

Macromolecule Structure determination by X-ray crystallography. A primer.

Pr. Jean Cavarelli

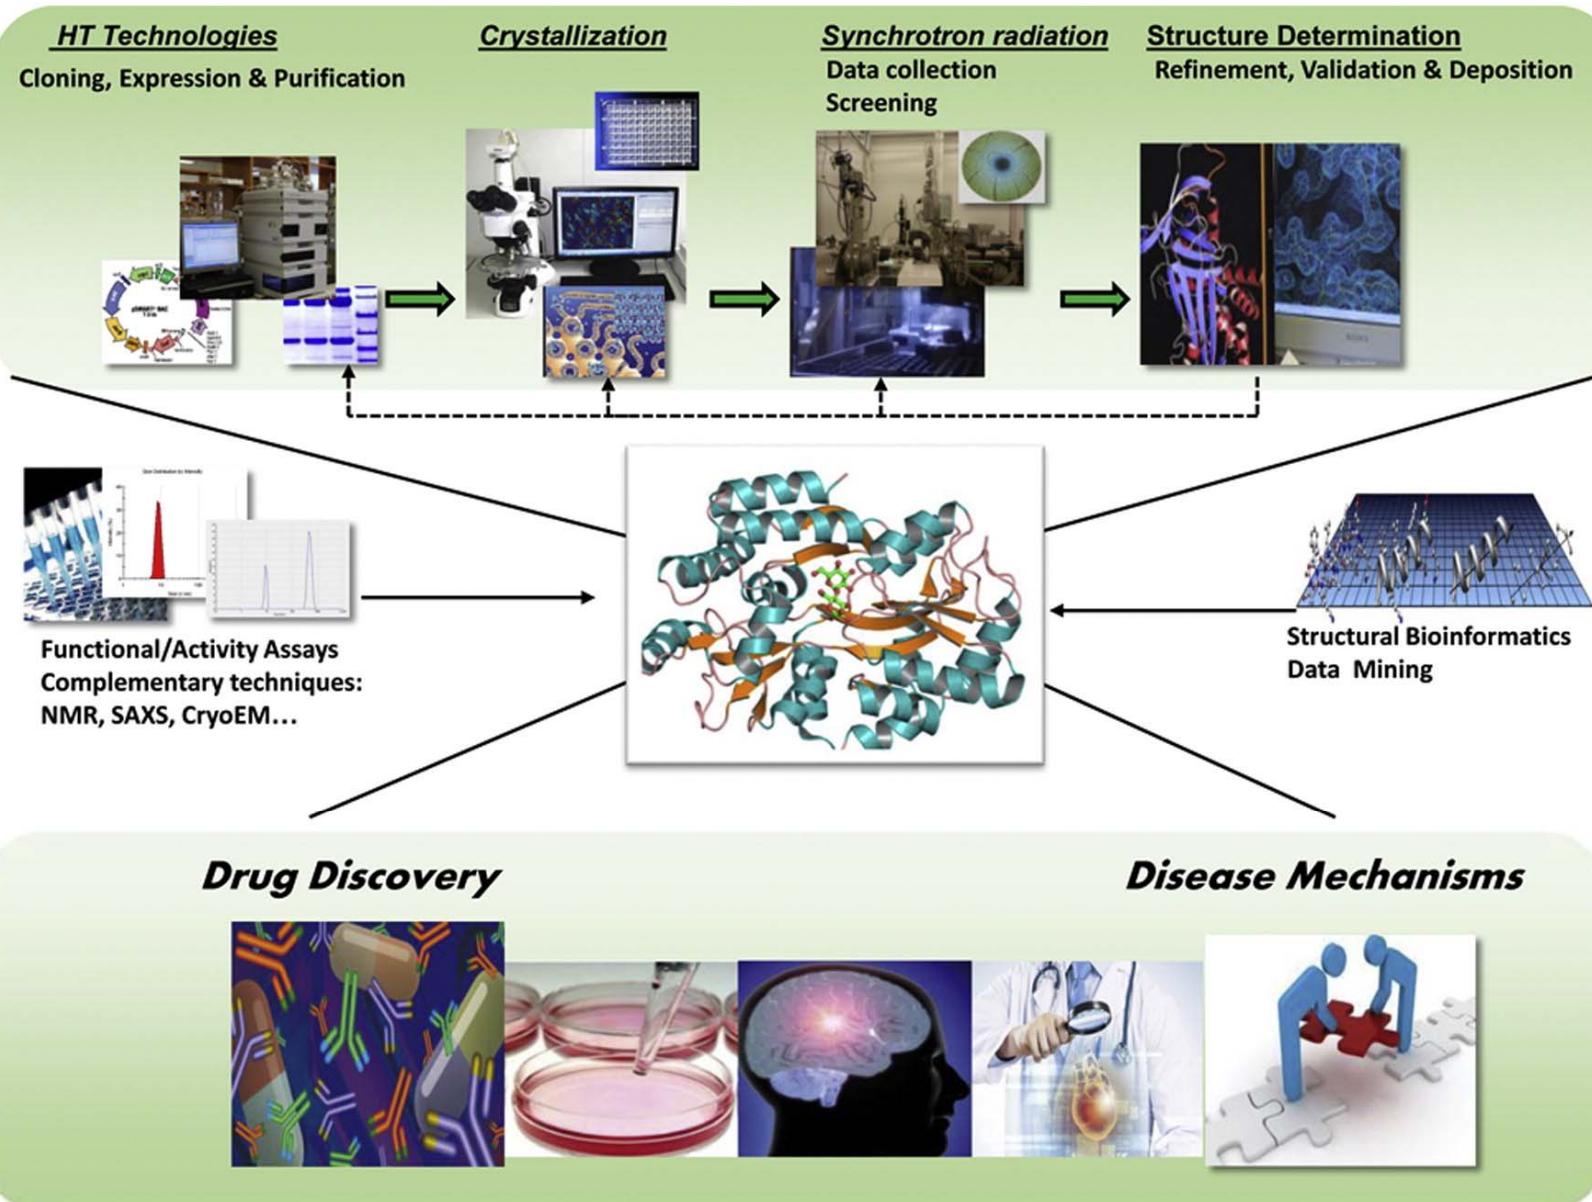
Structural biology of epigenetic targets

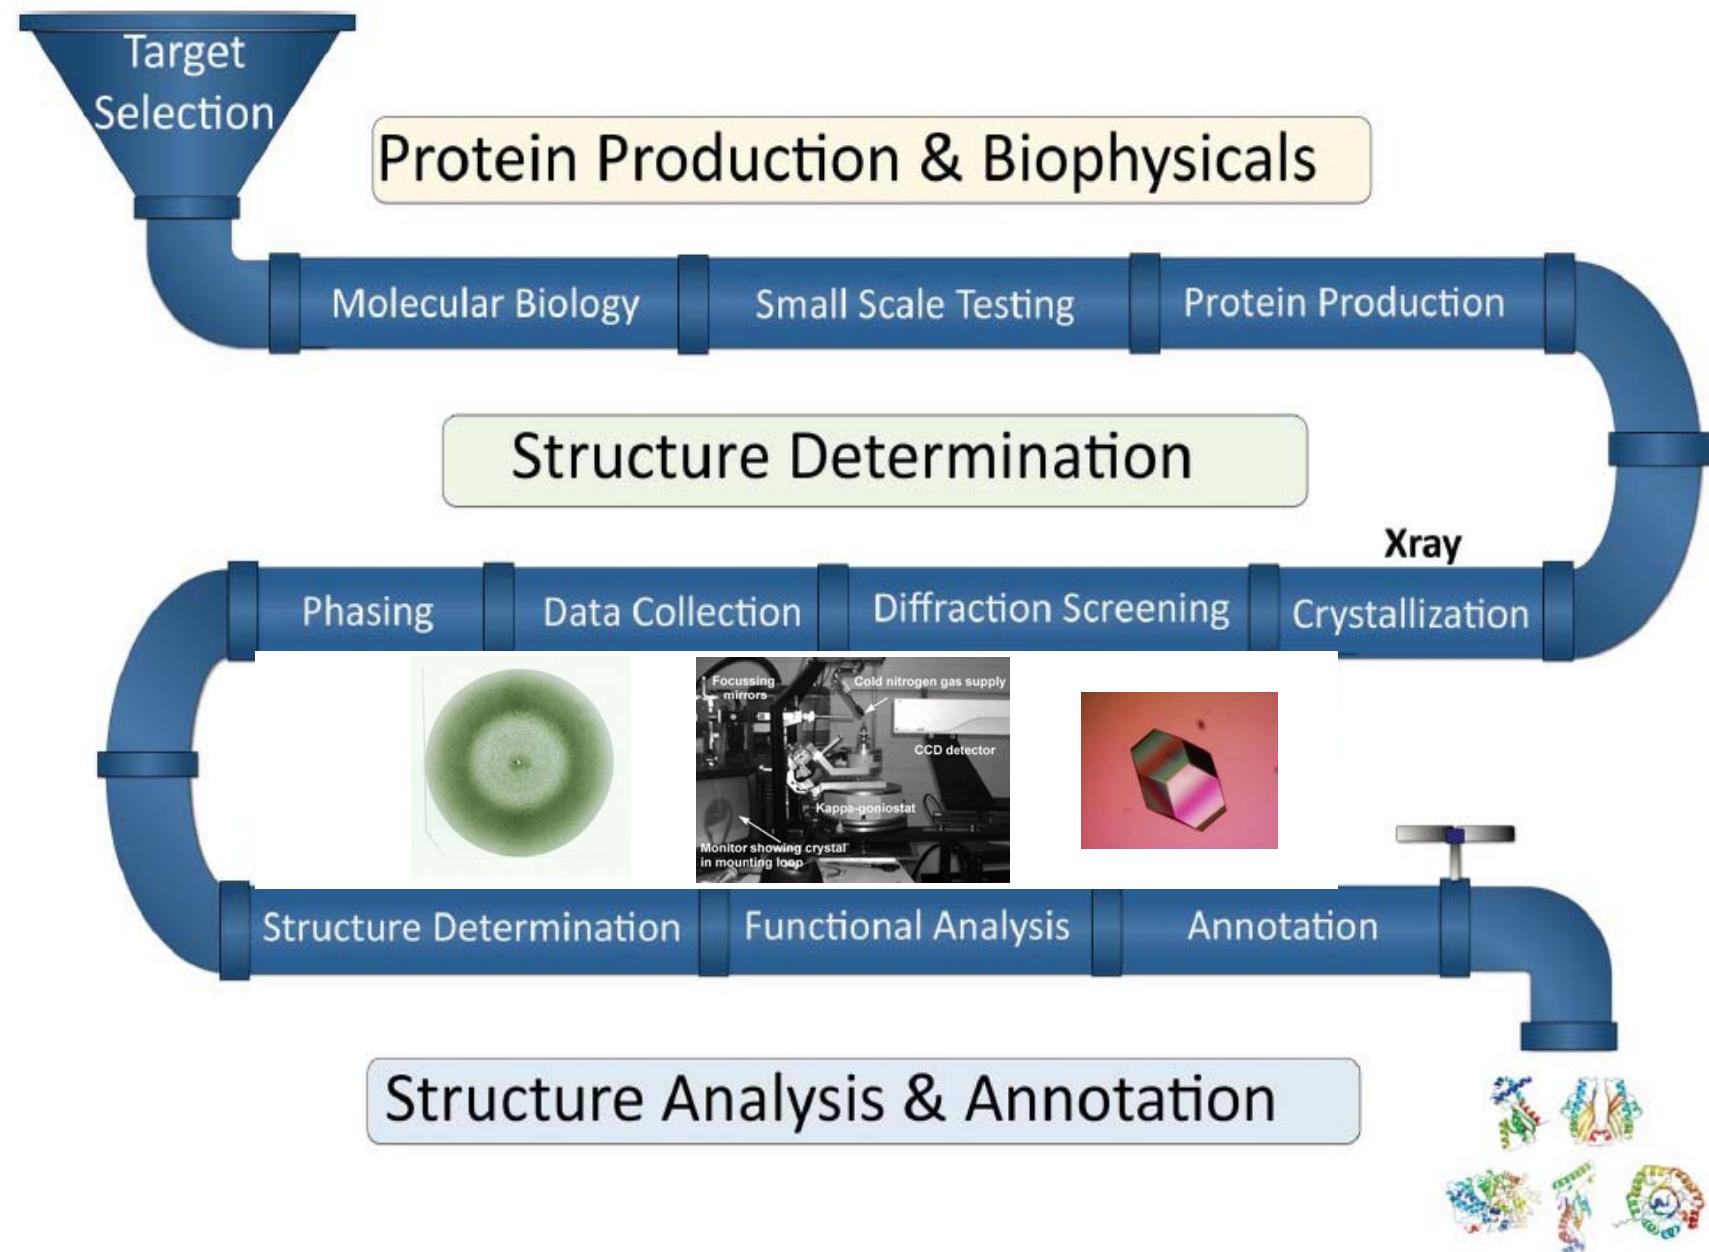


[jean.cavarelli@unistra.fr](mailto:jean.cavarelli@unistra.fr)

[jean.cavarelli@igbmc.fr](mailto:jean.cavarelli@igbmc.fr)

