Big Data Analysis (MA60306)

Bibhas Adhikari

Spring 2022-23, IIT Kharagpur

Lecture 18 March 15, 2023

Bibhas Adhikari (Spring 2022-23, IIT Kharag

Big Data Analysis

Lecture 18 March 15, 2023 1 / 14

3

・ 何 ト ・ ヨ ト ・ ヨ ト

Observation from LDA The posterior distribution is a primary concept to make predictions. Finding $\mathbb{E}[L(\mathbf{x})] = \mathbb{E}[\mathbf{b}^T \mathbf{x}]$ and $Var[L(\mathbf{x})]$ is crucial

3

< □ > < □ > < □ > < □ > < □ > < □ >

Observation from LDA The posterior distribution is a primary concept to make predictions. Finding $\mathbb{E}[L(\mathbf{x})] = \mathbb{E}[\mathbf{b}^T \mathbf{x}]$ and $Var[L(\mathbf{x})]$ is crucial

Problem Find the expected value of a function $f(\mathbf{x})$ with respect to a probability distribution $p(\mathbf{x})$ using a numerical sampling!

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

Observation from LDA The posterior distribution is a primary concept to make predictions. Finding $\mathbb{E}[L(\mathbf{x})] = \mathbb{E}[\mathbf{b}^T \mathbf{x}]$ and $Var[L(\mathbf{x})]$ is crucial

Problem Find the expected value of a function $f(\mathbf{x})$ with respect to a probability distribution $p(\mathbf{x})$ using a numerical sampling!

 \rightarrow If f is continuous then $\mathbb{E}[f] = \int f(\mathbf{x})p(\mathbf{x})d\mathbf{x}$ and replace the integral by summation for discrete random variables

Observation from LDA The posterior distribution is a primary concept to make predictions. Finding $\mathbb{E}[L(\mathbf{x})] = \mathbb{E}[\mathbf{b}^T \mathbf{x}]$ and $Var[L(\mathbf{x})]$ is crucial

Problem Find the expected value of a function $f(\mathbf{x})$ with respect to a probability distribution $p(\mathbf{x})$ using a numerical sampling!

- \rightarrow If f is continuous then $\mathbb{E}[f] = \int f(\mathbf{x})p(\mathbf{x})d\mathbf{x}$ and replace the integral by summation for discrete random variables
- → The idea of sampling methods is to obtain a set of samples from $\{x_l : 1 \le l \le L\}$ drawn independently from the distribution p(x)

Observation from LDA The posterior distribution is a primary concept to make predictions. Finding $\mathbb{E}[L(\mathbf{x})] = \mathbb{E}[\mathbf{b}^T \mathbf{x}]$ and $Var[L(\mathbf{x})]$ is crucial

Problem Find the expected value of a function $f(\mathbf{x})$ with respect to a probability distribution $p(\mathbf{x})$ using a numerical sampling!

- → If f is continuous then $\mathbb{E}[f] = \int f(\mathbf{x})p(\mathbf{x})d\mathbf{x}$ and replace the integral by summation for discrete random variables
- → The idea of sampling methods is to obtain a set of samples from $\{x_l : 1 \le l \le L\}$ drawn independently from the distribution p(x)
- $\rightarrow\,$ Then the expectation can be approximated by a finite sum

$$\widehat{f} = \frac{1}{L} \sum_{l=1}^{L} f(\mathbf{x}_l)$$

Observation from LDA The posterior distribution is a primary concept to make predictions. Finding $\mathbb{E}[L(\mathbf{x})] = \mathbb{E}[\mathbf{b}^T \mathbf{x}]$ and $Var[L(\mathbf{x})]$ is crucial

Problem Find the expected value of a function $f(\mathbf{x})$ with respect to a probability distribution $p(\mathbf{x})$ using a numerical sampling!

