

MOTIVACIÓN.

CARACTERÍSTICAS DE MÉTODOS BAYESIANOS.

- ACCOUNTING FOR UNCERTAINTY.

$$P(\theta|x) = \frac{P(x|\theta) \cdot P(\theta)}{P(x)}$$

- TÍPICAMENTE SE REQUIEREN INTEGRALES, QUE HAY QUE EVALUAR DE FORMA APROXIMADA.

* MONTE-CARLO SAMPLING

* VARIATIONAL METHODS.

WHY BE BAYESIAN WITH BIG DATA

- $p(\theta|x)$ se haría infinitamente estrecha en torno al máximo de $p(x|\theta)$, y tendríamos $\hat{\theta}_{MAP} = \hat{\theta}_{ML}$.
- Además $\int \hat{s}(\theta) p(\theta|x) d\theta \rightarrow \hat{s}(\hat{\theta}_{MAP})$
- En aplicaciones de big data, el nº de parámetros y la complejidad del modelo crece con el nº de datos.
- RETOS:
 - * COMPUTACIONALES Y DE ALGORÍTMICA:
requerimos métodos secuenciales y paralelizables.
 - * NUEVOS MÉTODOS en los que puede ser deseable incurrir en mayores errores de aproximación, o permitir sesgo no nulo
 - * IDEALMENTE: Entender este tradeoff.

OUTLINE

0. MOTIVATION

1. EXPONENTIAL FAMILIES.

THE EXPONENTIAL FAMILY OF DISTRIBUTIONS. (I)

- \mathbf{x} is a random vector, $\mathbf{X} \in S_1 \subset \mathbb{R}^{d_1}$
- $\boldsymbol{\theta}$ is a parameter vector, $\boldsymbol{\theta} \in S_2 \subset \mathbb{R}^{d_2}$
(random)

DEF: $\{p(\cdot|\theta)\}$ es una familia exponencial, si cada densidad de la familia puede escribirse como:

$$p(x|\theta) = h(x) e^{\langle \eta(\theta), t(x) \rangle - \log Z(\eta(\theta))}$$

$$\rightarrow \langle \eta(\theta), t(x) \rangle = [\eta(\theta)]^T t(x) = \sum_{i=1}^K \eta_i(\theta) t_i(x)$$

$\rightarrow \eta_i(\theta) \equiv$ PARÁMETROS NATURALES

$\rightarrow t_i(x) \equiv$ ESTADÍSTICOS NATURALES (SUFICIENTES) $\nparallel X \mid t(x)$

T.E.F.O.D. (II)

\rightarrow ASUMIMOS QUE S_1 NO DEPENDE DE θ

\rightarrow LA FAMILIA ES REGULAR si S_2 es un conjunto abierto.

\rightarrow LA FAMILIA ES MINIMA si No $\exists a \neq 0$ tal que $\langle a, t(x) \rangle = \text{cte.}$

\rightarrow OTRAS FORMAS FRECUENTES:

$$p(x|\theta) = \alpha(\theta) h(x) \exp[\langle \eta(\theta), t(x) \rangle]$$

$$p(x|\theta) = h(x) \exp[\langle \eta(\theta), t(x) \rangle - A(\theta)]$$

$$A(\theta) = \log[Z(\eta(\theta))]$$

Examples

Gaussian

Bernoulli

Binomial

...

Ver tx. 3. de los que me
descargué.

NATURAL PARAMETER FORM FOR BERNOUILLI

$$\begin{aligned}
 p(x) &= \theta^x (1-\theta)^{1-x} \\
 &= \exp \left[\log (\theta^x (1-\theta)^{1-x}) \right] \\
 &= \exp \left[x \log \theta + (1-x) \log (1-\theta) \right] \\
 &= \exp \left[x \log \frac{\theta}{1-\theta} + \log (1-\theta) \right]
 \end{aligned}$$

$$\begin{aligned}
 \text{Luego: } h(x) &= 1. & \eta(\theta) &= \log \frac{\theta}{1-\theta} \\
 t(x) &= x & -\log Z(\eta) &= \log (1-\theta)
 \end{aligned}$$