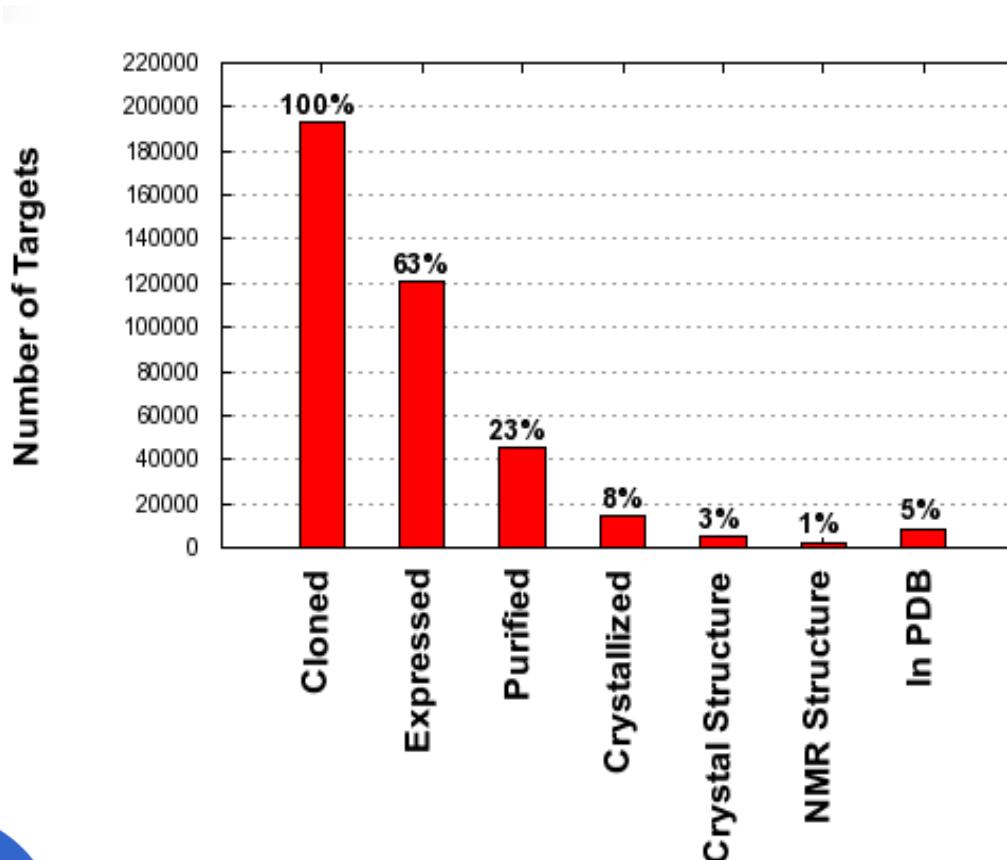
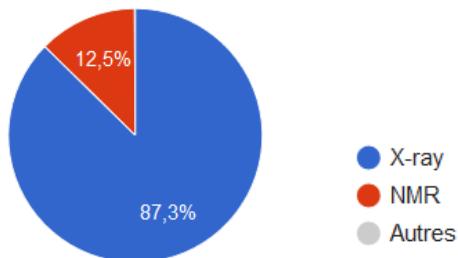






## DATA from Structural genomics centers

<http://targetdb.pdb.org/>



A screenshot of the TargetDB website interface. The top navigation bar includes links for Home, Databases, Homology Models, Methods & Technologies, E-Collection, About, and Help. The main content area features a search bar, a protein structure visualization, and several sections: Protein Resources, Latest PDB Results, Homology Models, and Methods & Technologies. Each section contains links to specific tools and databases.

## Interactions rayonnements - matière : Notions de base

### 1. Modification du rayonnement sous l'action de la matière :

Diminution de l'intensité : absorption du rayonnement

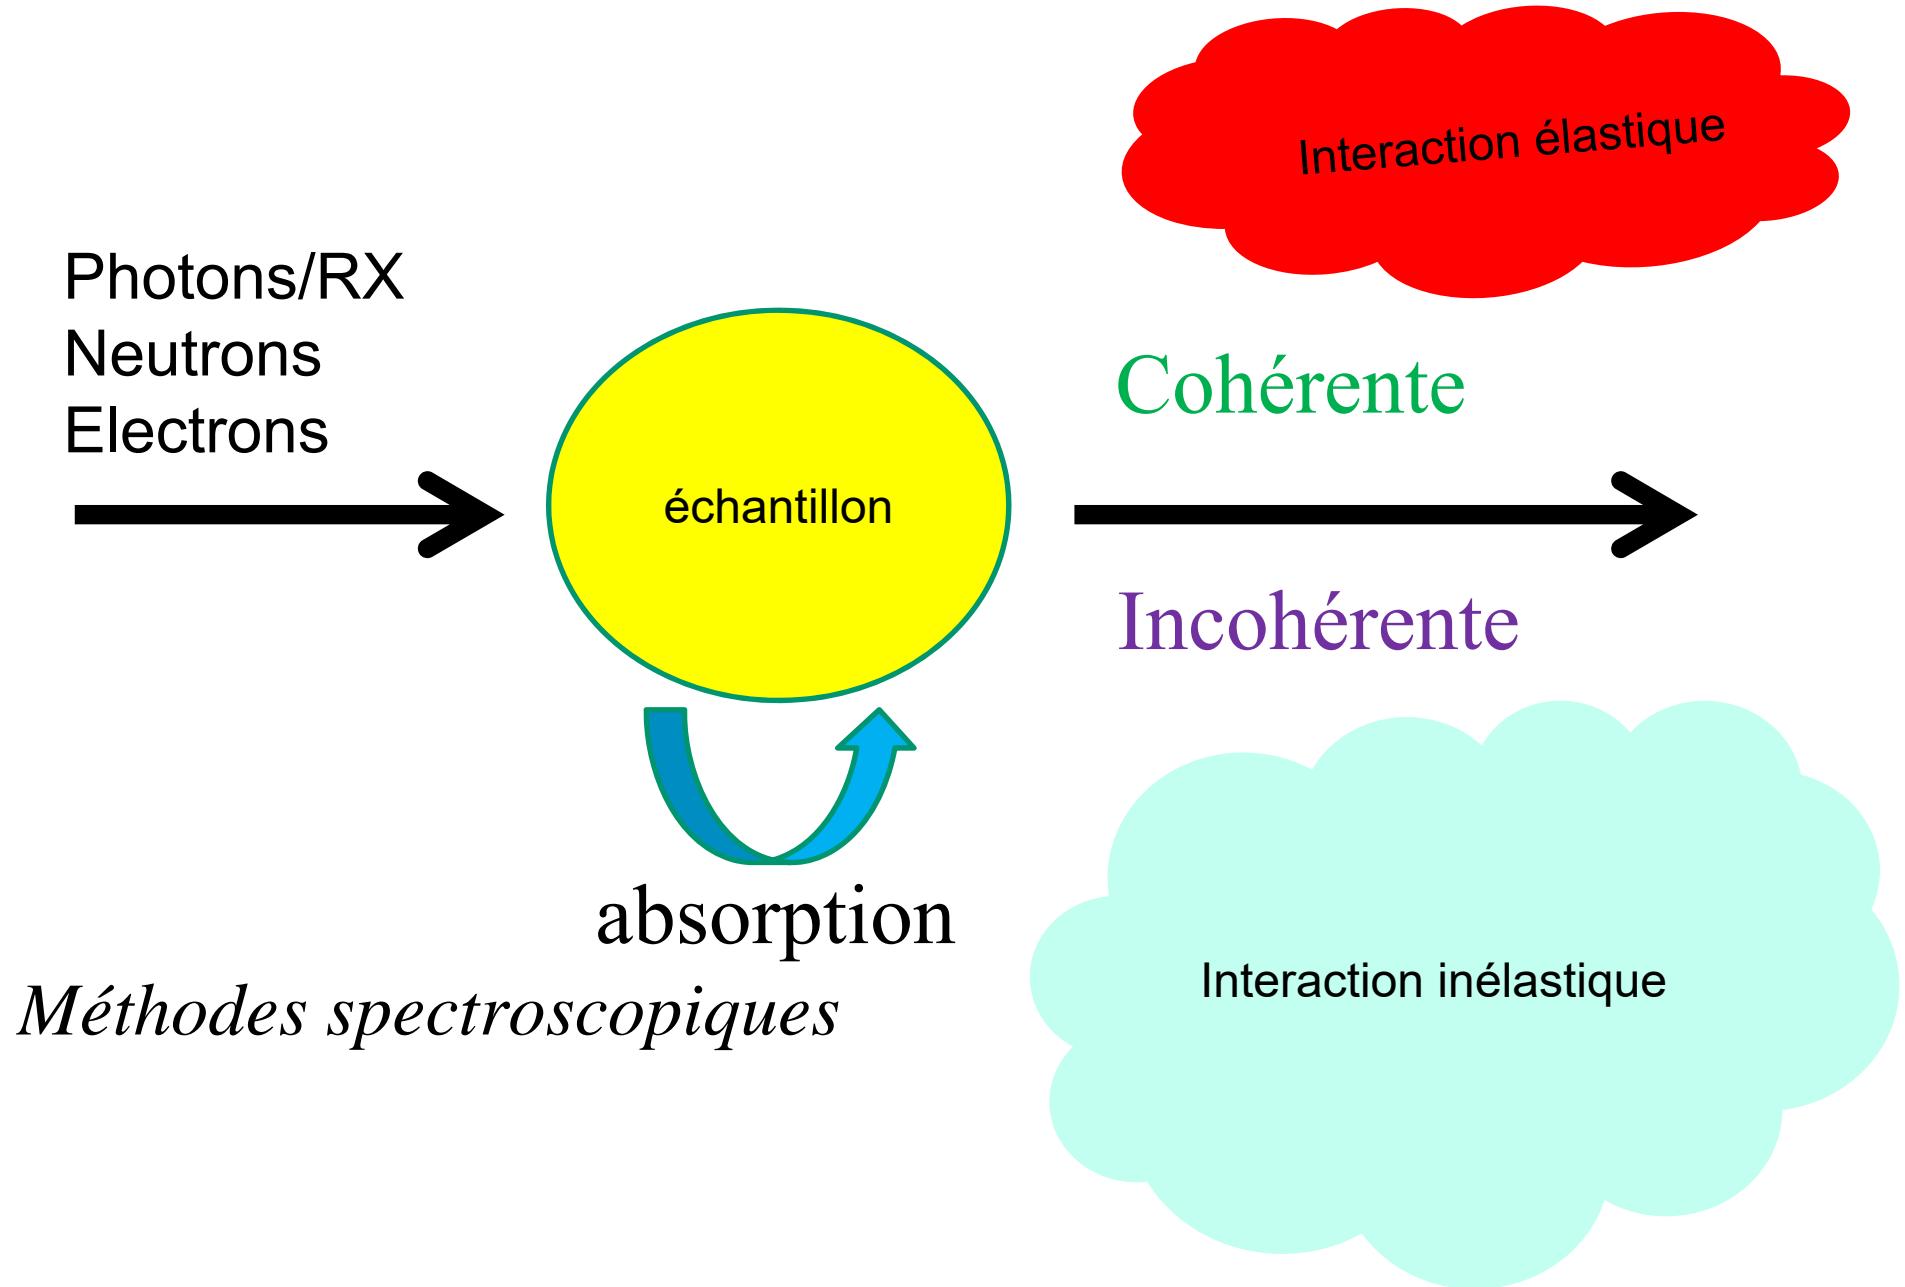
Changement du module du vecteur d'onde : une partie des photons ou des particules ont perdu de l'énergie

Changement du vecteur d'onde en direction : diffusion

### 2. Modification de la matière sous l'action du rayonnement :

L'énergie perdue par le rayonnement est intégralement transférée aux atomes de la matière sous différentes formes énergie potentielle, énergie cinétique, énergie de vibration thermique une partie de cette énergie pourra être réémise sous forme de rayonnements ou de chaleur

# Interactions rayonnements - matière



Interaction RX avec un cristal "typique" de protéine

(valeurs numériques pour  $\lambda=1\text{\AA}$ , 12.4 kev)

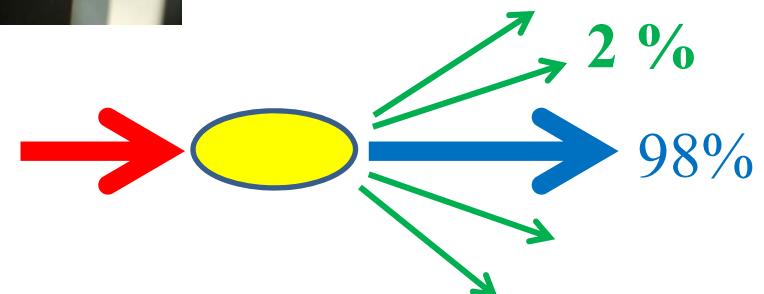
La majeure partie du rayonnement n'est pas « diffusée » (98%)

(pas de changement du vecteur d'onde en direction)



Pour la partie diffusée (2%), 3 possibilités :

Interaction par effet photoélectrique (84%)  
éjections d'électrons des atomes



Diffusion "Thompson" ("Rayleigh") (8%)

interaction cohérente et élastique, donnant lieu au phénomène d'interférences constructives observé (diffraction)



Diffusion "Compton" (8%)

Interaction inélastique et incohérente

## Diffusion élastique des Rayons X

Les Rayons X interagissent avec particules chargées :  
électrons, protons

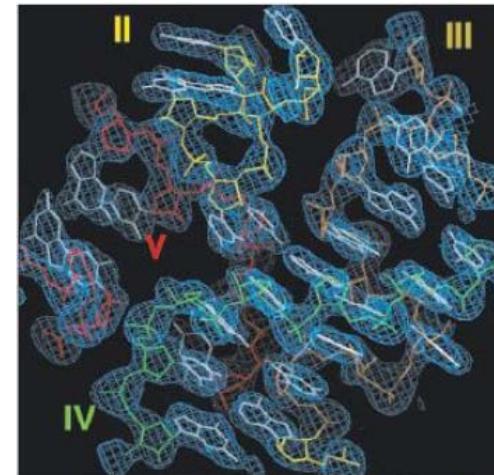
Section efficace de diffusion élastique électrons/protons

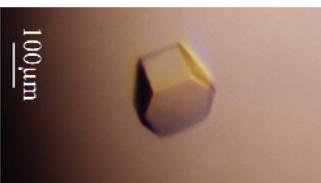
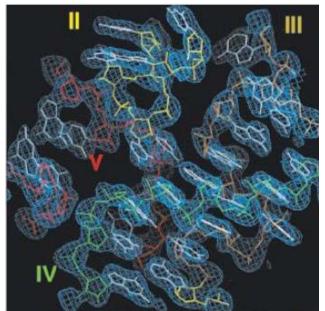
$$\frac{\sigma_e}{\sigma_p} \div \left( \frac{M_p}{M_e} \right)^2 \cong \left( \frac{1.6 \cdot 10^{-27}}{9,1 \cdot 10^{-31}} \right)^2 \cong 3,4 \cdot 10^6$$

La participation des protons est négligeable pour la diffusion élastique des RX

Pour les RX, la matière est vue comme une répartition d'électrons

La diffusion élastique des rayons X apporte des informations sur la densité électronique de l'échantillon.





