

Problemy odwrotne w geofizyce (L5)

Wojciech Dębski

debski@igf.edu.pl

www.igf.edu.pl/~debski


Plan wykładu

- ❖ Symulowane wyrzazanie - cd.
 - ★ Podstawy fizyczne
 - ★ Opis statystyczny
 - ★ Optymalizacja a krystalizacja - analogie
 - ★ Próbkowanie ważnościowe (ang. importance sampling)
- ❖ Technika łańcuchów Markowa (ang. *Markov Chain Monte Carlo*)
 - ★ procesy stochastyczne
 - ★ algorytm Metropolisa
 - ★ algorytmy błędzenia przypadkowego
- ❖ Algorytmy typu Simulated Annealing
 - ★ klasyczny Simulated Annealing
 - ★ algorytm *Very Fast Simulated Annealing*
 - ★ Jak używać algorytmu SA - “ściąga”

Proces schładzania


schładzanie powolne

Proces schładzania - system zdąża do stanu o minimum energii wewnętrznej
- ruchy termiczne zostają “zamrożone”



Proces schładzania

szybkie schładzanie



Układ fizyczny - opis statystyczny

- ❖ Interesują nas na ogół *makroskopiczne* wielkości: temperatura, gęstość, lepkość, itp.
- ❖ Wiele różnych *mikroskopowych* stanów odpowiada tej samej wielkości makroskopowej
- ❖ Równowaga termodynamiczna: *stan makroskopowy nie zmienia się w czasie* jednakże stany mikroskopowe - *tak*

Termodynamika równowagowa

Rozkład Boltzmana (kanoniczny)

$$p(C) = \frac{1}{Z} \exp \left(-\frac{E(C)}{kT} \right)$$

E - energy of a given state

T - temperature


$$Z(T, M, \dots) = \sum_C \exp \left(-\frac{E_i}{kT} \right)$$

prawdopodobieństwo realizacji stanu makroskopowego
przez dany stan mikroskopowy C


Proces schładzania

ewolucja rozkładu Boltzmana


$T=10$



$T=1$




$T=0.1$



Proces schładzania:



krystalizacja




Symulowane schładzanie - optymalizacja

Szukamy absolutnego minimum dodatniej funkcji $S(\mathbf{m}) > 0$

$$S(\mathbf{m}) \Rightarrow e^{-\frac{S(\mathbf{m})}{T}}$$




Algorytmy typu **Simulated Annealing**




Generowane próbki


$T=10$



$T=1$




$T=0.1$



ang. *Importance Sampling*


Two-step Metropolis (0.1)




Procesy dynamiczne

(z krótką pamięcią)

deterministyczne



stochastyczne



$$X(t + dt) = X(t) + f(X(t), t)dt \quad P(x, t) = \sum_{x'} P(x', t') K(t, x; t', x')$$

Łańcuchy Markowa


- ❖ dyskretny czas: $t_1, t_2, \dots$
- ❖ proces stochastyczny z “krótką” pamięcią $K(t_i, x; t_{i-1}, x_{i-1})$
- ❖ proces ergodyczny:
 - ★ stacjonarny $K(t, x; t', x') = K(x, x')$
 - ★ nieredukowalny: (graf nieredukowalny)
 - ★ aperiodyczny
- ❖ Istnieje rozkład stacjonarny: $\pi(x') = \pi(x)$

$$\pi(x) = \int_{x'} \pi(x') K(x; x') dx'$$

Stacjonarny łańcuch Markowa

$$p(x_i) = \sum_k p(x_k) K(x_i; x_k)$$

$$p(x) = \int_{x'}^k \pi(x') K(x; x') dx'$$




Realizacja łańcucha Markowa


Błądzenie przypadkowe (ang. random walk)

$$x_i \Longrightarrow x_{i+1} = x : p_{x_i \rightarrow x_{i+1}} = K(x_{i+1} | x_i)$$


ergodyczny




periodyczny



redukowalny



Algorytm przykład



Algorytm przykład


$$\mathbf{p}_i = (p_x, p_y, p_z)$$

Równanie ewolucji

$$\mathbf{p}_{i+1} = \mathbf{p}_i \cdot \begin{pmatrix} 0.1 & 0.9 & 0 \\ 0 & 0.1 & 0.9 \\ 0.6 & 0.3 & 0.1 \end{pmatrix}$$


$$\mathbf{p}_{i \rightarrow \infty} = ???$$

Algorytm przykład



Określenie procesu

1.



