

ировке параметров и т. д. (см. гл. 13 в [1]). При решении помещенных ниже задач предполагается использование только метода главных компонент (МГК).

Метод главных компонент. Во многих задачах обработки многомерных наблюдений и, в частности, в задачах классификации исследований интересуют в первую очередь лишь те признаки, которые обнаруживают наибольшую изменчивость (наибольший разброс) при переходе от одного объекта к другому.

С другой стороны, не обязательно для описания состояния объекта использовать какие-то из исходных, непосредственно замеренных на объекте признаков. Так, например, для определения специфики фигуры человека при покупке одежды достаточно назвать значения двух признаков (вес-рост), являющихся производными от измерений ряда параметров фигуры. При этом, конечно, теряется какая-то доля информации (портной берет до одиннадцати параметров на клиенте), как бы огрубляются различия (агрегировании) получающиеся при этом классы. Однако, как покажет исследование, к вполне удовлетворительной классификации людей с точки зрения специфики их фигуры приводит система, использующая три признака, каждый из которых является некоторой комбинацией от большого числа непосредственно замеряемых на объекте параметров.

Именно эти принципиальные установки заложены в сущность того линейного преобразования исходной системы признаков, которое приводит к главным компонентам. Формализуются же эти установки следующим образом.

Следуя общей оптимизационной постановке задачи снижения размерности (4.2) и полагая анализируемый признак X p -мерной случайной величиной с вектором средних значений $\mathbf{a} = (a^{(1)}, \dots, a^{(p)})$ и ковариационной матрицей $\Sigma = (\sigma_{ij})$ ($i, j = 1, 2, \dots, p$), вообще говоря, неизвестными, определим в качестве класса $F(X)$ допустимых преобразований исследуемых признаков $x^{(1)}, x^{(2)}, \dots, x^{(p)}$ их всевозможные *линейные ортогональные нормированные комбинации*, т. е.

$$F = \left\{ Z: z^{(j)} = \sum_{\nu=1}^p c_{j\nu} (x^{(\nu)} - a^{(\nu)}), j = 1, 2, \dots, p \right\},$$

$$\sum_{\nu=1}^p c_{j\nu}^2 = 1 \quad \text{и} \quad \sum_{\nu=1}^p c_{j\nu} c_{k\nu} = 0 \quad (4.3)$$

где $j = 1, 2, \dots, p$ и $k = 1, 2, \dots, p$, но $j \neq k$, а в качестве критерия (меры) информативности p -мерной системы показателей $Z(X) =$

$(z^{(1)}(X), z^{(2)}(X), \dots, z^{(p')}(X))$ выражение

$$I_{p'}(Z(X)) = \frac{D z^{(1)} + \dots + D z^{(p')}}{D x^{(1)} + \dots + D x^{(p)}}. \quad (4.4)$$

Тогда при любом фиксированном $p' = 1, 2, \dots, p$ вектор искомых вспомогательных переменных $\tilde{Z}(X) = (\tilde{z}^{(1)}(X), \dots, \tilde{z}^{(p')}(X))^T$ определяется как такая линейная комбинация

$$\tilde{Z} = LX \quad (4.5)$$

(где X — вектор-столбец *центрированных* исходных переменных, а

$$L = \begin{pmatrix} l_{11} & \dots & l_{1p} \\ \dots & \dots & \dots \\ l_{p'1} & \dots & l_{p'p} \end{pmatrix} —$$

матрица, строки которой удовлетворяют условию ортогональности), что

$$I_{p'}(\tilde{z}^{(1)}(X), \dots, \tilde{z}^{(p')}(X)) = \max_{Z(X) \in F} I_{p'}(Z(X)).$$

Полученные таким образом переменные $\tilde{z}^{(1)}(X), \dots, \tilde{z}^{(p)}(X)$ и называют главными компонентами вектора X . Отсюда вытекает следующее определение главных компонент.