- \rightarrow If f is continuous then $\mathbb{E}[f] = \int f(\mathbf{x})p(\mathbf{x})d\mathbf{x}$ and replace the integral by summation for discrete random variables
- → The idea of sampling methods is to obtain a set of samples from $\{x_l : 1 \le l \le L\}$ drawn independently from the distribution p(x)
- $\rightarrow\,$ Then the expectation can be approximated by a finite sum

$$\widehat{f} = \frac{1}{L} \sum_{l=1}^{L} f(\mathbf{x}_l)$$

 $\rightarrow\,$ The variance of this estimator is

$$var[\widehat{f}] = rac{1}{L}\mathbb{E}[(f - \mathbb{E}[f])^2]$$

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

Note

 $\rightarrow\,$ Accuracy of the estimator does not depend on the dimension of ${\bf x}$

э

(B)

Note

- $\rightarrow\,$ Accuracy of the estimator does not depend on the dimension of x
- $\rightarrow\,$ In principle, high accuracy may be achievable with a relatively small number of samples $x_{\rm l}$

Note

- $\rightarrow\,$ Accuracy of the estimator does not depend on the dimension of x
- $\rightarrow\,$ In principle, high accuracy may be achievable with a relatively small number of samples $x_{\it l}$

Problem Are the samples independent?

Graphical model A convenient representation of joint distribution $p(\mathbf{x})$

Graphical model A convenient representation of joint distribution $p(\mathbf{x})$

 \rightarrow Graph: G = (V, E), where V is called the vertex set, $E \subset V \times V$ is called the edge set

3

() < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < () < ()

Graphical model A convenient representation of joint distribution $p(\mathbf{x})$

- \rightarrow Graph: G = (V, E), where V is called the vertex set, $E \subset V \times V$ is called the edge set
- $\rightarrow\,$ The nodes represent random variables, and edges represent probabilistic relationship between those random variables

Graphical model A convenient representation of joint distribution $p(\mathbf{x})$

- \rightarrow Graph: G = (V, E), where V is called the vertex set, $E \subset V \times V$ is called the edge set
- $\rightarrow\,$ The nodes represent random variables, and edges represent probabilistic relationship between those random variables
- $\rightarrow\,$ The graph captures the way in which a joint distribution over all the random variables can be decomposed into a product of factors each depending only on a subset of random variables

くぼう くさう くさう しき

Graphical model A convenient representation of joint distribution $p(\mathbf{x})$

- \rightarrow Graph: G = (V, E), where V is called the vertex set, $E \subset V \times V$ is called the edge set
- $\rightarrow\,$ The nodes represent random variables, and edges represent probabilistic relationship between those random variables
- \rightarrow The graph captures the way in which a joint distribution over all the random variables can be decomposed into a product of factors each depending only on a subset of random variables

Belief networks/Bayesian networks/directed graphical models - the edges in these graphs are directed with other certain structure. The edges express causal relationships between the variables

Graphical model A convenient representation of joint distribution $p(\mathbf{x})$

- \rightarrow Graph: G = (V, E), where V is called the vertex set, $E \subset V \times V$ is called the edge set
- $\rightarrow\,$ The nodes represent random variables, and edges represent probabilistic relationship between those random variables
- \rightarrow The graph captures the way in which a joint distribution over all the random variables can be decomposed into a product of factors each depending only on a subset of random variables

Belief networks/Bayesian networks/directed graphical models - the edges in these graphs are directed with other certain structure. The edges express causal relationships between the variables Markov random fields/undirected graphical models - the edges express constraints between random variables

A B A B A B A B A B A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A

Bayesian networks Consider a joint random variables $\mathbf{X} = (X_1, X_2, X_3)$. Then by product rule:

$$p(a, b, c) = p(X_1 = a, X_2 = b, X_3 = c) = p(c|a, b) p(a, b)$$

3

(日) (四) (日) (日) (日)

Bayesian networks Consider a joint random variables $\mathbf{X} = (X_1, X_2, X_3)$. Then by product rule:

$$p(a, b, c) = p(X_1 = a, X_2 = b, X_3 = c) = p(c|a, b) p(a, b)$$

= $p(c|a, b) p(b|a) p(a)$

3

(日) (四) (日) (日) (日)

Bayesian networks Consider a joint random variables $\mathbf{X} = (X_1, X_2, X_3)$. Then by product rule:

$$p(a, b, c) = p(X_1 = a, X_2 = b, X_3 = c) = p(c|a, b) p(a, b)$$

= $p(c|a, b) p(b|a) p(a)$

This is valid for any choice of the distribution. The graphical model representation of this joint distribution is given by: For each conditional distribution, we add directed edge to the graph from the nodes corresponding to the random variables on which the distribution is conditional

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

Thus a link going from a node a to a node b, we say that node a is the parent of node b, and we say that the node b is the child of a

▲ □ ▶ ▲ □ ▶ ▲ □ ▶

Thus a link going from a node *a* to a node *b*, we say that node *a* is the parent of node *b*, and we say that the node *b* is the child of *a* From p(a, b, c) = p(c|a, b) p(b|a) p(a), observe that the left-hand side is symmetrical wrt the variables *a*, *b*, *c* but the right-hand side is not.