$$Z(\theta) = \frac{1}{1-\theta}$$

$$\begin{aligned}
 \text{Además, como } \frac{\theta}{1-\theta} &= e^\eta & \theta &= e^\eta (1-\theta) = e^\eta - \theta e^\eta \\
 \theta &= \frac{e^\eta}{1+e^\eta} & 1-\theta &= \frac{1}{1+e^\eta}
 \end{aligned}$$

$$\text{Luego } Z(\eta(\theta)) = 1+e^\eta$$

$$p(x|\theta) = \exp \left[x \cancel{\log \eta} - \log (1+e^\eta) \right]$$

NATURAL PARAMETER FOR GAUSSIAN

$$\begin{aligned}
 p(x) &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] \\
 &= \frac{1}{\sqrt{2\pi}} \exp\left[-\log\sigma\right] \exp\left[\frac{-x^2 + 2\mu x - \mu^2}{2\sigma^2}\right] \\
 &= \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{x^2}{2\sigma^2} + \frac{\mu x}{\sigma^2} - \left(\frac{\mu^2}{2\sigma^2} + \log\sigma\right)\right]
 \end{aligned}$$

$$\left. \begin{array}{l} \bullet h(x) = \frac{1}{\sqrt{2\pi}} \\ \bullet t(x) = \begin{bmatrix} x \\ x^2 \end{bmatrix} \end{array} \right\} \quad \left. \begin{array}{l} \bullet \eta(\theta) = \begin{bmatrix} \mu/\sigma^2 \\ -1/2\sigma^2 \end{bmatrix} \\ \bullet Z(\theta) = \exp\left[\frac{\mu^2}{2\sigma^2} + \log\sigma \cancel{+ c}\right] \end{array} \right\}$$

$$\left. \begin{array}{l} \eta_1 = \mu/\sigma^2 \\ \eta_2 = -1/2\sigma^2 \end{array} \right\} \rightarrow \sigma^2 = \frac{-1}{2\eta_2} \quad \rightarrow \mu = \eta_1 \cdot \sigma^2 = \frac{-\eta_1}{2\eta_2}$$

$$\begin{aligned}
 Z(\theta) &= \exp\left[\frac{\eta_1^2}{4\eta_2^2} \cdot (-\eta_2) + \frac{1}{2} \log \frac{-1}{2\eta_2}\right] \\
 &= \exp\left[\frac{-\eta_1^2}{4\eta_2^2} - \frac{1}{2} \log(-2\eta_2)\right]
 \end{aligned}$$

MUESTREO DE $p(x|\theta)$

Si la distribución de X es de una familia exponencial con parámetros naturales $\eta_i(\theta)$ y estadísticos naturales $t_i(x)$, entonces una colección de n muestras de $X = (X_1, \dots, X_n)$ tb. sigue una familia exponencial con los mismos parámetros naturales, y estadísticos naturales

$$t'_i(x) = \sum_{k=1}^n t_i(x_k)$$

INPT. FOR
BIG DATA

Demo:

$$\begin{aligned} p(\underline{x}) &= \prod_{k=1}^n p(x_k|\theta) = \prod_{k=1}^n h(x_k) \exp \left[\sum_i t_i(x_k) \eta_i(\theta) - \log Z(\theta) \right] \\ &= \prod_{k=1}^n h(x_k) \exp \left[\sum_{k=1}^n \sum_i t_i(x_k) \eta_i(\theta) - \log Z(\theta) \right] \\ &= \prod_{k=1}^n h(x_k) \exp \left[\sum_i \eta_i(\theta) \sum_{k=1}^n t_i(x_k) - \log Z(\theta) \right] \end{aligned}$$

THE ROLE OF $Z(\eta)$ → $A(\eta)$

- PERMITE NORMALIZAR LA DISTRIBUCIÓN, i.e.:

$$\int p(x|\theta) dx = \exp^{-A(\eta)} \int h(x) \exp \left[\eta^\top t(x) \right] dx = 1$$

$$\text{Luego } e^{A(\eta)} = Z(\eta) = \int h(x) \exp \left[\eta^\top t(x) \right] dx$$

i.e., si $t(x) = x$ tendríamos la T. Laplace.