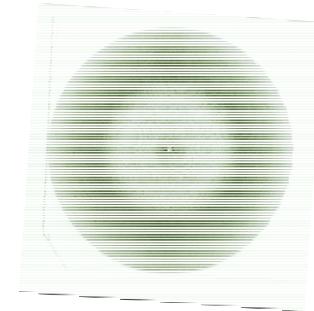
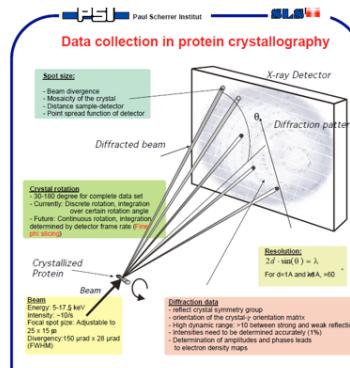
Espace direct

## Une structure cristalline

- Un groupe d'espace, une maille cristalline
- $N$  atomes dans une maille
- Pour chaque atome  $j$  ( $j = 1, N$ ), les "paramètres" :
  - l'interaction avec le rayonnement
    - facteur de diffusion  $f_j$
  - les coordonnées de position
    - $(x_j, y_j, z_j)$ , (coordonnées relatives)
  - le désordre statique et dynamique
    - $q_j, w_j$

$$\rho(x, y, z)$$

$$\rho(x, y, z) \xrightleftharpoons[\hat{\mathcal{F}}]{\hat{\mathcal{F}}} F_{hkl}$$



Espace réciproque

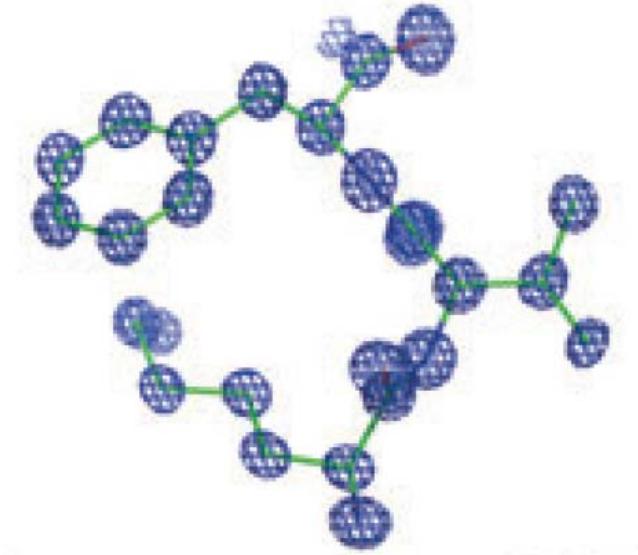
## Un ensemble de $m$ ondes "diffusées"

- Les rayons X interagissent avec les particules chargées : électrons, protons
- On utilise l'interaction élastique (cohérente) des rayons X
  - la participation des protons est négligeable (par rapport aux électrons)
  - pour les rayons X, la matière est vue comme une distribution d'électrons
- $m$  lié à la limite de diffraction du cristal ( $d_{min}$ ).
- chaque onde est caractérisée par 3 paramètres :
  - une direction de diffusion,
  - un module,
  - une phase (une différence de phase par rapport à une onde de référence).

$$m F_{hkl}, hkl \in D^*$$

$$\left\{ \begin{array}{lcl} \rho(x, y, z) & = & \hat{\mathcal{F}}[F_{hkl}] \\ F_{hkl} & = & \hat{\mathcal{F}}^{-1}[\rho(x, y, z)] \end{array} \right.$$

Le résultat de processus cristallographique



La référence et le juge de paix

La fonction densité électronique

Fonction densité électronique théorique

$$\rho(x, y, z) = \frac{1}{V} \sum_{h=-\infty}^{h=+\infty} \sum_{k=-\infty}^{k=+\infty} \sum_{l=-\infty}^{l=+\infty} |F_{hkl}| e^{i\phi_{hkl}} e^{-2i\pi(hx+ky+lz)}$$

- fonction réelle (**en absence de diffusion anomale**) et positive (si tous les termes sont inclus)
- fonction qui présente des maxima dans les régions occupées par les atomes
- fonction qui est donc en général interprétée en termes de positions atomiques

## Espace direct $\rightleftharpoons$ Espace réciproque

$$\rho(x, y, z) = \left(\frac{1}{V}\right) \sum_{h \in \mathbb{Z}} \sum_{k \in \mathbb{Z}} \sum_{l \in \mathbb{Z}} F_{hkl} e^{-2i\pi(hx+ky+lz)} = \left(\frac{1}{V}\right) \sum_{(h,k,l) \in \mathbb{Z}^3} |F_{hkl}| e^{i\phi_{hkl}} e^{-2i\pi(hx+ky+lz)}$$

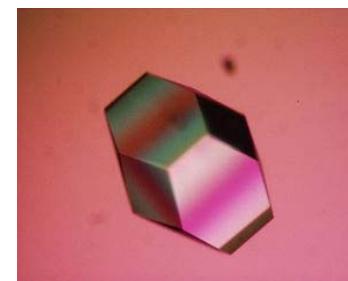
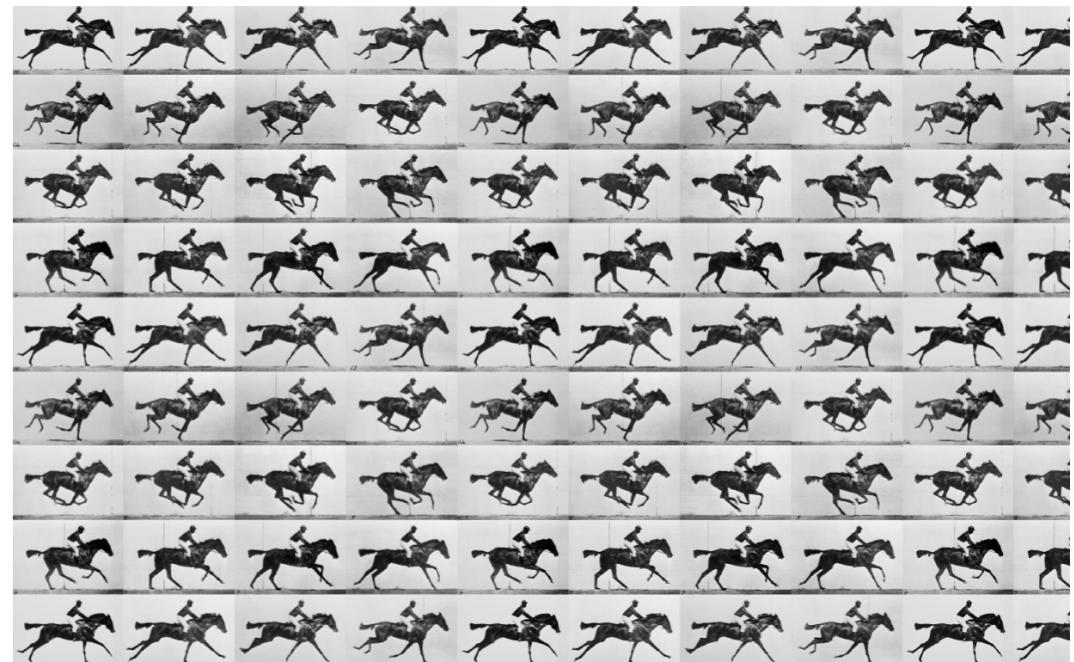
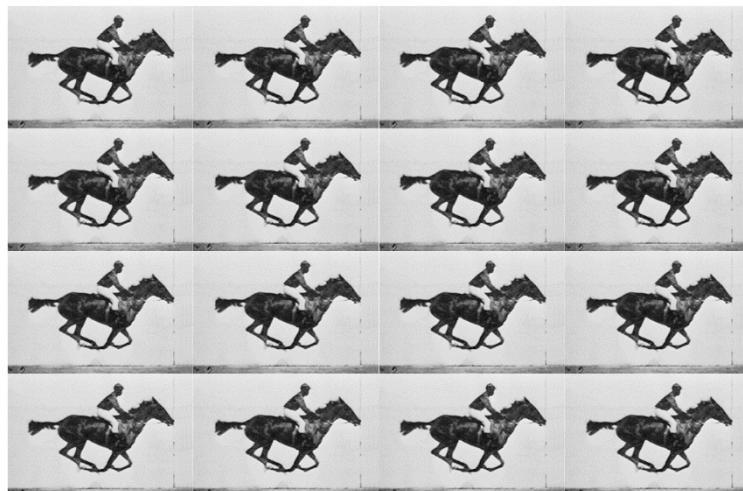
$$F_{hkl} = \sum_{j=1}^N q_j f_j^{hkl} w_j^{hkl} e^{2i\pi(hx_j+ky_j+lz_j)}$$

Structure	positions atomiques	facteur de diffusion	Facteur de Structure	module FS	Phase FS	Densité électronique
A	$\vec{r}_j$	$f_j$	$F_H$	$ F_H $	$\alpha_H$	$\rho(r)$
B	$-\vec{r}_j$	$f_j$	$\overline{F_H}$	$ F_H $	$-\alpha_H$	$\rho_B(r) = \rho(-r)$
C	$\vec{r}_j$	$-f_j$	$-F_H$	$ F_H $	$\pi + \alpha_H$	$\rho_C(r) = -\rho(r)$
D	$-\vec{r}_j$	$-f_j$	$-\overline{F_H}$	$ F_H $	$\pi - \alpha_H$	$\rho_D(r) = -\rho(-r)$

structure cristallographique = moyennes dans le temps et dans l'espace :

ensemble des structures présentes dans le cristal pendant le temps de l'expérience

le modèle construit en termes de paramètres atomiques se doit de refléter au mieux les positions et les mouvements des atomes dans le cristal



$\sim 10^{13}$  molecules

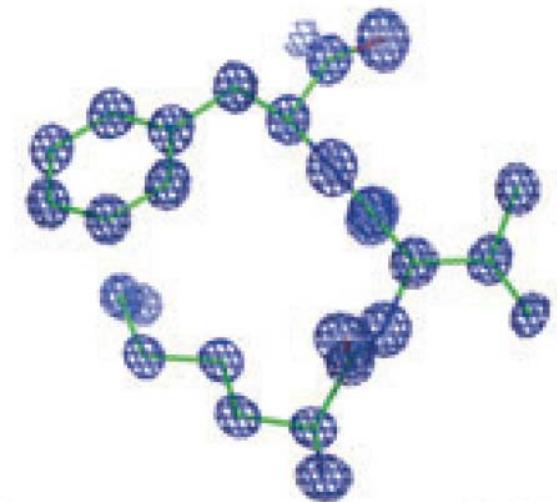
## Paramètres de déplacements atomiques

$$F_{hkl} = \sum_{j=1}^N q_j f_j^{hkl} w_j^{hkl} e^{2i\pi(hx_j + ky_j + lz_j)}$$

- Modéliser aux mieux les mouvements et le "désordre" des atomes dans la structure
- Les paramètres de déplacements atomiques

Désordre statique et dynamique

- Facteur d'occupation :  $q_i$  ( $j=1,n$ )
- Facteur de Debye Waller:  $w_i$ , ( $j=1,n$ )
  - Modèle simple isotrope, facteur d'agitation thermique
  - Modèle plus sophistiqué, anisotrope





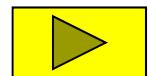
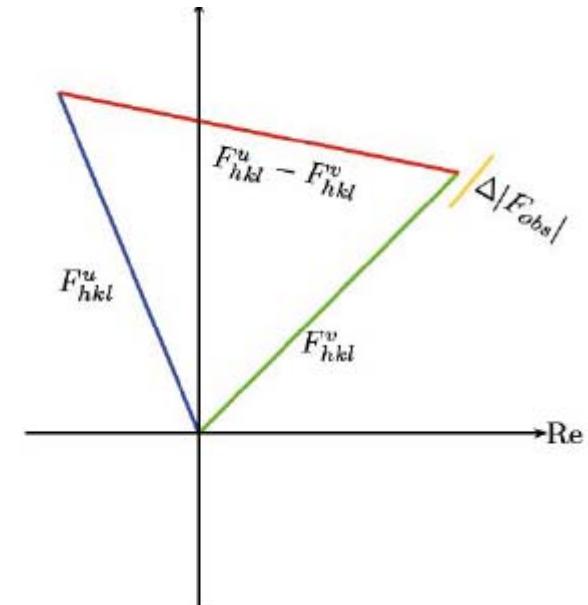


Fonction densité électronique. En théorie :

$$\rho(x, y, z) = \left(\frac{1}{V}\right) \sum_{h \in \mathbb{Z}} \sum_{k \in \mathbb{Z}} \sum_{l \in \mathbb{Z}} |F_{hkl}^{\text{vrai}}| e^{i\phi_{hkl}^{\text{vrai}}} e^{-2i\pi(hx+ky+lz)}$$