▲ □ ▶ ▲ □ ▶ ▲ □ ▶

Thus a link going from a node *a* to a node *b*, we say that node *a* is the parent of node *b*, and we say that the node *b* is the child of *a* From p(a, b, c) = p(c|a, b) p(b|a) p(a), observe that the left-hand side is symmetrical wrt the variables *a*, *b*, *c* but the right-hand side is not. In general, for *K* random variables,

$$p(X_1,...,X_K) = p(X_K|X_1,...,X_{K-1})...p(X_2|X_1)p(X_1)$$

< 日 > < 同 > < 回 > < 回 > < 回 > <

Thus a link going from a node *a* to a node *b*, we say that node *a* is the parent of node *b*, and we say that the node *b* is the child of *a* From p(a, b, c) = p(c|a, b) p(b|a) p(a), observe that the left-hand side is symmetrical wrt the variables *a*, *b*, *c* but the right-hand side is not. In general, for *K* random variables,

$$p(X_1,...,X_K) = p(X_K|X_1,...,X_{K-1})...p(X_2|X_1)p(X_1)$$

Then observe that, for any K, the corresponding Graphical model is fully connected, i.e. any two pair of nodes there is an link connecting them.

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

Consider the graph

 $p(\mathbf{X}) = p(X_1)p(X_2)p(X_3)p(X_4|X_1, X_2, X_3)p(X_5|X_1, X_3)p(X_6|X_4)p(X_7|X_4, X_5)$

- 3

イロト イポト イヨト イヨト

Consider the graph

$$p(\mathbf{X}) = p(X_1)p(X_2)p(X_3)p(X_4|X_1, X_2, X_3)p(X_5|X_1, X_3)p(X_6|X_4)p(X_7|X_4, X_5)$$

For any graph with K nodes, the joint distribution is given by

$$p(\mathbf{X}) = \prod_{k=1}^{K} p(X_k | pa_k)$$

where pa_k denotes the set of parents of X_k , and $\mathbf{X} = (X_1, \dots, X_K)$

3

< □ > < □ > < □ > < □ > < □ > < □ >

Directed acyclic graphs (DAGs) - a directed graph without cycles i.e. there are no closed paths within the graph

3

(日) (四) (日) (日) (日)

Directed acyclic graphs (DAGs) - a directed graph without cycles i.e. there are no closed paths within the graph

Ancestral sampling Suppose that the random variables have been ordered such that there are no links from any node to any lower numbered node i.e. each node has a higher number than any of its parents.

・ 何 ト ・ ヨ ト ・ ヨ ト

Directed acyclic graphs (DAGs) - a directed graph without cycles i.e. there are no closed paths within the graph

Ancestral sampling Suppose that the random variables have been ordered such that there are no links from any node to any lower numbered node i.e. each node has a higher number than any of its parents.

Goal: Draw a sample $\widehat{X}_1, \ldots, \widehat{X}_K$ from the joint distribution, starting from the lowest-numbered node

Directed acyclic graphs (DAGs) - a directed graph without cycles i.e. there are no closed paths within the graph

Ancestral sampling Suppose that the random variables have been ordered such that there are no links from any node to any lower numbered node i.e. each node has a higher number than any of its parents.

Goal: Draw a sample $\widehat{X}_1, \ldots, \widehat{X}_K$ from the joint distribution, starting from the lowest-numbered node

In practical applications, the higher numbered nodes correspond to the observed values and the lower numbered nodes correspond to the latent variables. For example, if an image is considered as an observation then object, position, and orientation will be the latent variables. (Draw a graphical model!)

イロト 不得 トイヨト イヨト 二日

 \rightarrow Draw a sample from the distribution $p(X_1)$, call it \hat{x}_1

3

(日) (四) (日) (日) (日)

- \rightarrow Draw a sample from the distribution $p(X_1)$, call it \widehat{x}_1
- \rightarrow Do the same for each conditional distribution $p(X_k|pa_k)$ attached with all the nodes sequentially in order

3

▲ □ ▶ ▲ □ ▶ ▲ □ ▶

- \rightarrow Draw a sample from the distribution $p(X_1)$, call it \widehat{x}_1
- \rightarrow Do the same for each conditional distribution $p(X_k|pa_k)$ attached with all the nodes sequentially in order
- \rightarrow Once we have sampled from the final random variable x_K , we will have achieved our objective of obtaining a sample from the joint distribution