- VALORES A VER ALGUNAS VENTAJAS DE LA REPRESENTACIÓN NATURAL.

6/

DERIVADA DE $A(\eta)$

$$A(\eta) = \log Z(\eta) = \log \underbrace{\int h(x) e^{\eta t(x)} dx}_{Q(\eta)}$$

$$\begin{aligned} \frac{d A(\eta)}{d \eta} &= \frac{1}{Q(\eta)} \cdot \frac{d Q(\eta)}{d \eta} = \frac{\int h(x) e^{\eta + t(x)} \cdot t(x) dx}{\int h(x) e^{\eta + t(x)} dx} \cdot \frac{e^{-A(\eta)}}{e^{-A(\eta)}} \\ &= \frac{\int p(x) \cdot t(x) dx}{\int p(x) dx} = \mathbb{E}[t(x)] \end{aligned}$$

E.g. Bernoulli:

$$\left. \begin{array}{l} A(\eta) = \log(1+e^\eta) \\ \frac{d A}{d \eta} = \frac{e^\eta}{1+e^\eta} = 0 \end{array} \right\} \text{Luego } \mathbb{E}\{t(x)\} = \mathbb{E}\{x\} = 0$$

E.g. Gaussian:

$$A(\eta) = \frac{-\eta_1^2}{4\eta_2} - \frac{1}{2} \log(-2\eta_2)$$

$$\frac{d A}{d \eta_1} = \frac{-2\eta_1}{4\eta_2} = \frac{-\eta_1}{2\eta_2} = \mu \quad \left[\mathbb{E}\{t_1(x)\} = \mathbb{E}\{x\} \right]$$

$$\frac{d A}{d \eta_2} = \frac{\eta_1^2}{4\eta_2^2} + \frac{1}{2} \frac{-2}{2\eta_2} = \mu^2 - \frac{1}{2\eta_2} = \mu^2 + \sigma^2 \left[\mathbb{E}\{t_2(x)\} = \mathbb{E}\{x^2\} \right]$$

SEGUNDA DERIVADA DE $A(\eta)$

- De manera similar:

$$\begin{aligned}\nabla^2 A(\eta) &= \mathbb{E} \left[t(x) t(x)^T \right] - \mathbb{E} \{ t(x) \} \mathbb{E} \{ t(x) \}^T \\ &= \text{Cov} [t(x)]\end{aligned}$$

MOMENT GENERATING FUNCTION

- For a general r.v. T , its moment generating function is defined as $M_T(s) = \mathbb{E} \{ e^{s \cdot T} \}$
- It does not always exist, but if it does it allows an easy calculation of moments, since:

$$\mathbb{E} \{ e^{s \cdot T} \} = 1 + \mathbb{E} \{ s \cdot T \} + \frac{\mathbb{E} \{ (s \cdot T)^2 \}}{2!} + \frac{\mathbb{E} \{ (s \cdot T)^3 \}}{3!} + \dots$$

Therefore $\left. \nabla_s^k \mathbb{E} \{ e^{s \cdot T} \} \right|_{s=0} = \mathbb{E} \{ T^k \}$

- FOR EXPONENTIAL FAMILIES:

$$\begin{aligned}\mathbb{E} \{ e^{s \cdot t(x)} \} &= \int e^{s \cdot t(x)} \cdot p(x) dx \\ &= \int e^{s \cdot t(x)} \cdot h(x) \cdot e^{\eta^T t(x)} e^{-\log Z} dx \\ &= e^{-\log Z} \int h(x) e^{(s+\eta)^T t} dx \\ &= e^{-\log Z(\eta)} \cdot Z(s+\eta)\end{aligned}$$

$$= e^{A(\eta+s) - A(\eta)}$$

Cumulant generating function

$$e^{(t+s)^3 - t^3}$$

$$\frac{d}{dt} = e^{(t+s)^3 - t^3} \Big|_{s=0}$$

$$= 3(t+s)^2 - 3t^2$$

$$\left. \nabla_s^k \mathbb{E} \{ e^{s \cdot t(x)} \} \right|_{s=0} = \left. \nabla_s^k A(\eta+s) \right|_{s=0} = \nabla_s^k A(\eta)$$