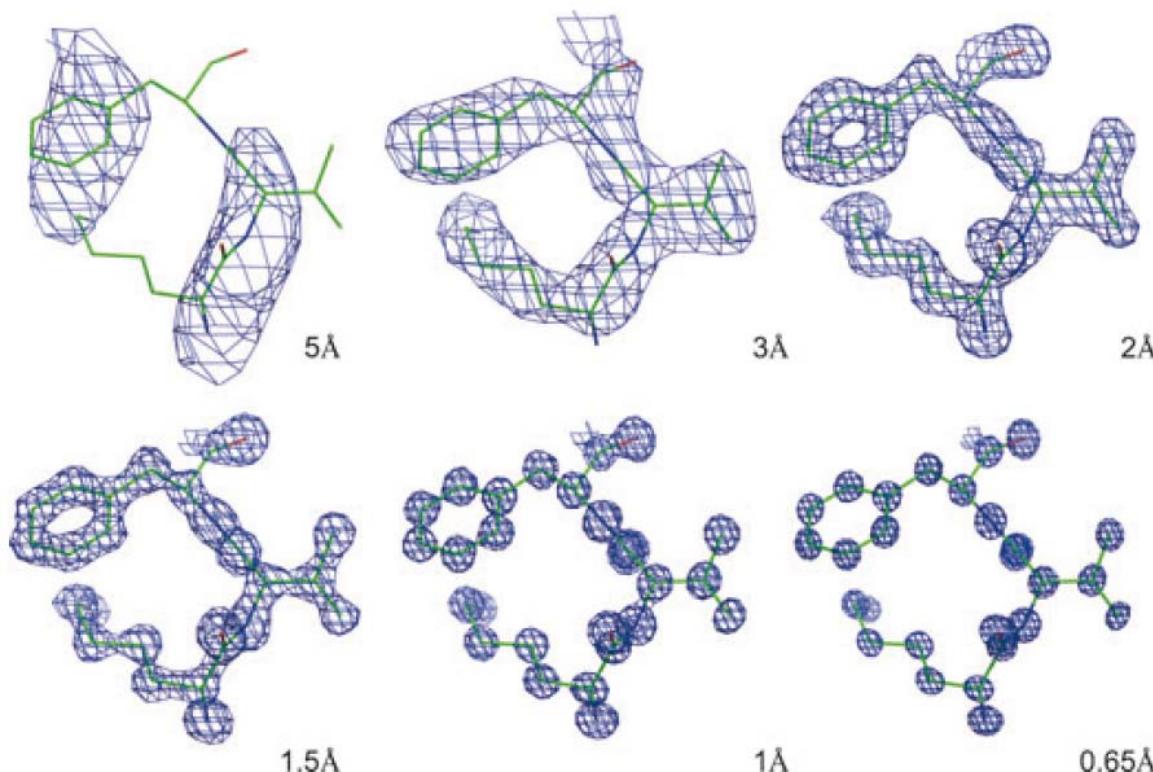
L'information de phases est essentielle  
Théoreme de Parseval

$$\langle (\Delta\rho)^2 \rangle = \left(\frac{1}{V^2}\right) \sum_{h \in \mathbb{Z}} \sum_{k \in \mathbb{Z}} \sum_{l \in \mathbb{Z}} |F_{hkl}^v - F_{hkl}^u|^2$$



Fonction densité électronique. La réalité :

$$\rho(x, y, z)^{obs} = \left(\frac{1}{V}\right) \sum_{hkl \in D^*} |F_{hkl}^{obs}| e^{i\phi_{hkl}^{calc}} e^{-2i\pi(hx+ky+lz)}$$



**Protein crystallography for non-crystallographers, or how to get the best (but not more) from published macromolecular structures**

Alexander Wlodawer<sup>1</sup>, Wladek Minor<sup>2,3</sup>, Zbigniew Dauter<sup>4</sup> and Mariusz Jaskolski<sup>5,6</sup>

FEBS Journal (2007) Journal compilation © 2007 FEBS. No claim to original US government works

Fonction densité électronique. La réalité :

$$\rho(x, y, z)^{obs} = \left(\frac{1}{V}\right) \sum_{hkl \in D^*} |F_{hkl}^{obs}| e^{i\phi_{hkl}^{calc}} e^{-2i\pi(hx+ky+lz)}$$

$\rho(x, y, z)^{obs} \neq \rho(x, y, z)^{vrai}$ . 3 sources d'erreurs principales :

- les erreurs sur la valeur des coefficients utilisés

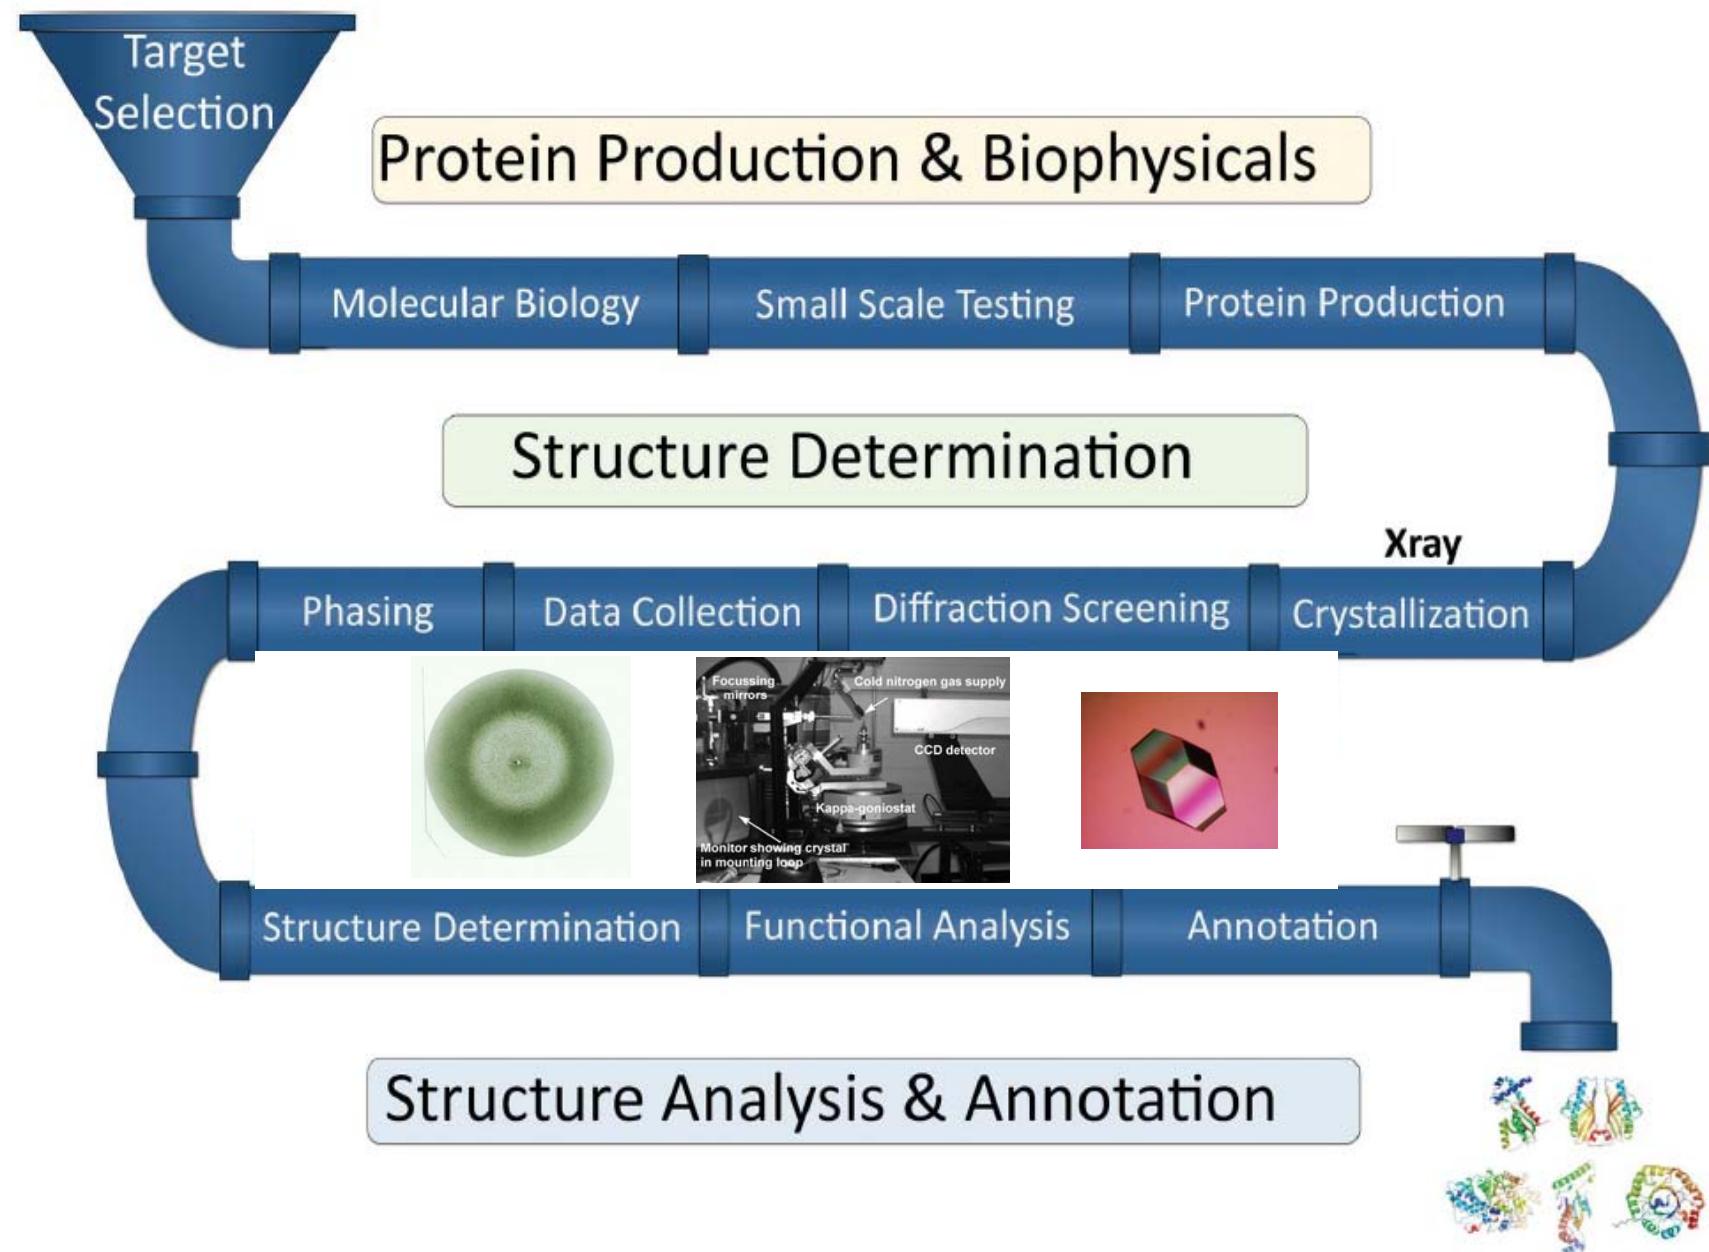
$$|F_{hkl}^{obs}| \neq |F_{hkl}^{vrai}| \quad \phi_{hkl}^{calc} \neq \phi_{hkl}^{vrai}$$

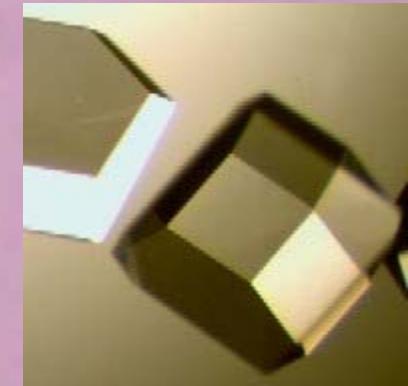
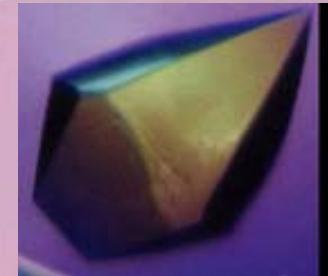
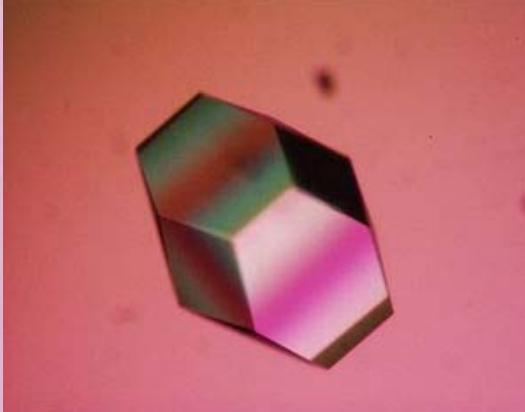
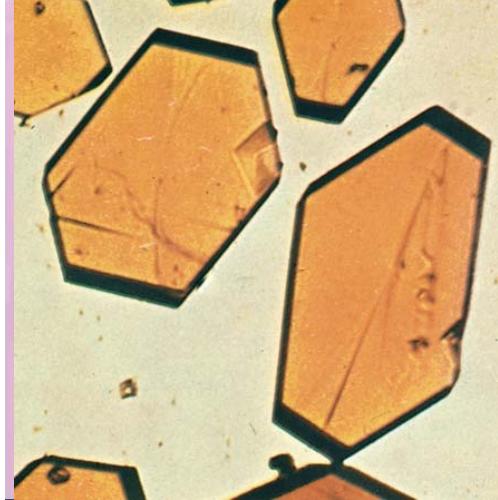
- les erreurs de troncatures

$$D^* \neq \mathbb{Z}^3$$

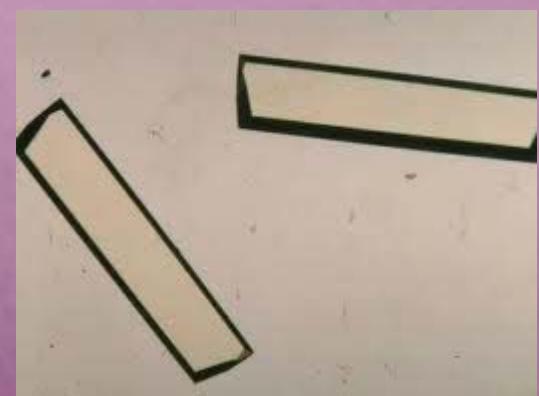
Conséquences des erreurs :