2.

$$K = \begin{pmatrix} K_{11} & \cdots & K_{1N} \\ K_{21} & \cdots & K_{2N} \\ \vdots & \vdots & \vdots \\ K_{M1} & \cdots & K_{MN} \end{pmatrix}$$

Algorytm Metropolisa-Hastinga


$$x_{i+1} = x_i + \delta x_i$$

$$K(x_i; x_{i+1}) = \min \left\{ 1, \frac{p(x_{i+1})}{p(x_i)} \right\}$$


Algorytm MH - ograniczenia

$$x_{i+1} = x_i + \delta x$$


too small




optimum



too large



Algorytm MH - ograniczenia



- ❖ Utwórz rozkład “Boltzmanowski” $p(\mathbf{m}, T) = \exp(-S(\mathbf{m})/T)$
- ❖ Wybierz T_0 , i model początkowy $\mathbf{m}^\alpha$ i oceń go

$$p_\alpha = p(\mathbf{m}^\alpha, T_0)$$

- ❖ Dla danej temperatury T_k wylosuj $\mathbf{m}^{\alpha+1}$ z $p(\mathbf{m}, T_k)$

★ wylosuj próbkę testową $\mathbf{m}^\beta$: $\mathbf{m}^\beta = \mathbf{m}^\alpha + \delta \mathbf{m}$

★ oceń $\mathbf{m}^\beta$: $p_\beta = p(\mathbf{m}^\beta, T_k)$

★ Utwóź $\mathbf{m}^{\alpha+1}$

zaakceptuj $\mathbf{m}^\beta$ z prawdopodobieństwem $p = \min(1, p_\beta/p_\alpha)$

$$\mathbf{m}^{\alpha+1} = \mathbf{m}^\beta$$

jeśli $\mathbf{m}^\beta$ odrzucona duplikuj stan obecny


$$\mathbf{m}^{\alpha+1} = \mathbf{m}^\alpha$$

- ❖ Zmniejsz temperaturę

$$T_{k+1} = f(T_k)$$

- ❖ Powtarzaj aż do osiągnięcia końcowej temperatury

Algorytm Metropolisa jako *Random Walk*



Algorytm SA przykład

```
while( T > Tf)      /* decrease T loop */
{
    nc =ceil( p2+p3*exp(-(double)k/(double)sa->n));
    if(nc<=1) nc=1;
    ++k;

    for(l=0;l<nc;l++) /* T=const loop */
    {

        for(j=0;j<N;j++)      /* generate new sample */
        {
            u=SArandval(0,1);      /* modified VFSA */
            x= fabs(2*u -1);
            z= T*( pow(1+1/T,x) - 1);

            if(u >=0.5)
                p=mi[j] + z * (mu[j]-mi[j]);
            else
```

```

    p= mi[j] - z * (mi[j]-ml[j]);

    mf[j]=p;
}

tt= (*fun)(mf);    /* evaluate */
    e = tt-ta;
z=exp(-e/T);
u=SArandval(0,1);

if( e<0 || z > u) /* accept */
{
    ta=tt;
    mc = mi;
    mi = mf;
    mf=mc;

if(ta < ts) /* keep the best */
{ ts=ta;
    for(i=0;i < N; i++)
        ms[i]=mi[i];
}
}

```

```

}

} /* End of T=const loop */

To=T;      /* decrease T (VFSA scheme) */
z=Tc*pow((double)(k),di);
T = Ti*exp(-z);

if(sa->pf>0) /* messages to STD_ERR */
{ if(k%sa->pf==0)
    fprintf(stderr," VFSA:  T = %.2e    dT = %.2e    iter: %-6d    nc: %

}

} /* End  of cooling (T) loop */

```