OTRAS PROPIEDADES

- Si la familia es regular, definimos el "score" con respecto al parámetro natural:

$$\nabla(x; \eta) \triangleq \nabla_{\eta} \log p(x|\eta) = \nabla_{\eta} \left[\langle \eta, t \rangle - \log Z(\eta) \right]$$

$$= t(x) - \nabla_{\eta} \log Z(\eta) = t(x) - \mathbb{E}\{t(x)\}$$

- Si la familia es regular, la información de Fisher con respecto al parámetro natural es:

$$I(\eta) \triangleq \mathbb{E}\{\nabla(x, \eta) \nabla(x, \eta)^T\} = \mathbb{E}\{t(x) - \mathbb{E}\{t(x)\}\}^T = \text{Cov}(t(x)) = \nabla^2 \log Z(\eta)$$

• STANDING

• ML solution

$$\nabla_{\eta} \log p(x) = \nabla_{\eta} \left[\eta^T \sum_i t(x_i) - \log Z(\eta) \right]$$

luego en la solución se satisface

$$\nabla A(\eta)_{\text{ML}} = \frac{1}{N} \sum_{i=1}^N t(x_i) = 0$$

A(η)

CONJUGATE PRIORS IN BAYESIAN STATISTICS.

$$p(\theta|x, \alpha') = \frac{p(\theta|\alpha) \cdot p(x|\theta)}{P(x)}$$

Si se cumple q. $p(\theta|\alpha)$ y $p(\theta|x, \alpha')$ son pdfs paramétricas (en α') de la misma familia, entonces decimos que el prior $p(\theta|\alpha)$ es conjugado con la función de verosimilitud $p(x|\theta)$

→ En general, $\alpha' = \alpha'(\alpha, x)$

→ La definición es general ...

→ pero si $p(x|\theta)$ pertenece a una familia exponencial regular, entonces siempre se puede encontrar un prior conjugado. (q. tb. es exponencial)

$$\begin{aligned} \text{Def.: } p(x|\theta) &= h_x(x) \exp \left[\langle \eta_x(\theta), t_x(x) \rangle - \log Z_x(\eta_x(\theta)) \right] \\ &= h_x(x) \exp \left[\underbrace{\langle (\eta_x(\theta), -\log Z_x(\theta)),}_{t_\theta(\theta)} \underbrace{\langle t_x(x), 1 \rangle \rangle}_{t_\theta(\theta)} \right] \end{aligned}$$

• CONJ. PRIOR


$$p(\theta|\alpha) = h_\theta(\theta) \exp \left[\underbrace{\frac{t_\theta(\theta)}{t_\theta(\theta)}}_{\text{ESTADÍSTICOS NATURALES}} \langle \eta_\theta(\alpha), (\eta_x(\theta), -\log Z_x(\eta_x(\theta))) \rangle - \log Z_\theta(\eta_\theta(\alpha)) \right]$$

• POSTERIOR

$$p(\theta|x, \alpha) \propto h_\theta(\theta) \cdot \exp \left[\underbrace{\langle t_\theta(\theta), \eta_\theta(\alpha) + \underbrace{\langle t_x(x), 1 \rangle}_{\text{VALORES DIFERENTES DE LOS PARÁMETROS NATURALES}} \rangle}_{\text{MISMO PUNTO}} \right]$$

→ Mismo punto → Valores diferentes de los parámetros naturales

Ejemplo: Dirichlet y Multinomial.