- perte d'interprétabilité de la fonction en terme de positions atomiques
- distance minimale pour que 2 "détails" soient vus séparément, en théorie  $\approx 0,7d_{min}$  pratiquement  $\approx d_{min}$
- des maxima "élargis" avec des "hauteurs" réduites
- des faux maxima, des minima négatifs
- des superpositions d'extrema (maxima, minima)

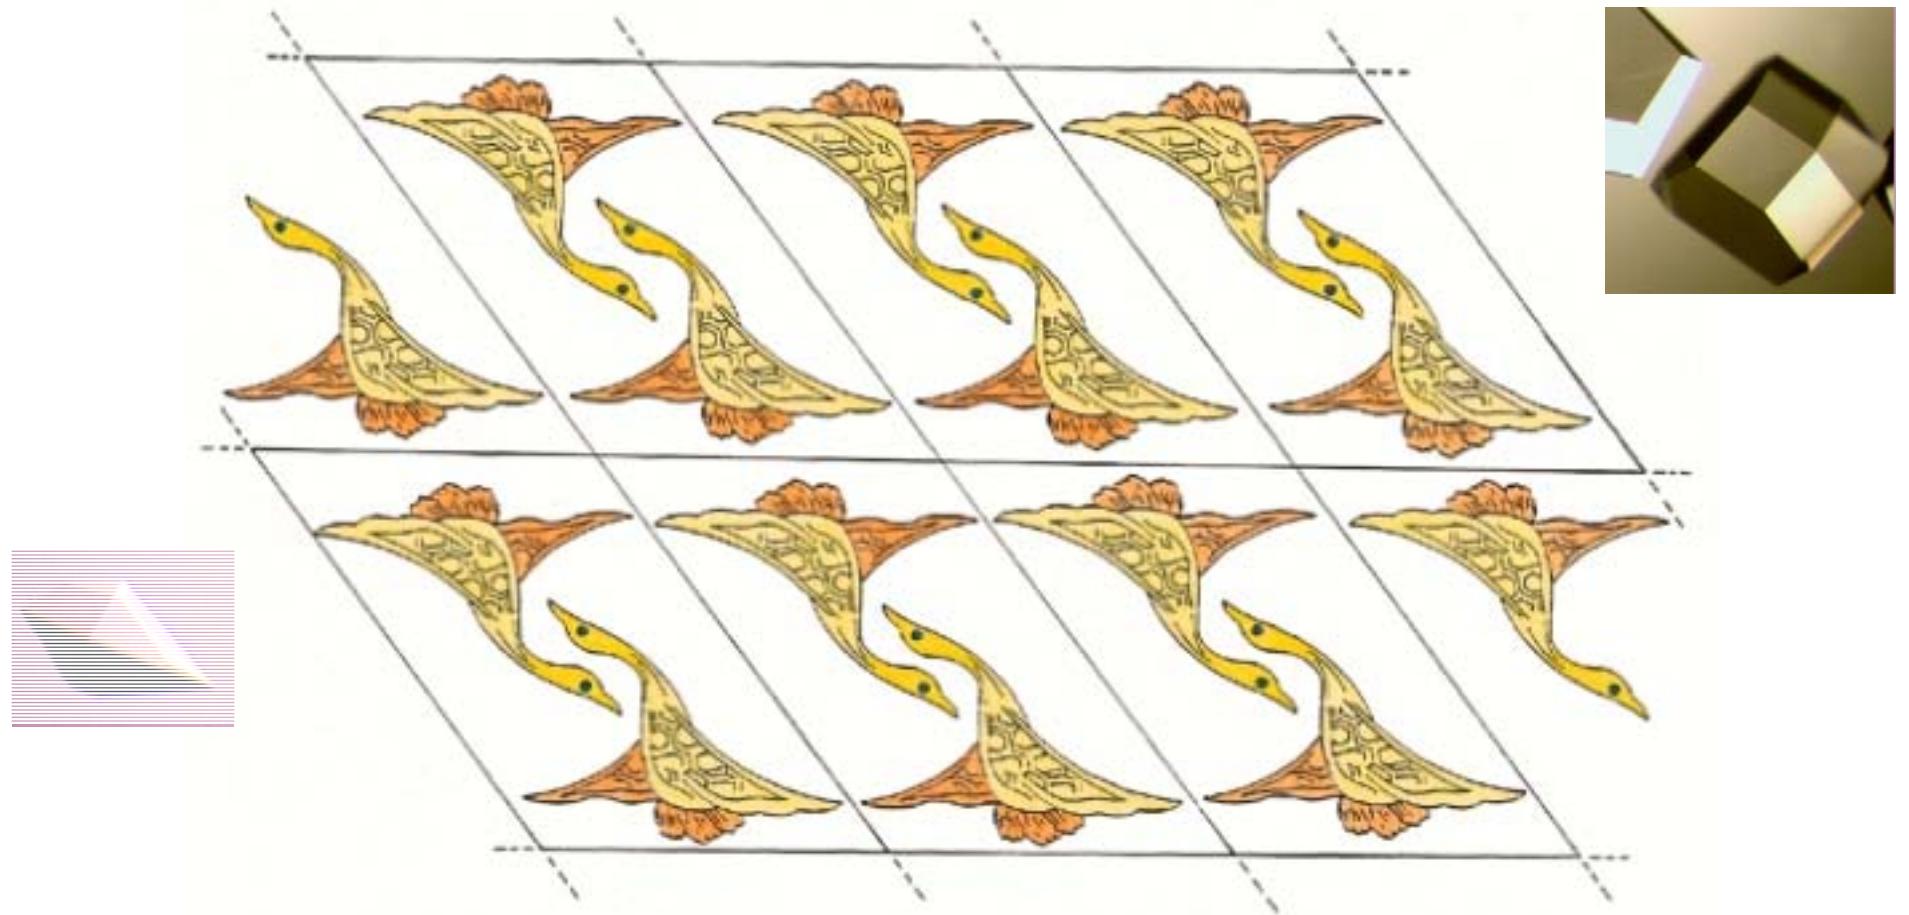




$\sim 10^{13}$  molecules



# Un cristal : Arrangement périodique ordonné



Reproduction ULP Strasbourg. Autorisation CFC-Paris

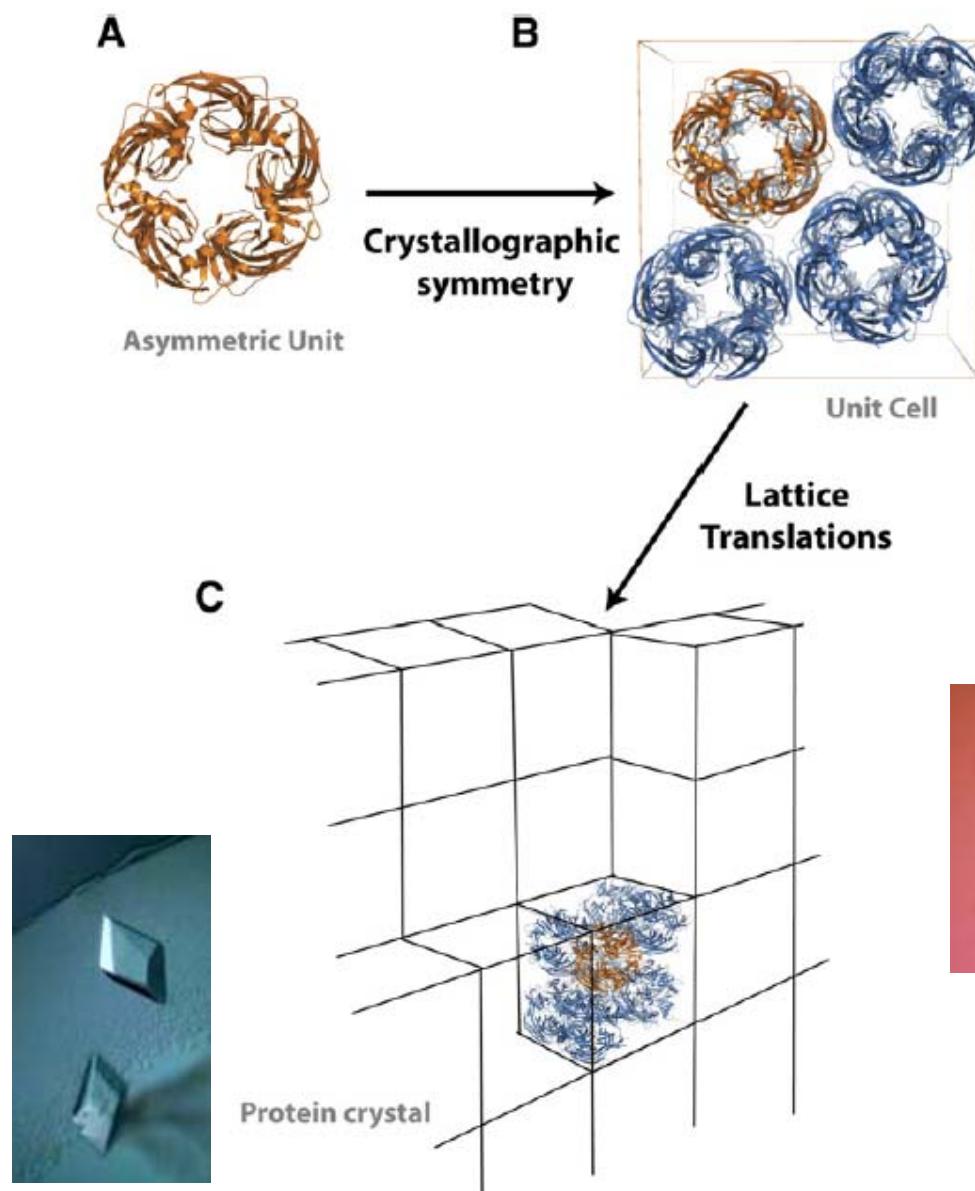
© 1999 GARLAND PUBLISHING INC.  
A member of the Taylor & Francis Group

230 Groupes d'espaces

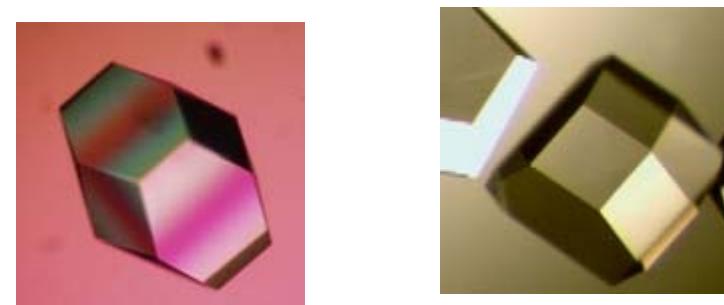
Maille cristalline caractérisée par l'un des 7 systèmes cristallins



# Un cristal : Arrangement périodique ordonné



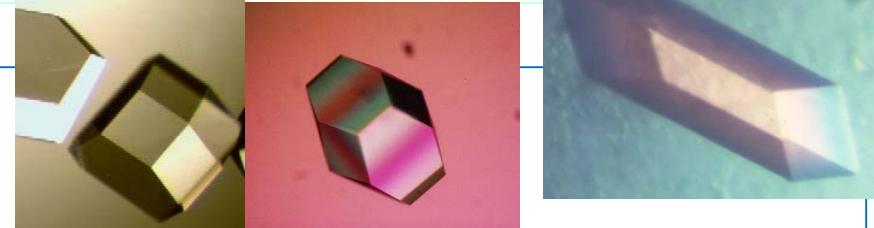
7 systèmes cristallins  
230 groupes d'espaces



Daniel L. Minor, Jr.  
Neuron 54, May 24, 2007 ©2007 Elsevier Inc.

Reproduction ULP Strasbourg. Autorisation CFC-Paris

# Symétrie des cristaux



## Symétrie macroscopique

- gouverne les formes extérieures des cristaux
- correspond à la **symétrie ponctuelle** ou **symétrie d'orientation**
- Ne rend pas compte de la structure atomique



Travaux de Haüy (1784)

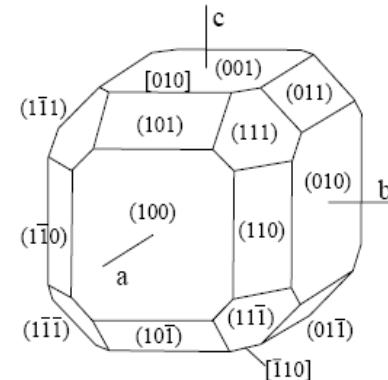
Classification en 7 systèmes : Mohs 1820

Les 32 groupes ponctuels : Hessel, 1830

Indexation des faces : Miller, 1839

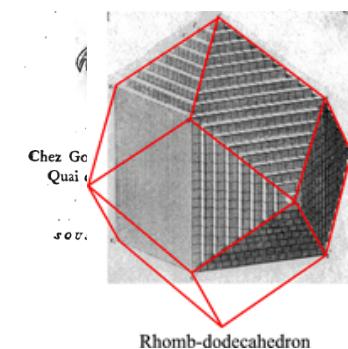
## Symétrie microscopique

- Vision atomique, **Symétrie spatiale**
- Bravais : **14 réseaux**, 1848
- **Groupes spatiaux**. 230 groupes
  - Sohncke, 1879, Schoenflies-Fedorov 1891; Maugin-Hermann, 1933