Первой главной компонентой $\tilde{z}^{(1)}(X)$ исследуемой системы показателей $X = (x^{(1)}, \dots, x^{(p)})^T$ называется такая нормированно-центрированная линейная комбинация этих показателей, которая среди всех прочих нормированно-центрированных линейных комбинаций переменных $x^{(1)}, \dots, x^{(p)}$ обладает наибольшей дисперсией.

k -й главной компонентой $\tilde{z}^{(k)}(X)$ ($k = 2, 3, \dots, p$) исследуемой системы показателей $X = (x^{(1)}, \dots, x^{(p)})^T$ называется такая нормированно-центрированная линейная комбинация этих показателей, которая не коррелирована с $k-1$ предыдущими главными компонентами и среди всех прочих нормированно-центрированных и некоррелированных с предыдущими $k-1$ главными компонентами линейных комбинаций переменных $x^{(1)}, \dots, x^{(p)}$ обладает наибольшей дисперсией.

З а м е ч а н и е 1 (переход к центрированным переменным). Поскольку, как увидим ниже, решение задачи (а именно вид матрицы линейного преобразования L) зависит только от элементов ковариационной матрицы Σ , которые в свою очередь не изменяются при замене исходных переменных $x^{(j)}$ переменными $x^{(j)} - c^{(j)}$ ($c^{(j)}$ — произвольные постоянные

числа), то в дальнейшем *уже центрирована*, т. е. на практике этого добиваются $\bar{x}^{(j)} = \sum_{i=1}^n x_i^{(j)} / n$ (для центрированной переменной \bar{x} мы не будем).

З а м е ч а н и е 2 (о центрировании реальных статистических данных). Ответственно вектора $\hat{\sigma}_{kj}$ с дальнейших рассуждений.

З а м е ч а н и е 3. Наиболее естественными компонентами $x^{(1)}, x^{(2)}, \dots, x^{(p)}$ являются *исходную природу* и соответствующие им примеры.

ни индивидуумов (все это относится к структуре потребления).

исследование общего характера с помощью специальных методов.

да антропологические измерения (длины) и т. д. Если же измерения в различных единицах, то результаты будут существенно завышенными. Поэтому в процессе анализа переходят к вспомогательным переменным с помощью нормирования.

где $\hat{\sigma}_{jj}$ соответствует дисперсии j -й компоненты относительно ковариационной матрицы Σ временно выборочной матрицы X_i .

где $\hat{\sigma}_{jj}$ соответствует дисперсии j -й компоненты относительно ковариационной матрицы Σ временно выборочной матрицы X_i .

где $\hat{\sigma}_{jj}$ соответствует дисперсии j -й компоненты относительно ковариационной матрицы Σ временно выборочной матрицы X_i .

где $\hat{\sigma}_{jj}$ соответствует дисперсии j -й компоненты относительно ковариационной матрицы Σ временно выборочной матрицы X_i .

где $\hat{\sigma}_{jj}$ соответствует дисперсии j -й компоненты относительно ковариационной матрицы Σ временно выборочной матрицы X_i .

где $\hat{\sigma}_{jj}$ соответствует дисперсии j -й компоненты относительно ковариационной матрицы Σ временно выборочной матрицы X_i .

где $\hat{\sigma}_{jj}$ соответствует дисперсии j -й компоненты относительно ковариационной матрицы Σ временно выборочной матрицы X_i .

где $\hat{\sigma}_{jj}$ соответствует дисперсии j -й компоненты относительно ковариационной матрицы Σ временно выборочной матрицы X_i .

), то в дальнейшем будем считать, что исходная система показателей *центрирована*, т. е. что $E x^{(j)} = 0, j = 1, 2, \dots, p$. В статистической практике этого добиваются, переходя к наблюдениям $\tilde{x}_i^{(j)} = x_i^{(j)} - \bar{x}^{(j)}$, где $\bar{x}^{(j)} = \sum_{i=1}^n x_i^{(j)} / n$ (для упрощения обозначений волнистую черту над центрированной переменной и над главной компонентой в дальнейшем ставить не будем).

З а м е ч а н и е 2 (переход к выборочному варианту). Поскольку в реальных статистических задачах располагаем *лишь оценками* \hat{a} и $\hat{\Sigma}$ соответственно вектора средних a и ковариационной матрицы Σ , то во всех дальнейших рассуждениях под $\hat{a}^{(j)}$ понимается $\bar{x}^{(j)}$, а под $\hat{\sigma}_{kj}$ — выборочная ковариация $\hat{\sigma}_{kj} = \sum_{i=1}^n (x_i^{(k)} - \bar{x}^{(k)})(x_i^{(j)} - \bar{x}^{(j)}) / n$ ($j, k = 1, 2, \dots, p$).