- PRIOR: $p(\theta|\alpha) = \frac{\Gamma(\sum_i \alpha_i)}{\prod_i \Gamma(\alpha_i)} \cdot \prod_i \theta_i^{\alpha_i - 1}$

- MULTINOMIAL
TRIPLICIDAD: $p(x|\theta) = \frac{(\sum_i x_i)!}{x_1! x_2! \dots x_n!} \prod_{i=1}^n \theta_i^{x_i}$

x_1 : # 1's

x_2 : # 2's

\vdots

x_n : # n's

K experimentos

n posibles valores.

- POSTERIOR: $p(\theta|x, \alpha) \propto \prod_{i=1}^n \theta_i^{(x_i + \alpha_i) - 1}$

q. es Dirichlet con perímetros $x_i + \alpha_i$

Por tanto, ha de ser:

$$p(\theta|x) = \frac{\Gamma(\sum_i \alpha_i + x_i)}{\prod_i \Gamma(\alpha_i + x_i)} \cdot \prod_{i=1}^n \theta_i^{(x_i + \alpha_i) - 1}$$

Otros pares de conjugados:

- Gaussian - Gaussian.

- Beta - Bernoulli

...

MCMC INFERENCE


- Recordemos que en INF. BAYESIANA

$$p(\theta|x) = \frac{p(x|\theta) p(\theta)}{p(x)}$$

- EN OCASIONES θ , ADENÁS DE HIPERPARÁMETROS TIENE VAR. LATENTES DEL MODELO

- OBJETIVO MCMC: obtener muestras i.i.d de $p(\theta|x)$ ~~cuando esta no~~

~~SE PUEDE EVALUAR DE FORMA CERRADA,~~ o CUANDO QUIERO EVALUAR INTEGRALES TIPO $\int f(\theta) \cdot p(\theta|x) d\theta$



MCMC: $\theta_0, \theta_1, \dots, \theta_t, \theta_{t+1}$

Bajo DETERMINADAS CONDICIONES LA CADENA CONVERGE A LA DISTRIBUCIÓN BÚSQUEDA, DE MANERA QUE PODEMOS QUEDARNOS CON UNA SERIE DE VALORES (NO CONSECUTIVOS).

- WE COLLECT SAMPLES FROM THE ~~THE~~ SIMULATED TRAJECTORY AND USE THEM TO COMPUTE MONTE CARLO ESTIMATES.

BIAIS AND VARIANCE

- Imagine the estimation of r.variable z , using an estimator \hat{z}

$$\text{BIAS}[\hat{z}] = E\{\hat{z} - z\} = E\{\hat{z}\} - E\{z\}$$

$$\text{Var}[\hat{z}] = E\{(\hat{z} - E\{\hat{z}\})^2\}$$

$$\text{MSE}[\hat{z}] = (\text{BIAS}[\hat{z}])^2 + \text{Var}[\hat{z}]$$

- TÍPICAMENTE CON MCMC SE DEJA ITERAR MUCHO Y $\text{BIAS}[\hat{z}] \rightarrow 0$; EN BIG DATA PUEDE SER PREFERIBLE NO ELIMINAR COMPLETAMENTE EL SESGO ASINTÓTICO.

MONTE CARLO ESTIMATOR

- We want to estimate:

$$\mathbb{E}[f(\theta)] = \int_{\Theta} f(\theta) \cdot p(\theta|x) d\theta$$

- Given a sequence of i.i.d samples $\{\theta_i\}$ from $p(\theta|x)$:

$$\hat{\mathbb{E}}[f(\theta)] = \frac{1}{n} \sum_{i=1}^n f(\theta_i)$$

- El CLT permite escribir que conforme $n \rightarrow \infty$

~~$$\sqrt{n} \left(\hat{\mathbb{E}}[f(\theta)] - \mathbb{E}[f(\theta)] \right)$$~~


$\overset{d}{\rightarrow} N(0, \sigma^2)$

$$\frac{1}{n} \left(\sum_{i=1}^n f(\theta_i) - \mathbb{E}[f(\theta)] \right) \sim N(0, \sigma^2 (\sigma/\sqrt{n})^2)$$

- I.e., el error MSE decrece con Θ escala con $1/\sqrt{n}$ independientemente de la dimensión de θ .