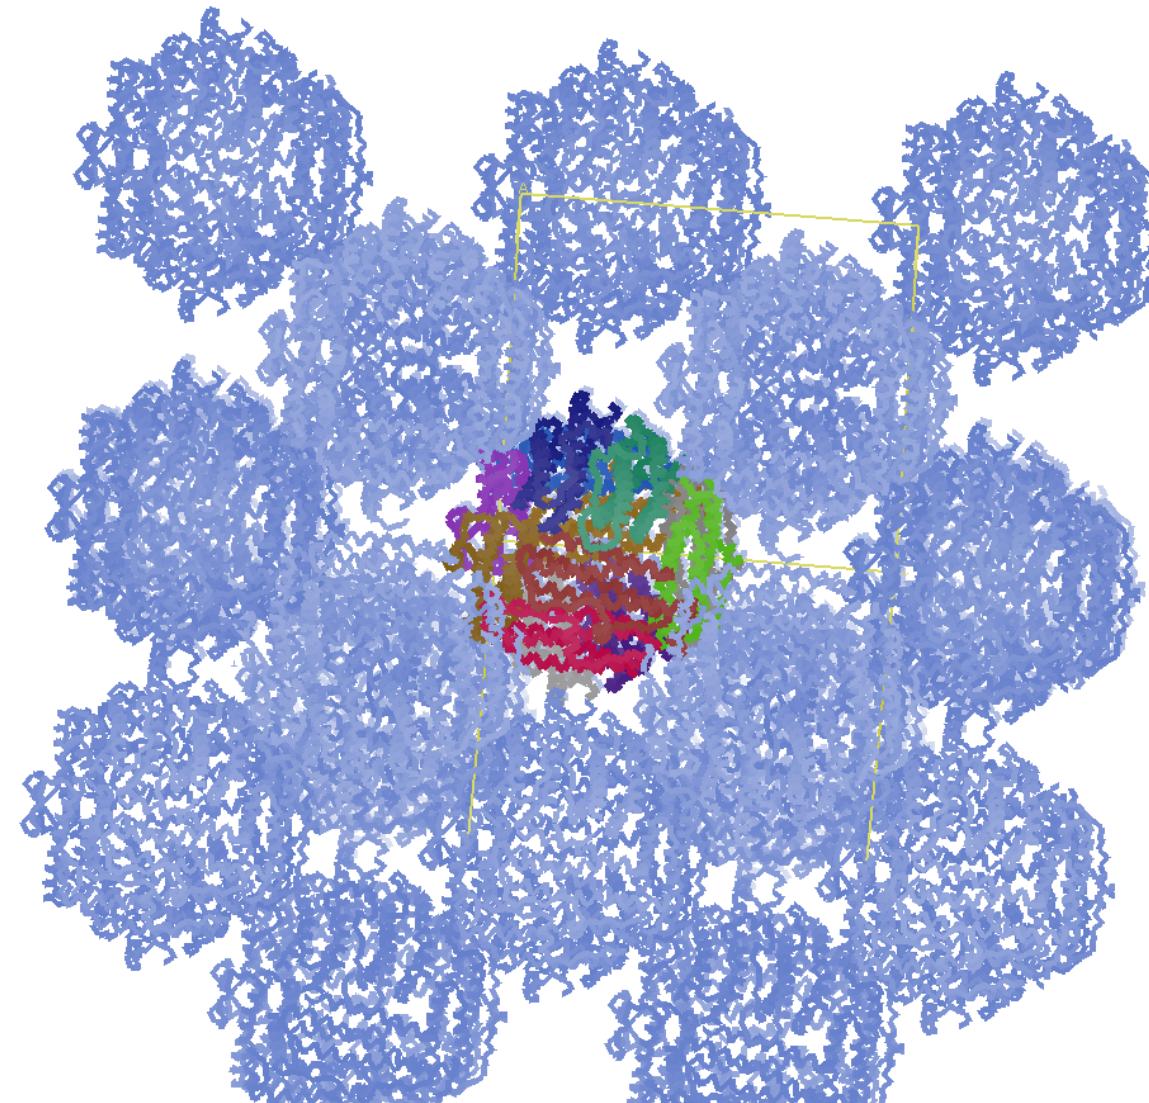
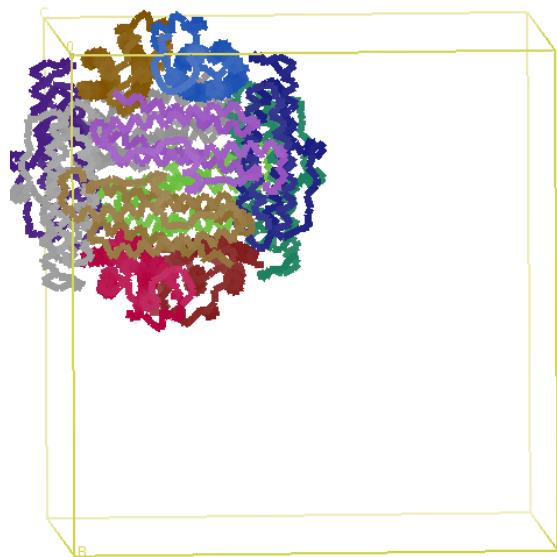


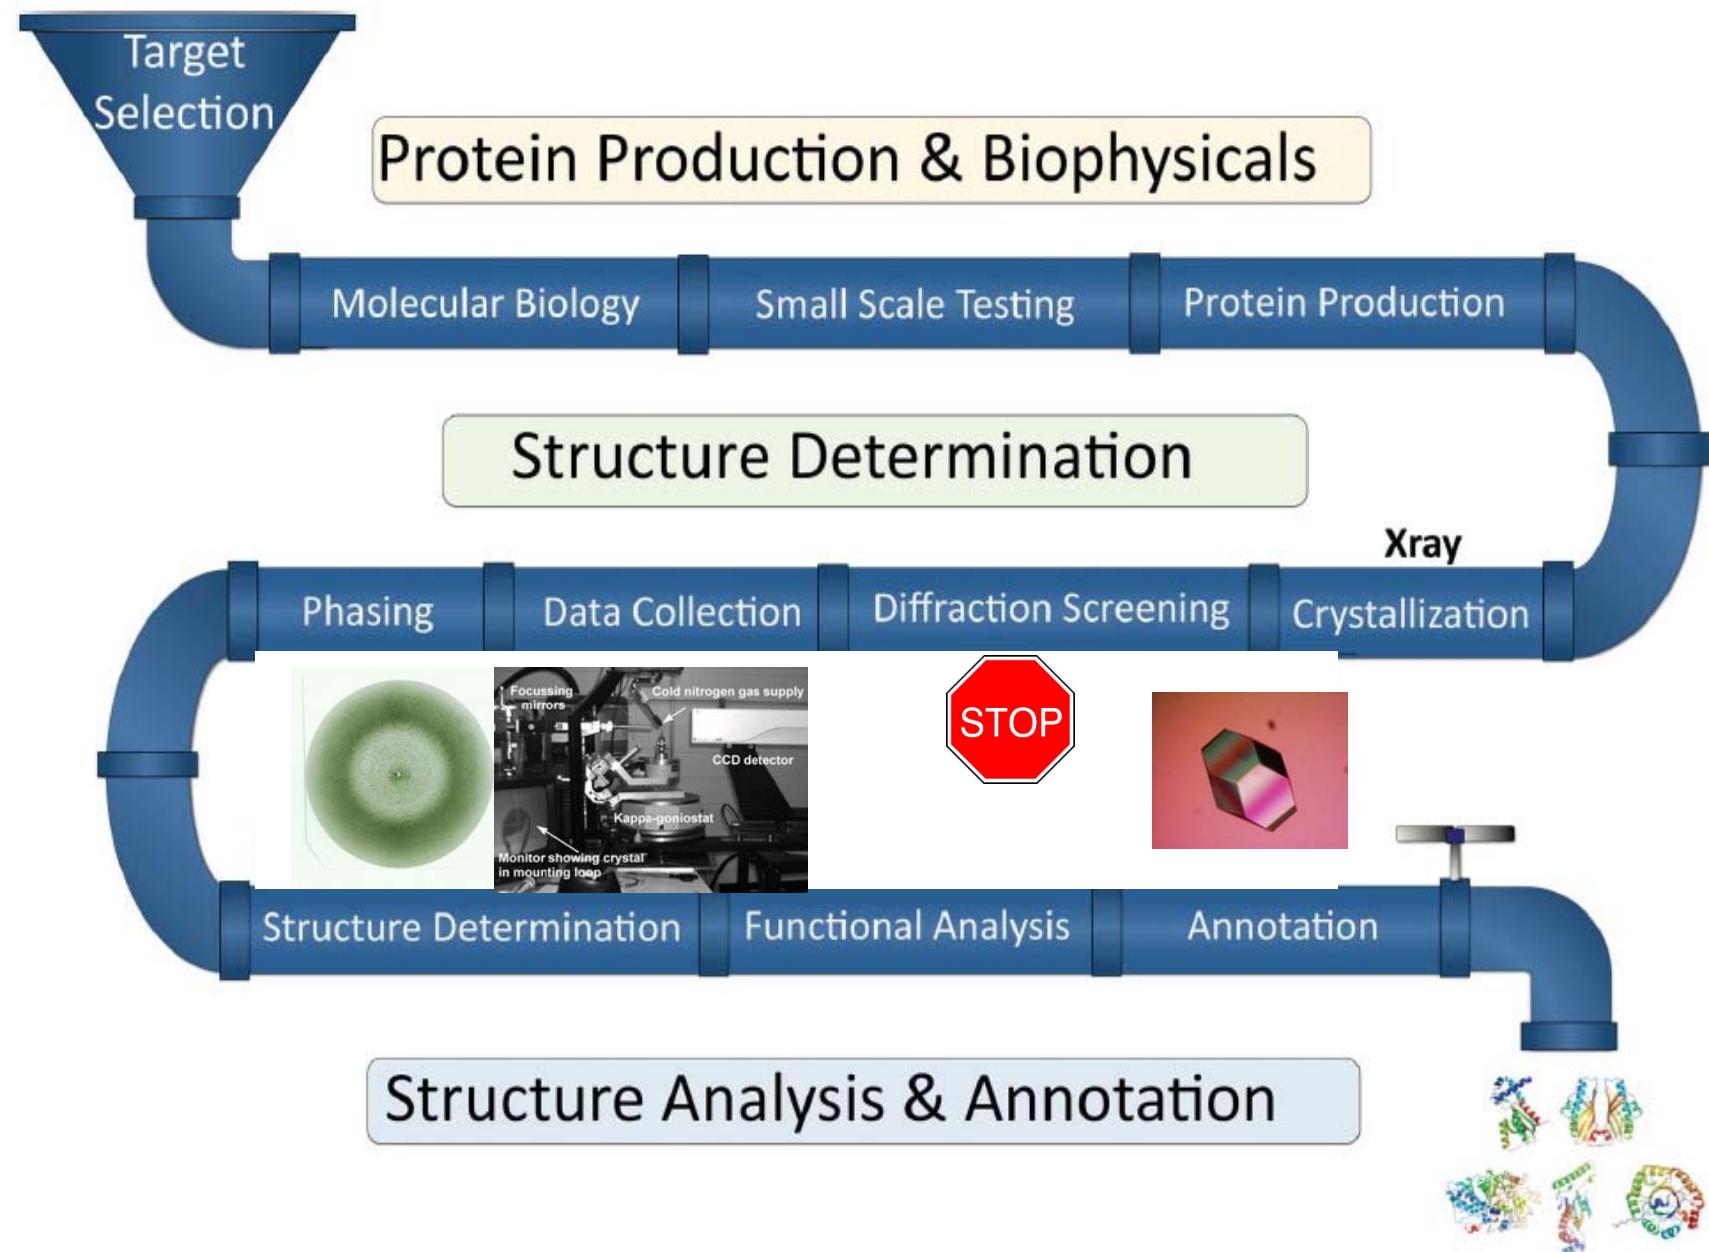
E S S A I  
D'UNE THÉORIE  
SUR LA STRUCTURE  
DES CRYSTEAUX,  
APPLIQUÉE  
À PLUSIEURS GENRES DE SUBSTANCES  
CRYSTALLISÉES;

Par M. l'Abbé HAÜY, de l'Académie Royale des  
Sciences, Professeur d'Humanités dans l'Université de  
Paris.



Système	Symétrie	Groupes ponctuels	Contraintes imposées	Réseaux de Bravais
Triclinique	Identité ou inversion	$1, \bar{1}$	$a \ b \ c$ $\alpha \ \beta \ \gamma$	P
Monoclinique	1 sym d'ordre 2	$2, m, 2/m$	$a \ b \ c$ $\alpha = \gamma = 90^\circ$ $\beta$	P, C
Orthorhombique	3 syms d'ordre 2 $\perp$	$222, mm2, mmm$	$a \ b \ c$ $\alpha = \beta = \gamma = 90^\circ$	P, C, I, F
Quadratique	axe d'ordre 4	$4, \bar{4}, 4/m$ $422, 4mm, \bar{4}2m$ $4/mmm$	$a = b = c$ $\alpha = \beta = \gamma = 90^\circ$	P, I
Hexagonal	axe d'ordre 6	$6, \bar{6}, 6/m$ $622, 6mm, \bar{6}2m$ $6/mmm$	$a = b = c$ $\alpha = \beta = 90^\circ \quad \gamma = 120^\circ$	P
Trigonal / Rhomboédrique	axe d'ordre 3	$3, \bar{3}$ $32, 3m, \bar{3}m$	$a = b = c$ $\alpha = \beta = 90^\circ \quad \gamma = 120^\circ$ axe 3 $\parallel \vec{c}$  $a = b = c$ $\alpha = \beta = \gamma$ axe 3 $\parallel \vec{a} + \vec{b} + \vec{c}$	P  R
Cubique	4 axes d'ordre 3	$23, m\bar{3}$ $432, \bar{4}3m, m\bar{3}m$	$a = b = c$ $\alpha = \beta = \gamma = 90^\circ$	P, I, F



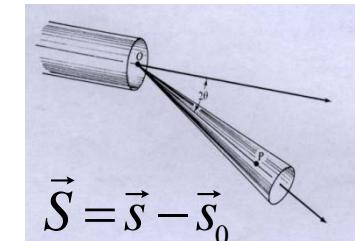


## Diffusion élastique cohérente des RX par un atome

chaque atome est caractérisé par une certaine densité électronique  $\rho(r)$

En prenant comme unité l'amplitude diffusé par un électron en O,

$$F(\vec{S}) = \oint_V \rho(r) \exp(2i\pi \vec{r} \cdot \vec{S}) dr^3$$



**Facteur de diffusion** ( $f_j$ ) d'un atome j

caractérise l'interaction de l'atome j avec les rayons X  
(par rapport à un électron libre)