З а м е ч а н и е 3. Использование главных компонент оказывается более естественным и плодотворным в ситуациях, в которых все компоненты $x^{(1)}, x^{(2)}, \dots, x^{(p)}$ исследуемого вектора X имеют *общую физическую природу* и соответственно *измерены в одних и тех же единицах*. К таким примерам можно отнести исследование структуры бюджета времени индивидуумов (все $x^{(j)}$ измеряются в единицах времени), исследование структуры потребления семей (все $x^{(j)}$ измеряются в денежных единицах), исследование общего развития и умственных способностей индивидуумов с помощью специальных тестов (все $x^{(j)}$ измеряются в баллах), разного рода антропологические исследования (все $x^{(j)}$ измеряются в единицах меры длины) и т. д. Если же признаки $x^{(1)}, x^{(2)}, \dots, x^{(p)}$ измеряются в различных единицах, то результаты исследования с помощью главных компонент существенно зависят от выбора масштаба и природы единиц измерения. Поэтому в подобных ситуациях исследователь предварительно переходит к вспомогательным безразмерным признакам $x^{*(j)}$, например, с помощью нормирующего преобразования

$$x_i^{*(j)} = \frac{x_i^{(j)} - \bar{x}^{(j)}}{\sqrt{\hat{\sigma}_{jj}}}, \quad (4.1')$$

$$j = 1, 2, \dots, p;$$

$$i = 1, 2, \dots, n,$$

где $\hat{\sigma}_{jj}$ соответствует ранее введенным обозначениям, а затем строит главные компоненты относительно этих вспомогательных признаков X^* и их ковариационной матрицы $\hat{\Sigma}_{X^*}$, которая, как легко видеть, является одновременно выборочной *корреляционной* матрицей \hat{R} исходных наблюдений

Вычисление главных компонент. Из определения главных компонент следует, что для вычисления первой главной компоненты необходимо решить оптимизационную задачу вида (4.2), т. е. в данном случае:

$$\begin{cases} D(l_1 X) \rightarrow \max_{l_1}; \\ l_1 l_1^T = 1, \end{cases} \quad (4.5)$$

где l_1 — первая строка матрицы L (см. (4.5)). Учитывая центрированность переменной X (т. е. $E X = 0$) и то, что $E(X X^T) = \Sigma$, имеем

$$D(l_1 X) = E(l_1 X)^2 = E(l_1 X X^T l_1^T) = l_1 \Sigma l_1^T.$$

Следовательно, задача (4.6) может быть записана

$$\begin{cases} l_1 \Sigma l_1^T \rightarrow \max_{l_1}; \\ l_1 l_1^T = 1, \end{cases} \quad (4.6)$$

Вводя функцию Лагранжа $\varphi(l_1, \lambda) = l_1 \Sigma l_1^T - \lambda(l_1 l_1^T - 1)$ и дифференцируя ее по компонентам вектор-столбца l_1^T , имеем:

$$\frac{\partial \varphi}{\partial l_1^T} = 2 \Sigma l_1^T - 2 \lambda l_1^T,$$

что дает систему уравнений для определения l_1 :

$$(\Sigma - \lambda I) l_1^T = 0 \quad (4.7)$$

(здесь $0 = (0, 0, \dots, 0)^T$ — p -мерный вектор-столбец из нулей).

Для того чтобы существовало ненулевое решение системы (4.7) (а оно должно быть ненулевым, так как $l_1 l_1^T = 1$), матрица $\Sigma - \lambda I$ должна быть вырожденной, т. е.

$$|\Sigma - \lambda I| = 0. \quad (4.8)$$

Этого добиваются подбором соответствующего значения λ . Уравнение (4.8) (относительно λ) называется *характеристическим* для матрицы Σ . Известно (см. [1], Приложение 2), что при симметричности и неотрицательной определенности матрицы Σ (каковой она и является как всякая ковариационная или корреляционная матрица) это уравнение имеет p вещественных неотрицательных корней $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$, называемых *характеристическими* (или *собственными*) значениями матрицы Σ .

Учитывая, что $D \tilde{z}^{(1)} = D(l_1 X) = l_1 \Sigma l_1^T$ и $l_1 \Sigma l_1^T = \lambda$ (последнее соотношение следует из соотношения (4.7) после его умножения слева на l_1 , с учетом $l_1 l_1^T = 1$), получаем $D \tilde{z}^{(1)}(X) = \lambda$.

