي تتجمع خصائصها وقابلية معالجة أكثر وتطبيقات أدوات تحليلية مختلفة إن المادة التي سننظرها في هذا الفصل ستكون ما يلي نأسس لبعض النظريات حول المفاهيم والبرهان الترميزية المستخدمة عبر الكتاب

1-1 المصفوفات
في الحالة العامة كل الفضاءات الشعاعية المعقدة في هذا الفصل هي عقدية ما لم ينص على خلاف ذلك

المصفوفة العقدية من الرتبة $n \times m$ هي M من الأعداد العقدية حيث يأخذ قيمته من 1 إلى n و 1 إلى m من الأعمدة

إن مجموع كل المصفوفات من الرتبة $n \times m$ تمثل فضاء شعاعي عقدي يشار إليه بالرمز $M^{n \times m}$

العمليات الرئيسية على المصفوفات هي كالتالي:

• الجمع: $C = A + B$ حيث A, B, C هي مصفوفات من الرتبة $n \times m$.

• الضرب: حيث $C = \alpha A$ عندما $C_{ij} = \alpha a_{ij}$ ، $i = 1, 2, \dots, n$ ، $j = 1, 2, \dots, m$.

"المصفوفة النائية"

• الهزب للمصفوفة أفردي

في بعض الأحيان يستخدم الترميز بالأسفحة العنودية والاصفية

إن السطوح العددية هو شعاع مقنن في العدد ذو الرصم n في المصفوفة A .

$$a_{*j} = \begin{pmatrix} a_{1j} \\ a_{2j} \\ \vdots \\ a_{nj} \end{pmatrix}$$

شكل مشابه الرصم a_{ix} سار إليه للدلالة على المصفوفة ذو الرصم n في المصفوفة A .

٤) سيجد المثال يتبع أن نكتب كالتالي: (مصفوفة سكرية أو عمودية)

$$A = (a_{x1}, a_{x2}, \dots, a_{xm})$$

$$A = \begin{pmatrix} a_{1x} \\ a_{2x} \\ \vdots \\ a_{nx} \end{pmatrix}$$

منقول المصفوفة A في الفضاء العقدي \mathbb{C} من الرتبة $m \times n$ هو مصفوفة C في الفضاء العقدي \mathbb{C} من الرتبة $n \times m$ والتي نأخذها تعرف بالشكل:

$$c_{ij} = a_{ji}, \quad i=1, \dots, m, \quad j=1, \dots, n$$

وترمز بالشكل A^T .

من العادة هناك صلة وثيقة أكثر في استخدام مرافقة المنقول ومنقول المرافق ويرمز بالرمز A^H ويعرف بالعلاقات:

$$A^H = A^{-T} = \overline{A^T}$$

في حين الخفا سير إلى مرافقة المصفور (المرافقة العقدي)

إن المصفوفات تتعلقه بالتبنيات الحفية بين المصفوفات الشعاعية منتبهة العدد.

ذلك لأن تمثل هذه التبنيات بالاسمقادي قائدين مطابقتين.

الأولى للمصفور الشعاعي الأول (المنظمة)

والأخرى للمستقر الشعاعي للمصفور الشعاعي أو مدى المصفوفة A .

1.2 المصفوفات المربعة والتمثيل الذاتي

تكون المصفوفة مربعة إذا كان عدد أعمدة m مساوياً لعدد صفوفها n .
للتفصيل، إذا كان $m = n$.

مصفوفة مربعة هامة هي المصفوفة المحايدة

$$I = \{ \delta_{ij} \} \quad i, j = 1, \dots, n$$

حيث δ_{ij} هو الترميز Kronecker

إن المصفوفة المحايدة تحقّق المساواة $AI = IA = A$ لكل مصفوفة A من الرتبة n

إن مقلوب المصفوفة A "إن وجد" هو مصفوفة C تحقّق

$$CA = AC = I$$

نبارك مقلوب المصفوفة A بـ A^{-1}

"الصفة الثالثة"