MARKOV CHAIN

ESPACIO DE ESTADOS DISCRETO.



$$\theta_0, \theta_1, \theta_2, \theta_3, \theta_4, \dots \in \{\theta_a, \theta_b, \theta_c\}$$

Distrib. inicial: $\pi_0(\theta)$

Prob. de transición: $P(\theta_{t+1} | \theta_t) : T(\theta_t \rightarrow \theta_{t+1})$
(Prop. MARKOV).

Homogéneo: Cuando las propiedades no dependen de t .

ESPACIO DE ESTADOS CONTINUO

$$\theta_0, \theta_1, \theta_2, \theta_3, \dots, \theta_t, \dots \in \mathbb{H}$$

Homogéneo en el tiempo. Prob. de transición: $T(\theta \rightarrow \theta')$

- ~~Def.~~: $\pi_t(\theta)$ es la dd.p. de θ_t , depende de $T(\theta \rightarrow \theta')$, pero también de $\pi_0(\theta)$

$$- \pi_{t+1}(\theta) = (\pi T)(\theta) = \int_{\mathbb{H}} T(\theta' \rightarrow \theta) \pi_t(\theta') d\theta'$$

MARKOV CHAIN: SIMULACIÓN

- Sample θ_0 from $\pi_0(\theta)$

- For $t=0, 1, 2, \dots$

Sample θ_{t+1} from ~~$\pi(\theta_{t+1} | \theta_t)$~~ $P(\theta_{t+1} | \theta_t) : T(\theta_t \rightarrow \theta)$

- Nos interesan los cadenas q. convergen a una distribución estacionaria ~~transitoria~~ única

$$\lim_{t \rightarrow \infty} \pi_t(\theta) = \pi(\theta)$$

independientemente de la distribución $\pi_0(\theta)$

- Objetivo: Diseñar T para q. $\pi(\theta)$ sea la ~~deseada~~ deseada.

MARKOV CHAIN: DISTRIB. ESTACIONARIA

- $\pi(\theta)$ es una distrib. estacionaria \Leftrightarrow para un operador T , si y solo si:

$$\pi(\theta) = (\pi T)\theta$$

- Existen condiciones para el estudio de cuando una cadena converge a una distrib. estacionaria inicial.
- Condición suficiente:

$$\underbrace{T(\theta \rightarrow \theta')\pi(\theta)}_{\text{Prob. q. manda a } \theta'} = \underbrace{T(\theta' \rightarrow \theta)\pi(\theta')}_{\text{Prob. que sale de } \theta'} \quad \forall \theta, \theta'$$

- Decimos q. se satisface "the detailed balance condition" o que el operador T es reversible.

MC HC estimación

- Sea $\pi(x)$ la distrib. estacionaria de la MC, podemos estimar:

$$\mathbb{E}[f(\theta)] = \int f(\theta) \pi(\theta) d\theta \approx \frac{1}{n} \sum_{i=1}^n f(\theta_i)$$

- Nótese q. no hemos exigido i.i.d., aún así, se satisfacen resultados asintóticos similares a los del est. de Montecarlo.

$$\frac{1}{n} \sum_{i=1}^n f(\theta_i) - \mathbb{E}\{f(\theta)\} \sim N(0, (\sigma/n)^2)$$

$$\text{con } \sigma^2 = \text{Var}[f(\theta)] + 2 \underbrace{\sum_{t=1}^{\infty} \text{Cov}[f(\theta_t), f(\theta_0)]}_{\text{Permit. pq. las muestras no son i.i.d.}} \quad \begin{matrix} \text{(Tiempo converge a } 0 \text{ x } \infty) \\ \text{y } \theta_0 \sim \pi(\theta) \end{matrix}$$

(en la práctica es algo peor, pq. la expresión asume inicialización perfecta $\theta_0 \sim \pi(\theta)$)

- En cualquier caso, decrece con $1/n$ el error.