▲ □ ▶ ▲ □ ▶ ▲ □ ▶

- ightarrow Draw a sample from the distribution $p(X_1)$, call it \widehat{x}_1
- \rightarrow Do the same for each conditional distribution $p(X_k|pa_k)$ attached with all the nodes sequentially in order
- \rightarrow Once we have sampled from the final random variable x_K , we will have achieved our objective of obtaining a sample from the joint distribution
- \rightarrow To obtain a sample from some marginal distribution corresponding to a subset of variables, the sampled values for the required nodes are taken out ignoring the samples values for the remaining nodes

For example, to draw a sample from a distribution $p(x_2, x_4)$, we sample from the full joint distribution and then retain the values \hat{x}_2, \hat{x}_4 and discard the remaining values $\{\hat{x}_{j\neq 2,4}\}$

Linear-Gaussian models - a multivariate Gaussian can be expressed as a directed graph corresponding to a linear-Gaussian model

3

• # • • = • • = •

Linear-Gaussian models - a multivariate Gaussian can be expressed as a directed graph corresponding to a linear-Gaussian model

Consider an arbitrary directed acyclic graph with n nodes, which is attached with a random variable X_i having Gaussian distribution. The mean of this distribution is taken to be a linear combination of the states of the parent nodes pa_i of node i:

$$p(X_i|pa_i) = \mathcal{N}\left(X_i \left| \sum_{j \in pa_i} w_{ij}x_j + b_i, v_i \right. \right),$$

where w_{ij} and b_i are parameters governing the mean, and v_i is the variance of the conditional distribution for X_i

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

Then setting $\mathbf{X} = (X_1, X_2, \dots, X_n)$. Then

$$\ln p(\mathbf{x}) = \sum_{i=1}^{n} \ln p(x_i | pa_i)$$
$$= -\sum_{i=1}^{n} \frac{1}{2v_i} \left(x_i - \sum_{j \in pa_i} w_{ij} x_j - b_i \right)^2 + \text{constant}$$

3

イロト イポト イヨト イヨト

Then setting $\mathbf{X} = (X_1, X_2, \dots, X_n)$. Then

$$n p(\mathbf{x}) = \sum_{i=1}^{n} \ln p(x_i | pa_i)$$
$$= -\sum_{i=1}^{n} \frac{1}{2v_i} \left(x_i - \sum_{j \in pa_i} w_{ij} x_j - b_i \right)^2 + \text{constant}$$

Finding mean and covariance of the joint distribution recursively:

 \rightarrow From the expression of $p(X_i | pa_i)$,

$$X_i = \sum_{j \in pa_i} w_{ij} X_j + b_i + \sqrt{v_i} \epsilon_i,$$

where ϵ_i is a zero mean, unit variance Gaussian rv satisfying $\mathbb{E}[\epsilon_i] = 0$ and $\mathbb{E}[\epsilon_i \epsilon_j] = I_{ij}$, the *ij*-th entry of the identity matrix

Then setting $\mathbf{X} = (X_1, X_2, \dots, X_n)$. Then

$$\ln p(\mathbf{x}) = \sum_{i=1}^{n} \ln p(x_i | pa_i)$$
$$= -\sum_{i=1}^{n} \frac{1}{2v_i} \left(x_i - \sum_{j \in pa_i} w_{ij} x_j - b_i \right)^2 + \text{constant}$$

Finding mean and covariance of the joint distribution recursively:

 \rightarrow From the expression of $p(X_i | pa_i)$,

$$X_i = \sum_{j \in pa_i} w_{ij} X_j + b_i + \sqrt{v_i} \epsilon_i,$$

where ϵ_i is a zero mean, unit variance Gaussian rv satisfying $\mathbb{E}[\epsilon_i] = 0$ and $\mathbb{E}[\epsilon_i \epsilon_j] = I_{ij}$, the *ij*-th entry of the identity matrix \rightarrow Then

$$\mathbb{E}[X_i] = \sum_{i \in pa_i} w_{ij} \mathbb{E}[X_j] + b_i$$

Bibhas Adhikari (Spring 2022-23, IIT Kharag

Further

$$Cov[X_i, X_j] = \mathbb{E}[(X_i - \mathbb{E}[X_i])(X_j - \mathbb{E}[X_j])]$$

= $\mathbb{E}\left[(X_i - \mathbb{E}[X_i])\left\{\sum_{k \in pa_j} w_{jk}(X_k - \mathbb{E}(X_k)) + \sqrt{v_j}\epsilon_j\right\}\right]$
= $\sum_{k \in pa_j} w_{jk}Cov[X_i, X_k] + I_{ij}v_j$

Thus covariance can similarly be evaluated recursively starting from the lowest numbered node

3

A B A A B A

Example Suppose the graph corresponding to a graphical model has no links and only with n isolated nodes i.e. random variables.