Поэтому для обеспечения $\tilde{z}^{(1)}$ нужно выбрать λ_1 , т. е.

Подставляем λ_1 в систему $(\Sigma - \lambda_1 I) l_1 = 0$, определяем компонентный вектор l_1 . Таким образом, первая главная компонента $\tilde{z}^{(1)}(X) = l_1 X$ соответствует наибольшему значению λ_1 .

Далее аналогично можно определить остальные главные компоненты вектора X по убыванию значений λ_k . Таким образом, соответствующие главные компоненты $\tilde{z}^{(1)}, \dots, \tilde{z}^{(p)}$ могут быть записаны как $\tilde{z}^{(j)} = (l_{j1}, \dots, l_{jp})^T$, $X = (x_1, \dots, x_p)^T$, $j = \overline{1, p}$, являющимися соответствующими собственными значениями матрицы Σ в соответствии с условиями (4.8).

В дальнейшем в целях «упрощения» над переменными $\tilde{z}^{(j)}$ компоненты просто $Z = (z_1, \dots, z_p)^T$.

Основные числовые характеристики. Определим основные числовые характеристики (дисперсии, ковариации) главных компонент исходных данных Z :

- $E Z = E(L X) = L \cdot E X = 0$.
- ковариационная матрица $\Sigma_Z = E(Z Z^T)$.

$$\begin{aligned} \Sigma_Z &= E(Z Z^T) \\ &= L \cdot E(X X^T) L^T = L \Sigma L^T. \end{aligned}$$

Умножая слева соотношение (4.8) на l_j , получаем

(4.9)

ому для обеспечения максимальной величины дисперсии пере-
 (1) нужно выбрать из p собственных значений матрицы Σ наи-
 т. е.

$$D \tilde{z}^{(1)}(X) = \lambda_1.$$

ставляем λ_1 в систему уравнений (4.7) и, решая ее относительно
 p , определяем компоненты вектора l_1 .

им образом, первая главная компонента получается как линей-
 комбинация $\tilde{z}^{(1)}(X) = l_1 X$, где l_1 — собственный вектор матрицы
 соответствующий наибольшему собственному числу этой матрицы.

ее аналогично можно показать, что $\tilde{z}^{(k)}(X) = l_k X$, где l_k — соб-
 ственный вектор матрицы Σ , соответствующий k -му по величине соб-
 ственному значению λ_k этой матрицы.

им образом, соотношения для определения всех p главных ком-
 понент вектора X могут быть представлены в виде (4.5), где $\tilde{Z} =$
 $(\tilde{z}^{(1)}, \dots, \tilde{z}^{(p)})^T$, $X = (x^{(1)}, \dots, x^{(p)})^T$, а матрица L состоит из строк
 (l_{j1}, \dots, l_{jp}) , $j = \overline{1, p}$, являющихся собственными векторами матрицы
 соответствующими собственным числам λ_j . При этом сама матрица L
 в соответствии с условиями (4.3) является ортогональной, т. е.

$$LL^T = L^T L = I. \quad (4.9)$$

дальнейшем в целях упрощения обозначений мы будем опускать
 « X » над переменными главными компонентами, т. е. обозначать главные
 компоненты просто $Z = (z^{(1)}, z^{(2)}, \dots, z^{(p)})$.

Основные числовые характеристики главных компонент.
 елим основные числовые характеристики (средние значения, дис-
 персия, ковариации) главных компонент в терминах основных числовых
 характеристик исходных переменных и собственных значений матрицы

$$E Z = E(L X) = L \cdot E X = 0;$$

ковариационная матрица вектора главных компонент:

$$\begin{aligned} \Sigma_Z &= E(Z Z^T) = E((L X)(L X)^T) = E(L X X^T L^T) \\ &= L \cdot E(X X^T) \cdot L^T = L \cdot \Sigma \cdot L^T. \end{aligned}$$

множая слева соотношения

$$(\Sigma - \lambda_k I) l_k^T = 0, \quad k = \overline{1, p},$$

на l_j ($j = \overline{1, p}$), получаем, что

$$\mathbf{L}\Sigma\mathbf{L}^T = \Sigma_Z = \begin{pmatrix} \lambda_1 & & & 0 \\ & \lambda_2 & & \\ & & \ddots & \\ 0 & & & \lambda_p \end{pmatrix}. \quad (4.10)$$