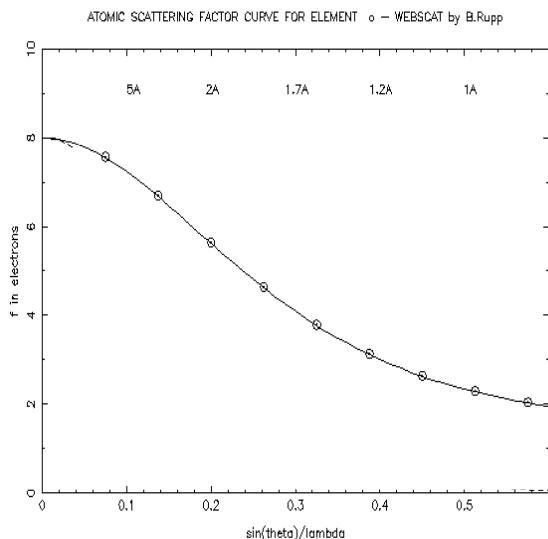
# Diffusion élastique cohérente des RX par un atome

facteur de diffusion ( $f_j$ ) d'un atome j

## Diffusion non anomale

- l'énergie des photons X est assez différente de l'énergie de liaison d'un électron dans l'atome, les électrons diffusent comme s'ils étaient libres
- facteur de diffusion ( $f_j$ ) d'un atome j est un nombre réel

$$f_j(S) = \int 4\pi r^2 \rho(r) \frac{\sin(2\pi r S)}{2\pi r S} dr$$



pour  $\frac{\sin \theta}{\lambda} = 0$ ,  $f_i^0 \cong Z_i$

Approximation polynomiale (Cromer, Waber 1968)

$$f^0\left(\frac{\sin \theta}{\lambda}\right) = \sum_{i=1}^{i=4} a_i e^{-b_i\left(\frac{\sin \theta}{\lambda}\right)^2} + c$$

## diffusion anomale :

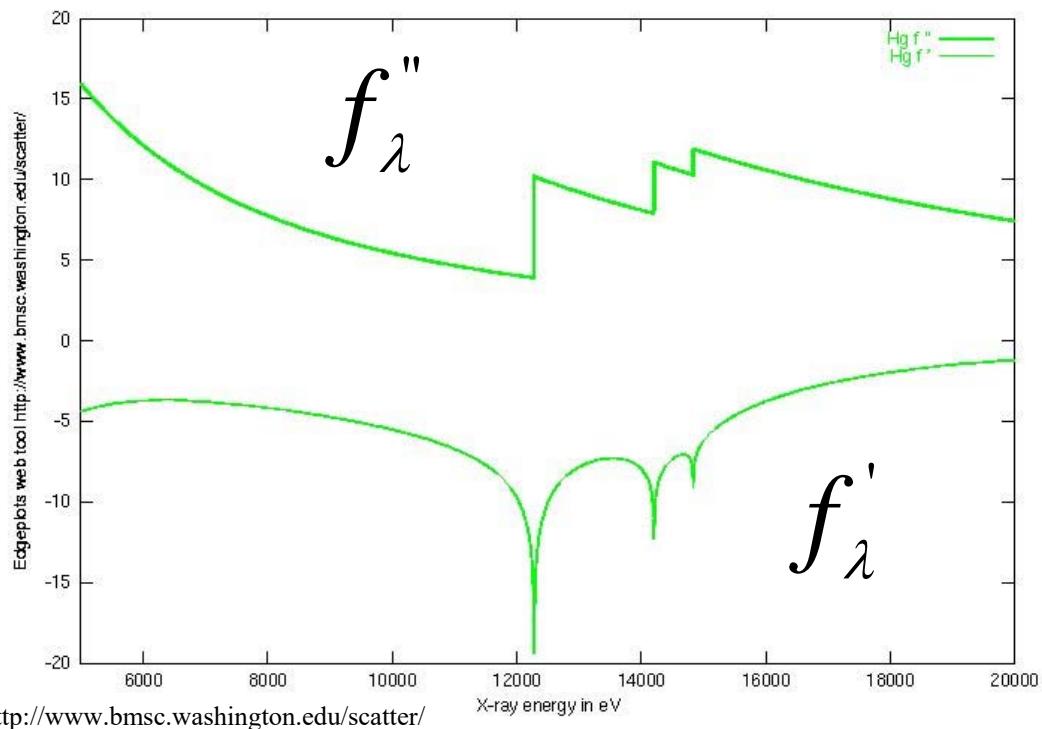
- l'énergie des photons X est très proche de l'énergie de liaison d'un électron dans l'atome,
- effets de résonance entre le photon incident et l'électron importants,

→

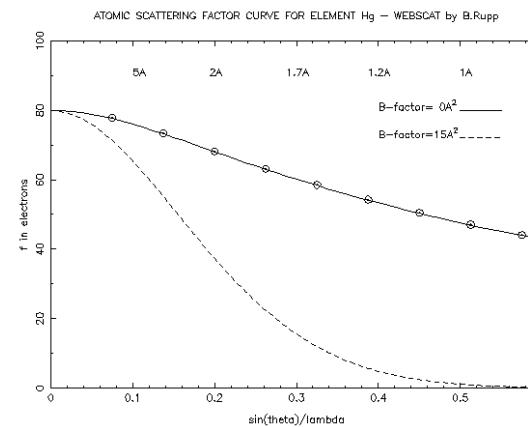
- changement de phase et d'amplitude de l'onde diffusée dépendant de la nature de l'atome
  - l'onde diffusée par l'atome n'est plus en phase avec l'onde de référence diffusée par un électron à l'origine.
- facteur de diffusion ( $f_j$ ) d'un atome j est un nombre complexe

$$f_j(\lambda) = f_j^0 + f_j'(\lambda) + i f_j''(\lambda)$$

$$f(\lambda) = f_0 + f'(\lambda) + i f''(\lambda)$$

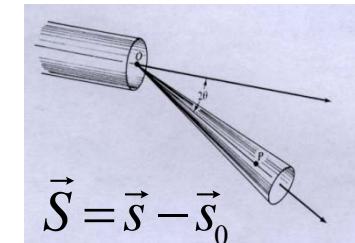


$$E_{\text{(keV)}} \cong \frac{12,3985}{\lambda_{\text{(\AA)}}}$$



# Diffusion par n atomes

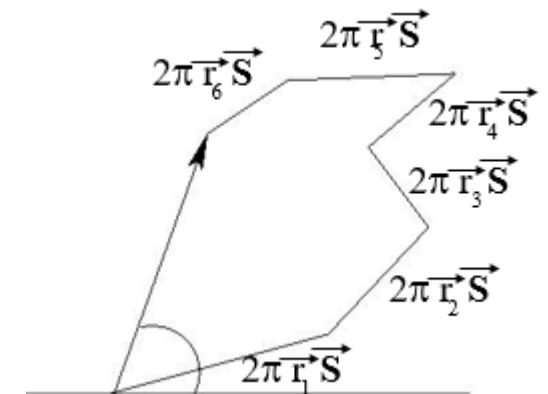
- N atomes caractérisés par :
  - facteur de diffusion  $f_j$  ( $j=1,n$ )
  - position  $r_j$  ( $j=1,n$ )



- En prenant comme unité l'amplitude diffusé par un électron en O,

l'onde diffusée par n atomes dans une direction quelconque caractérisée par l'angle  $2\theta$  est :

$$F(\vec{S}) = \sum_{j=1}^{j=n} f_j \exp(2i\pi \vec{r}_j \cdot \vec{S})$$



# Diffraction par un réseau tridimensionnel d'atomes identiques

- Un réseau caractérisé par les vecteurs  $(\vec{a}, \vec{b}, \vec{c})$
- Pour  $(n_a, n_b, n_c)$  grands,
  - Interférences constructives si et seulement si



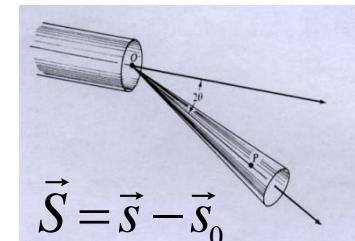
Max von Laue

Nobel Prize in Physics 1914

$$\vec{a} \cdot \vec{S} = h, \quad h \in \mathbb{Z}$$

$$\vec{b} \cdot \vec{S} = k, \quad k \in \mathbb{Z}$$
 Equations de Laue

$$\vec{c} \cdot \vec{S} = l, \quad l \in \mathbb{Z}$$



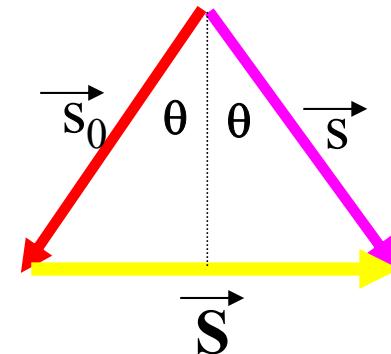
## Diffraction par un réseau tridimensionnel d'atomes identiques

$$\vec{a} \cdot \vec{S} = h, \quad h \in \mathbb{Z}$$

$$\vec{b} \cdot \vec{S} = k, \quad k \in \mathbb{Z}$$

$$\vec{c} \cdot \vec{S} = l, \quad l \in \mathbb{Z}$$

Équations de Laue



- Les équations de Laue sont vérifiées si et seulement si

–  $\vec{S}$  est un vecteur du réseau réciproque

$$\exists (h, k, l) \in \mathbb{Z}^3 / \vec{S} = h \vec{a}^* + k \vec{b}^* + l \vec{c}^*$$

– On a alors **diffraction dans la direction**  $\vec{s} = \vec{S} + \vec{S}_0$



Max von Laue

1879 - 1960

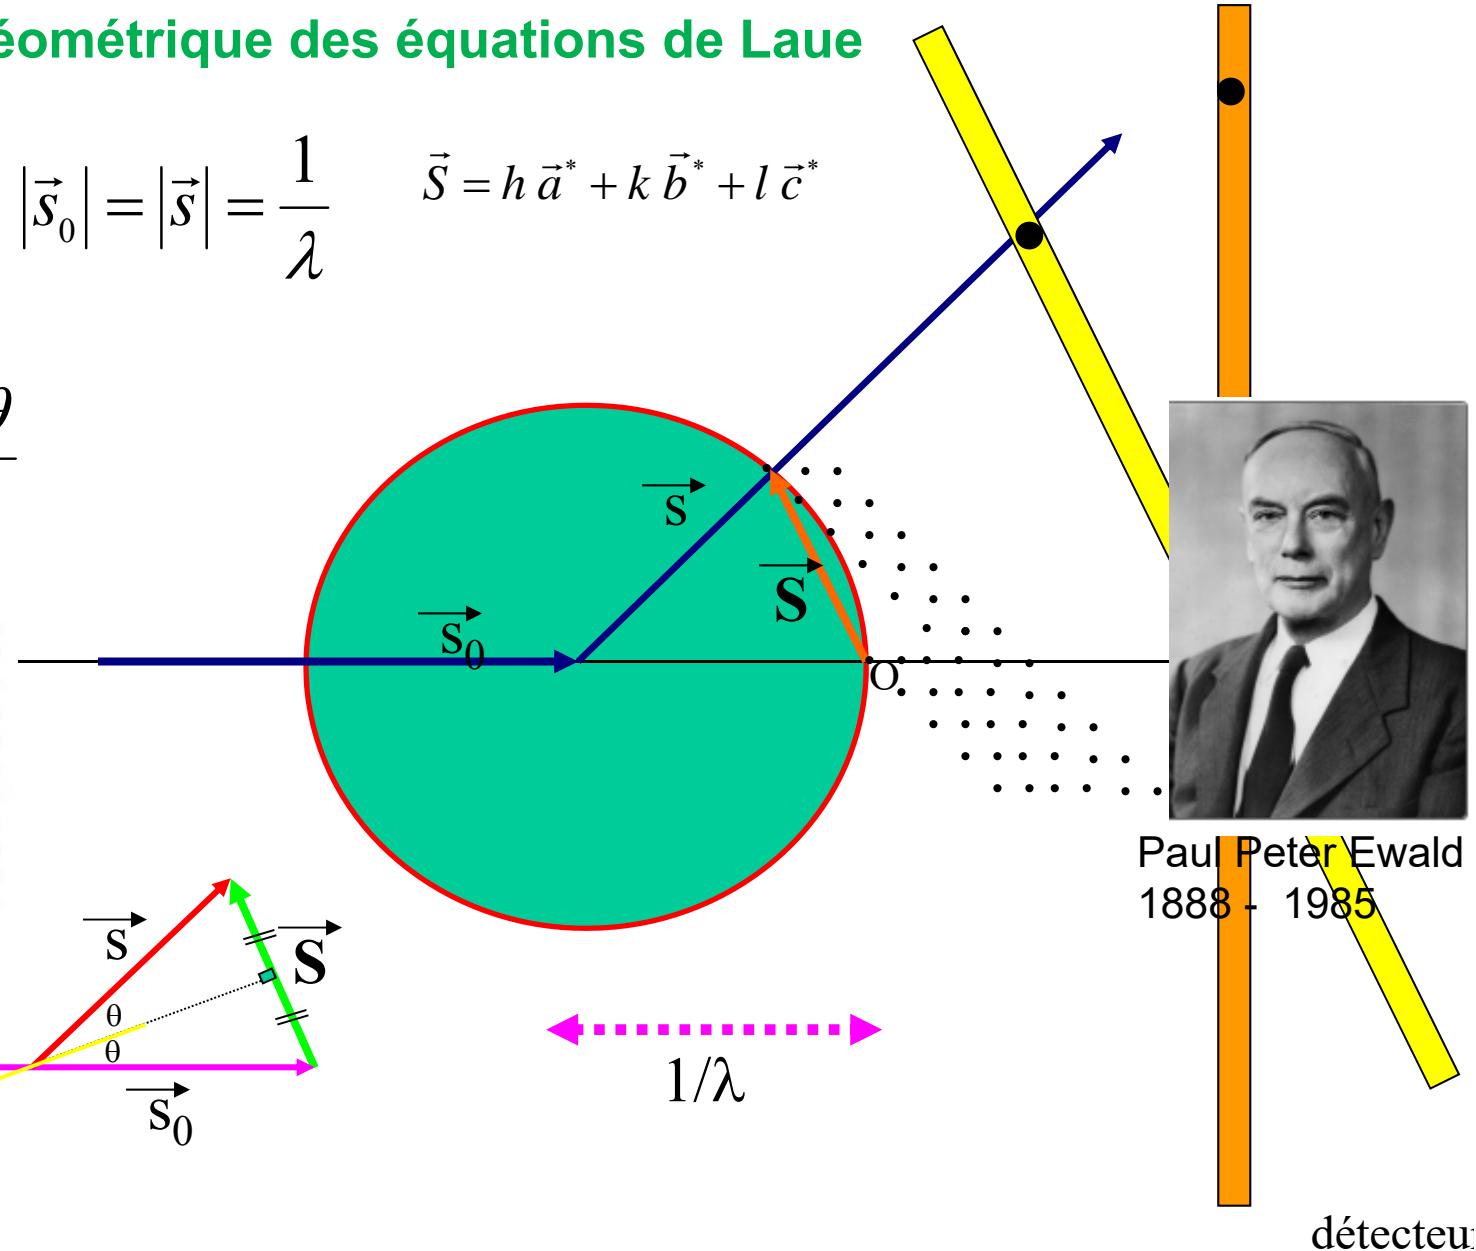
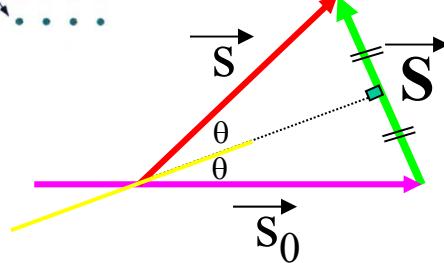
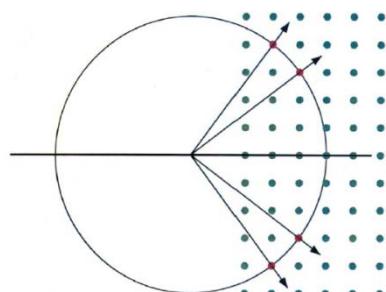
Nobel Prize in Physics 1914