 \rightarrow There are no w_{ij} and hence only *n* parameters v_i

A B A A B A

Example Suppose the graph corresponding to a graphical model has no links and only with n isolated nodes i.e. random variables.

- \rightarrow There are no w_{ij} and hence only *n* parameters v_i
- \rightarrow From the recursive relations of $\mathbb{E}[X_i]$ and $Cov[X_i, X_j]$, we see that the mean of **X** is (b_1, b_2, \ldots, b_n)

- 3

<日

<</p>

Example Suppose the graph corresponding to a graphical model has no links and only with n isolated nodes i.e. random variables.

- \rightarrow There are no w_{ij} and hence only *n* parameters v_i
- \rightarrow From the recursive relations of $\mathbb{E}[X_i]$ and $Cov[X_i, X_j]$, we see that the mean of **X** is (b_1, b_2, \ldots, b_n)
- ightarrow The covariance matrix is diagonal of the form $\textit{diag}(v_1,\ldots,v_n)$

医静脉 医黄疸 医黄疸 医黄疸

Example Suppose the graph corresponding to a graphical model has no links and only with n isolated nodes i.e. random variables.

- \rightarrow There are no w_{ij} and hence only *n* parameters v_i
- \rightarrow From the recursive relations of $\mathbb{E}[X_i]$ and $Cov[X_i, X_j]$, we see that the mean of **X** is (b_1, b_2, \ldots, b_n)
- $\rightarrow\,$ The covariance matrix is diagonal of the form $\mathit{diag}(\mathit{v}_1,\ldots,\mathit{v}_n)$
- \rightarrow The joint distribution has 2n parameters and represents a set of n independent univariate Gaussian distributions

< ロ > < 同 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < 回 > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ > < □ >

Example Suppose the graph corresponding to a Graphical model is fully connected i.e. each node has all lower numbered nodes as parents

 \rightarrow The matrix defined by w_{ij} has i-1 nonzero entries in each row with the diagonal entry 0

< □ > < □ > < □ > < □ > < □ > < □ >

Example Suppose the graph corresponding to a Graphical model is fully connected i.e. each node has all lower numbered nodes as parents

- \rightarrow The matrix defined by w_{ij} has i-1 nonzero entries in each row with the diagonal entry 0
- \rightarrow The total number of parameters w_{ij} is n(n-1)/2

Example Suppose the graph corresponding to a Graphical model is fully connected i.e. each node has all lower numbered nodes as parents

- \rightarrow The matrix defined by w_{ij} has i-1 nonzero entries in each row with the diagonal entry 0
- \rightarrow The total number of parameters w_{ij} is n(n-1)/2
- \rightarrow The total number of independent parameters w_{ij} and v_i is then n(n+1)/2 corresponding to a general symmetric matrix

A B A B A B A B A B A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A

Example Suppose the graph corresponding to a Graphical model is fully connected i.e. each node has all lower numbered nodes as parents

- \rightarrow The matrix defined by w_{ij} has i-1 nonzero entries in each row with the diagonal entry 0
- \rightarrow The total number of parameters w_{ij} is n(n-1)/2
- \rightarrow The total number of independent parameters w_{ij} and v_i is then n(n+1)/2 corresponding to a general symmetric matrix

Example

$$\mu = (b_1, b_2 + w_{21}b_1, b_3 + w_{32}b_2 + w_{32}w_{21}b_1)$$

$$\Sigma = \begin{bmatrix} v_1 & w_{21}v_1 & w_{32}w_{21}v_1 \\ w_{21}v_1 & v_2 + w_{21}^2v_1 & w_{32}(v_2 + w_{21}^2v_1) \\ w_{32}w_{21}v_1 & w_{32}(v_2 + w_{21}^2v_1) & v_3 + w_{32}^2(v_2 + w_{21}^2v_1) \end{bmatrix}$$

A B A B A B A B A B A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A
 B
 A