Из (4.10), в частности, следует подтверждение взаимной некоррелированности главных компонент, а также тот факт, что $D z^{(k)} = \lambda_k$ ($k = \overline{1, p}$);
в) сумма дисперсий исходных признаков равна сумме дисперсий всех главных компонент. Действительно,

$$\begin{aligned} \sum_{k=1}^p D z^{(k)} &= \text{tr } \Sigma_Z = \text{tr } (\mathbf{L}\Sigma\mathbf{L}^T) = \text{tr } ((\mathbf{L}\Sigma)\mathbf{L}^T) \\ &= \text{tr } (\mathbf{L}^T(\mathbf{L}\Sigma)) = \text{tr } ((\mathbf{L}^T\mathbf{L})\Sigma) = \text{tr } \Sigma = \sum_{k=1}^p D x^{(k)}; \end{aligned}$$

г) обобщенная дисперсия исходных признаков X ($\det \Sigma$) равна обобщенной дисперсии главных компонент. Действительно, обобщенная дисперсия вектора Z равна

$$\begin{aligned} \det \Sigma_Z &= \det (\mathbf{L}\Sigma\mathbf{L}^T) = \det ((\mathbf{L}\Sigma)\mathbf{L}^T) = \det (\mathbf{L}^T(\mathbf{L}\Sigma)) \\ &= \det ((\mathbf{L}\mathbf{L}^T)\Sigma) = \det (\Sigma). \end{aligned} \quad (4.10')$$

Следствие 1. Из б) и в), в частности, следует, что критерий информативности метода главных компонент (4.4) может быть представлен в виде

$$I_{p'}(Z(X)) = \frac{\lambda_1 + \dots + \lambda_{p'}}{\lambda_1 + \dots + \lambda_p}, \quad (4.4')$$

где $\lambda_1, \lambda_2, \dots, \lambda_p$ — собственные числа ковариационной матрицы Σ вектора X , расположенные в порядке убывания.

Кстати, представление $I_{p'}(Z(X))$ в виде (4.4') дает исследователю некоторую основу, опорную точку зрения, при вынесении решения о том, сколько последних главных компонент можно без особого ущерба изъять из рассмотрения, сократив тем самым размерность исследуемого пространства.

Действительно, анализируя с помощью (4.4') изменение относительно доли дисперсии, вносимой первыми p' главными компонентами, в зависимости от числа этих компонент, можно разумно определить число

компонент, которое
изменении $I_{p'}$, изобра
сократить размерно
не всех остальных
характеристику рас

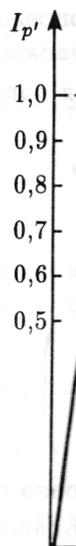


Рис. 4.1. Изменение критерия информативности $I_{p'}$ при изменении числа главных компонент p' .

Следствие 2. Если $x^{*(1)}, \dots, x^{*(p)}$ — главные компоненты, то по замечанию 3 ковариационной матрицы $\Sigma_{X^*} = \mathbf{R}$ и из

или

Тогда критерий информативности $I_{p'}$ можно представить в виде

мент, которое целесообразно оставить в рассмотрении. Так, при изменении $I_{p'}$, изображенном на рис. 4.1, очевидно, целесообразно было бы уменьшить размерность пространства с $p = 10$ до $p' = 3$, так как добавление всех остальных семи главных компонент может повысить суммарную характеристику рассеяния не более чем на 10%.

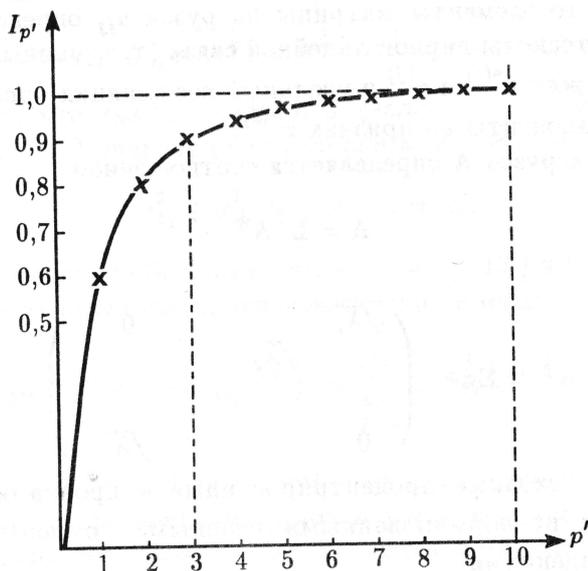


Рис. 4.1. Изменение относительной доли суммарной дисперсии исследуемых признаков, обусловленной первыми p' главными компонентами, в зависимости от p' (случай $p = 10$)