$\text{MC}_\text{MC} = \text{Transient bias}$

- Previous results hold for the stationary phase of the Markov Chain.
- There is a transient bias due to initializing the Markov chain out of stationarity.

(If it were possible to initialize in the stationary case, then we could draw i.i.d. samples).

- Transient bias decreases at a rate at least $\Theta(1/n)$, and hence it is dominated by the MC standard error.




Fig. 2.1.

$\text{MC}_\text{MC} = \text{Transient bias (2)}$

- It would be possible to remove transient bias. For instance, for very large n : $\hat{\mathbb{E}}\{f(\theta)\} = f(X_n)$
... but error would be fixed.

- More clever choices: $\hat{\mathbb{E}}\{f(\theta)\} = \frac{1}{\lceil n/2 \rceil} \sum_{i=\lceil n/2 \rceil}^n f(X_i)$




Fig. 2.1.




Fig. 2.2.

METROPOLIS HASTINGS.

ALG. 1.

- $p(\theta, x)$ can be evaluated up to proportionality
- $q(\theta'|\theta) \sim N(\theta, \sigma)$, σ ej: tiene influencia en el comportamiento del algoritmo.
- If q symmetric simplifies to the Hastings algorithm.

K-H- proof.

$$\begin{aligned}
 T(\theta' \rightarrow \theta) p(\theta'|x) &= \\
 &= p(\theta|x) \cdot q(\theta|\theta') \cdot \min \left[1, \frac{p(\theta|x) q(\theta'|\theta)}{p(\theta'|x) q(\theta|\theta')} \right] \\
 &= \min \left[p(\theta'|x) \cdot q(\theta|\theta'), p(\theta|x) q(\theta'|\theta) \right] \\
 &= \min \left[1, \frac{p(\theta'|x) q(\theta|\theta')}{p(\theta|x) \cdot q(\theta|\theta)} \right] \cdot p(\theta|x) \cdot q(\theta'|\theta) \\
 &= T(\theta \rightarrow \theta') \cdot p(\theta|x) \quad \text{c.q.d.}
 \end{aligned}$$

GIBBS SAMPLING.

$$p(\theta|x) = p(\theta^{(1)}, \theta^{(2)}, \dots, \theta^{(d)}|x)$$

Alg.: Initialize θ_0

For $t = 0, \dots, n$:

For $j = 0, \dots, d$:

Sample $\theta_{t+1}^{(j)}$ from $p(\theta^{(j)} | \theta_t^{(0)}, \dots, \theta_t^{(j-1)}, \theta_t^{(j+1)}, \dots, \theta_t^{(n)}, x)$ a conjunta.

STOCHASTIC GRADIENT ASCENT.

- OBJ: $\phi^* = \arg \max_{\phi} f(\phi)$

- $f(\phi) = \sum_{k=1}^K g(\phi, \bar{y}^{(k)})$; donde $\bar{y}^{(k)}$ es un minibatch de

- $\nabla f(\phi) = \sum_{k=1}^K p_k \frac{1}{p_k} \nabla_{\phi} g(\phi, \bar{y}^{(k)}) = \mathbb{E}_{\hat{k}} \left[\frac{1}{p_{\hat{k}}} \nabla_{\phi} g(\phi, \bar{y}^{(\hat{k})}) \right]$

Alg: Initialize $\phi^{(0)} \in \mathbb{R}^n$

For $t = 0, 1, 2, \dots$

$\hat{k}_t \leftarrow$ sample index k with probability p_k ; $k=1, \dots, K$

$$\phi^{(t+1)} = \phi^{(t)} + \frac{p^{(t)}}{p_{\hat{k}}} G^{(t)} \nabla_{\phi} g(\phi^{(t)}, \bar{y}^{(\hat{k}^{(t)})})$$

GND. TH. 2.11

- No general theory to analyze rates of convergence
for non-convex problems.