إن محدد المصفوفة A يمكن أن يعرف بطريقة مباشرة

للسهولة استعمل هنا التعريف العمودي

إن محدد المصفوفة ذات الرتبة $n \times n$ يعرف على أنه محدد a

إذا "محدد المصفوفة من الرتبة $n \times n$ يعطى بالشكل

$$\det(A) = \sum_{j=1}^n a_{ij} \det(A_{ij})$$

حيث المصفوفة A_{ij} هي من الرتبة $(n-1) \times (n-1)$ حصل على كل من حذف

السطر الأول والعمود j من المصفوفة A

نصّال محدد مصفوفة الأنتشار إذا كان محدد A مساوياً للصفر أي $\det(A) = 0$

ونصّال محدد غير انتشاري إذا كان غير ذلك

لدينا الحفام n البسيطة التالية

- $\det(AB) = \det(A) \cdot \det(B)$

- $\det(A^T) = \det(A)$

- $\det(\alpha A) = \alpha^n \det(A)$

- $\det(\bar{A}) = \overline{\det(A)}$

- $\det(I) = 1$

من التعريف العلوي للمحددات يمكن أن يكون من الواضح بالاستقراء البريا من أن
 التابع الذي يتركه كقيمة عقدية λ بالصفحة $PA(\lambda) = \det(AI - \lambda I)$
 هو كثير حدود من الدرجة A .

هذا تعريف بالمحددات المميزة للمصفوفة A .

تعريف 1.1: الصفحة العقدية λ تدعى صفحة ذاتية للمصفوفة المربعة A إذا وجد شعاع غير
 صفري u من الفضاء E صفحة $Au = \lambda u$

يدعى الشعاع u بالشعاع الذاتي للمصفوفة A مرتبطة بالصفحة λ .
 إن مجموعة كل القيم الذاتية للمصفوفة A يدعى بالعين المصفوفة ويشير إليها
 بالرمز $\sigma(A)$.

العدد λ صفحة ذاتية للمصفوفة A إذا وفقط إذا

$$\det(A - \lambda I) = PA(\lambda) = 0$$

هذا صحيح إذا وفقط إذا كان λ جذراً للمعادلة المميزة.

بالقدر هناك ما لا يقل عن n صفحة ذاتية مختلفة.

من الواضح أن تكون المصفوفة شاذة إذا وفقط إذا احتلت الصفحة صفحة ذاتية

نتيجة معروفة في الجبر الخطي تدعى بالادعيات التالية:

الادعيات 1.2:

تكون المصفوفة A غير شاذة إذا وفقط إذا كان لا صفوحة

وهكذا، إن محدد المصفوفة غير صفوحة إذا كان المصفوفة متكونة من صفوحة

إن الصفحة المطلقة الأضحية للقيم الذاتية صفحة صفحة الصفحة المصفوفة والرمز $\rho(A)$

بالشكل

$$\rho(A) = \max_{\lambda \in \sigma(A)} |\lambda|$$

إن أثر المصفوفة يتساوى مجموع كل عناصر قطرها الرئيسي

$$\text{tr}(A) = \sum_{i=1}^n a_{ii}$$

"الصفحة الرابعة"

إن من الواضح بسهولة أن أثر المصفوفة A تاري أيضاً مجموع قيمه الذاتية محدودة بمضاريتها كجذر للمعادلة المميزة.

الادعاء 1.3 :

إذا كانت λ قيمة ذاتية للمصفوفة A فإن مرافق λ هو قيمة ذاتية للمصفوفة الهرميتية A^H .

إن الشعاع الذاتي للمصفوفة A^H المتعلقة بالقيمة الذاتية $\bar{\lambda}$ يدعى شعاعاً ذاتياً تاري للمصفوفة A .

عندما تكون الاختلافات متناهية فإن الشعاع الذاتي للمصفوفة A يدعى شعاعاً ذاتياً حينئذٍ.

لذا، إن القيمة الذاتية λ أو أيضاً $\bar{\lambda}$ لكل من الشعاع الذاتي العيني والشعاع كصيف العلاقات التالية:

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

أو بشكل مكافئ:

$$u^H A^H = \bar{\lambda} u^H \quad \text{و} \quad A^H v = \bar{\lambda} v$$

النتيجة المعاصرة الأولى