Следствие 2. Если X^* — вектор нормированных признаков $x^{*(1)}, \dots, x^{*(p)}$, т. е. $E x^{*(j)} = 0$ и $D x^{*(j)} = 1$ для $j = \overline{1, p}$, то согласно замечанию 3 ковариационная и корреляционные матрицы совпадают, т. е. $\Sigma_{X^*} = R$ и из б) и в) следует

$$\text{tr } \Sigma_Z = \text{tr } \Sigma_{X^*} = \text{tr } R = p$$

$$\sum_{k=1}^p \lambda_k = p.$$

Тогда критерий информативности (4.4') может быть представлен в виде

$$I_{p'}(Z(X)) = \frac{\lambda_1 + \dots + \lambda_{p'}}{p}. \quad (4.4'')$$

Матрица «нагрузок» $A = (a_{ij})$, $i, j = 1, 2, \dots, p$, главная компонента на исходные признаки также является важной характеристикой главных компонент. Если анализируемые переменные $X = (x^{(1)}, x^{(2)}, \dots, x^{(p)})^T$ предварительно процентрированы и пронормированы (см. выше замечания 1 и 3), т.е. если главные компоненты строятся для признаков $X^* = (x^{*(1)}, x^{*(2)}, \dots, x^{*(p)})^T$, $E x^{*(i)} = 0$, $D x^{*(i)} = 1$, $i = 1, 2, \dots, p$, то элементы матрицы нагрузок a_{ij} определяют одновременно степень тесноты парной линейной связи (т.е. парный коэффициент корреляции) между $x^{*(i)}$ и $z^{(j)}$ и удельный вес влияния *пронормированной* j -й главной компоненты на признак $x^{*(i)}$.

Матрица нагрузок A определяется соотношением

$$A = L^T \Lambda^{\frac{1}{2}}, \quad (4.11)$$

где

$$\Lambda^{\frac{1}{2}} = \Sigma_Z^{\frac{1}{2}} = \begin{pmatrix} \sqrt{\lambda_1} & & & 0 \\ & \sqrt{\lambda_2} & & \\ & & \ddots & \\ 0 & & & \sqrt{\lambda_p} \end{pmatrix}.$$

Она связывает исходные процентрированные и пронормированные переменные X^* с пронормированными главными компонентами $z_n^{(j)} = z^{(j)} / \sqrt{\lambda_j}$ соотношениями:

$$X^* = L^T \Lambda^{\frac{1}{2}} \Lambda^{-\frac{1}{2}} Z = A Z_n, \quad (4.12)$$

т.е.

$$x^{*(i)} = a_{i1} z_n^{(1)} + a_{i2} z_n^{(2)} + \dots + a_{ip} z_n^{(p)}. \quad (4.12')$$

Таким образом, коэффициент a_{ij} действительно определяет удельный вес влияния j -й нормированной главной компоненты $z_n^{(j)}$ на i -й исходный признак. Это подтверждается, в частности, и следующим фактом:

$$\begin{aligned} r(x^{*(i)}, z^{(j)}) &= \frac{E[(x^{*(i)} - E x^{*(i)})(z^{(j)} - E z^{(j)})]}{\sqrt{D x^{*(i)} D z^{(j)}}} \\ &= \frac{E(x^{*(i)} z^{(j)})}{\sqrt{\lambda_j}} = E\left(x^{*(i)} \frac{z^{(j)}}{\sqrt{\lambda_j}}\right) \\ &= E(x^{*(i)} z_n^{(j)}) = E\left[(a_{i1} z_n^{(1)} + \dots + a_{ip} z_n^{(p)}) z_n^{(j)}\right] \\ &= a_{ij} E\left((z_n^{(j)})^2\right) = a_{ij}, \end{aligned} \quad (4.13)$$