## Construction d'Ewald. Sphère d'Ewald

### Interprétation géométrique des équations de Laue

$$\vec{S} = \vec{s} - \vec{s}_0 \quad |\vec{s}_0| = |\vec{s}| = \frac{1}{\lambda}$$

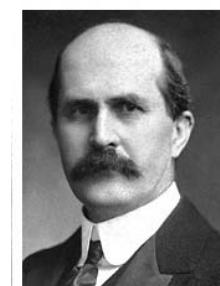
$$|\vec{S}| = 2 \frac{\sin \theta}{\lambda}$$



## Interprétation géométrique des équations de Laue

$$|\vec{S}| = \frac{1}{d_{hkl}} = 2 \frac{\sin \theta}{\lambda}$$

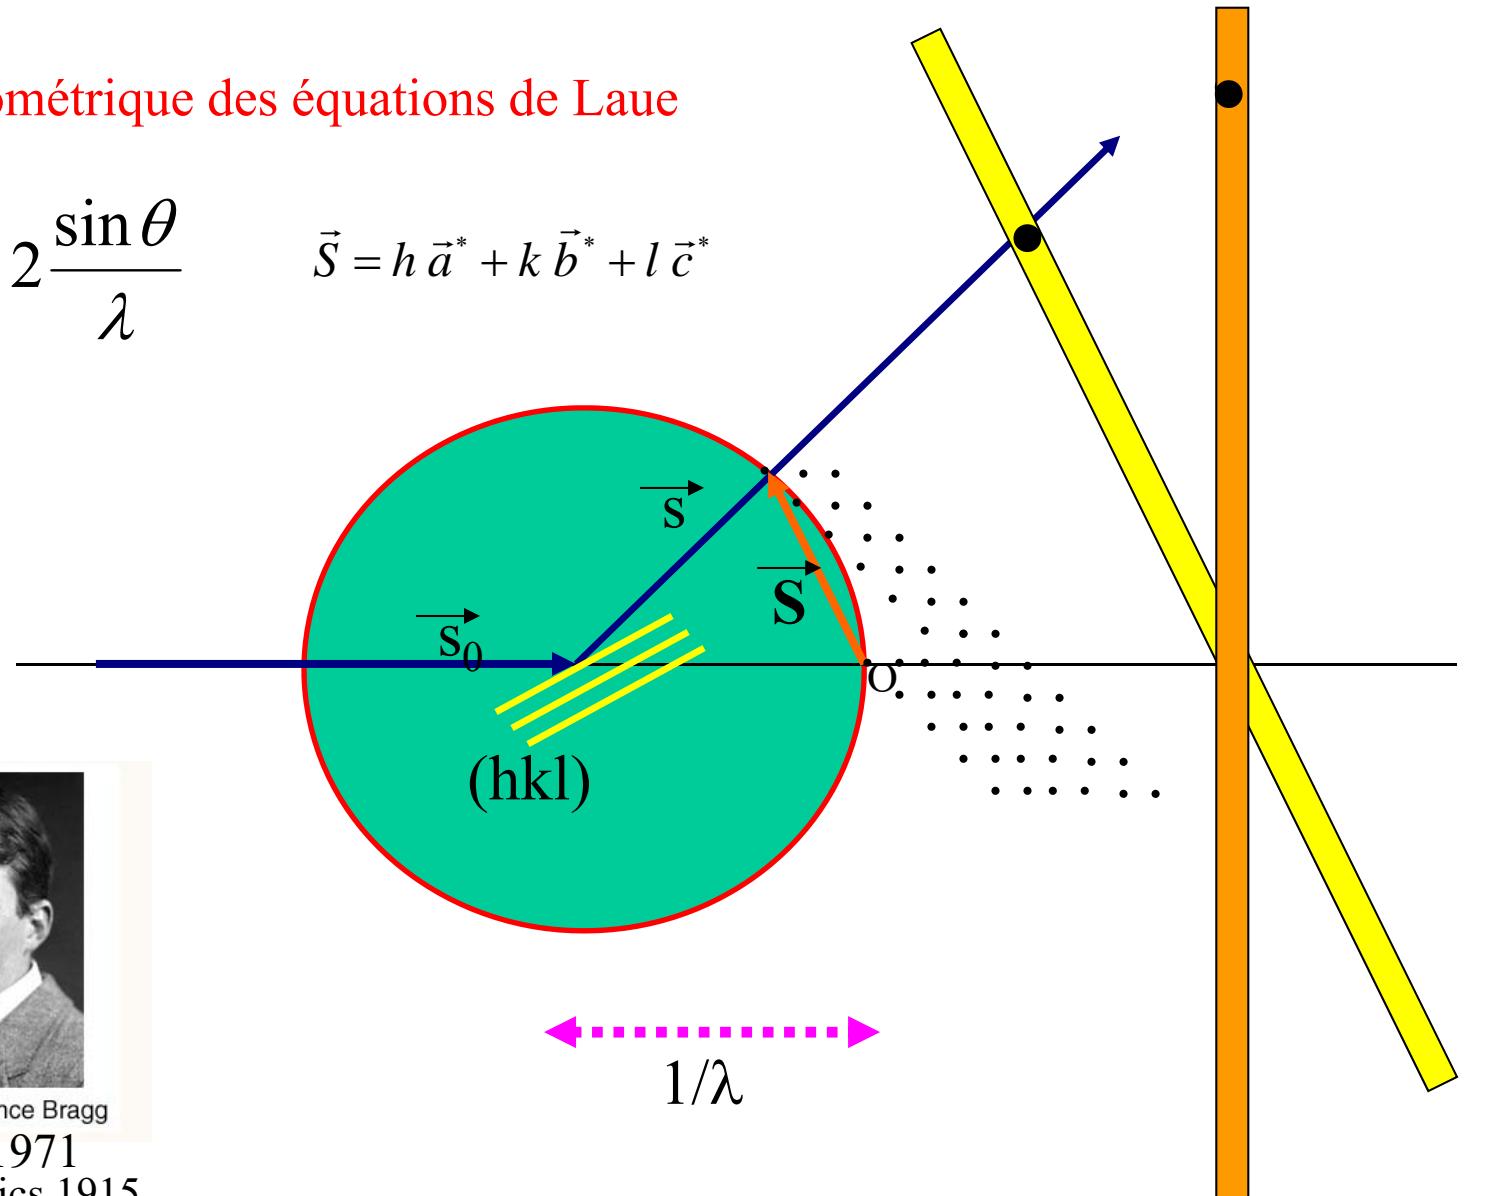
$$\vec{S} = h \vec{a}^* + k \vec{b}^* + l \vec{c}^*$$



William Henry Bragg  
1862 - 1942



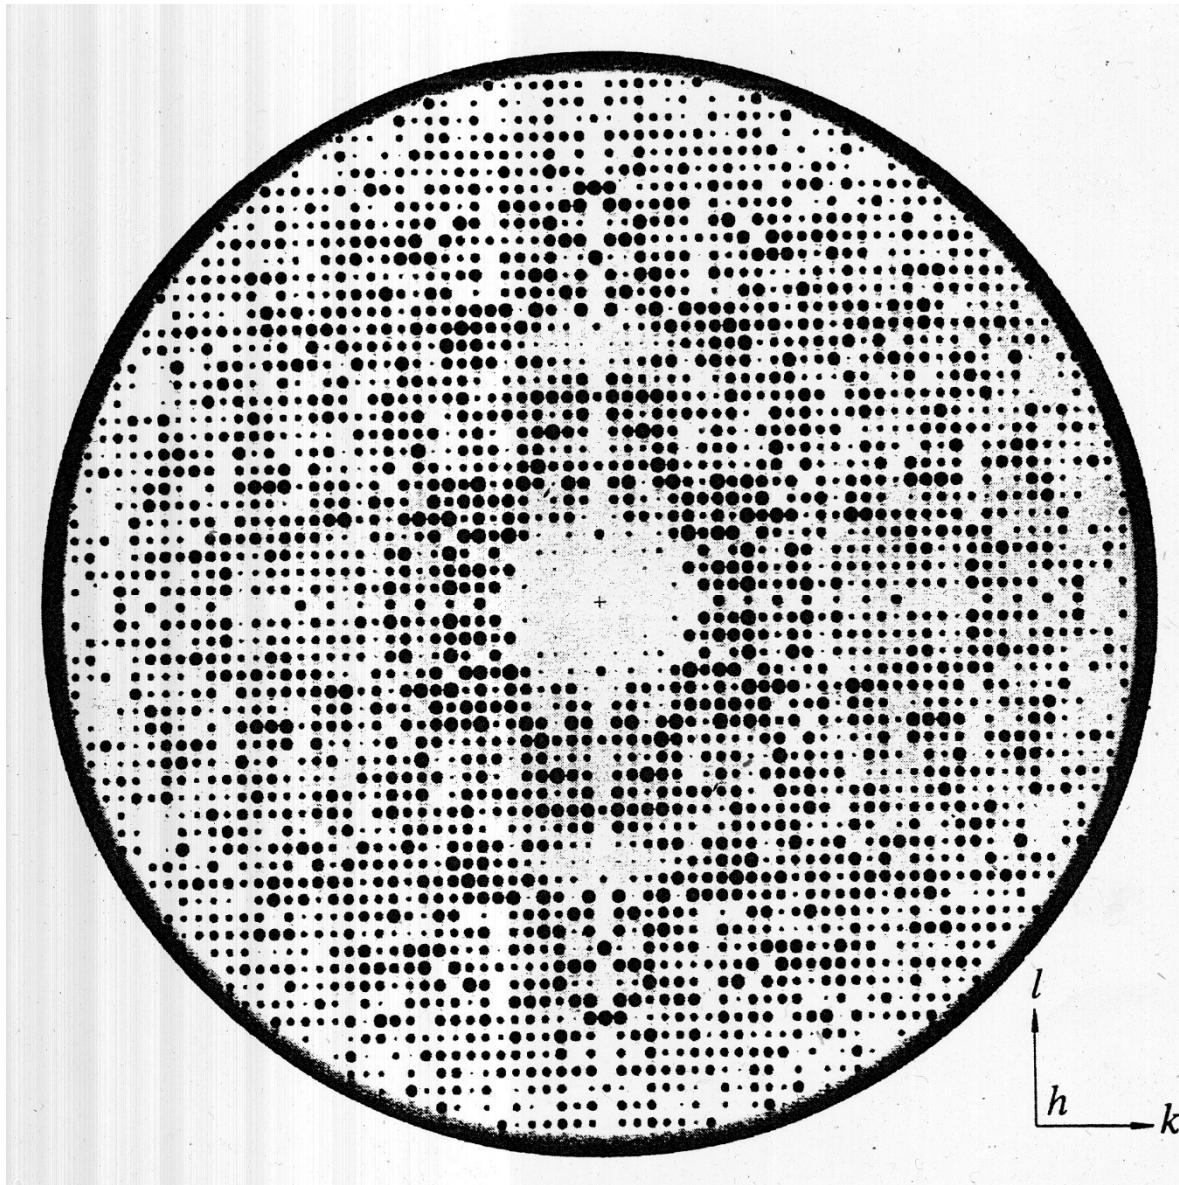
William Lawrence Bragg  
1890 - 1971  
Nobel Prize in Physics 1915



Loi de Bragg

$$2 d_{hkl} \sin \theta = \lambda$$

détecteur



N $\omega$ v

$\lambda=1.22\text{\AA}$

$a=411\text{\AA}$   $b=410\text{\AA}$

$c=420\text{\AA}$

$\alpha=59^\circ$   $\beta=58,9^\circ$

$\gamma=64^\circ$

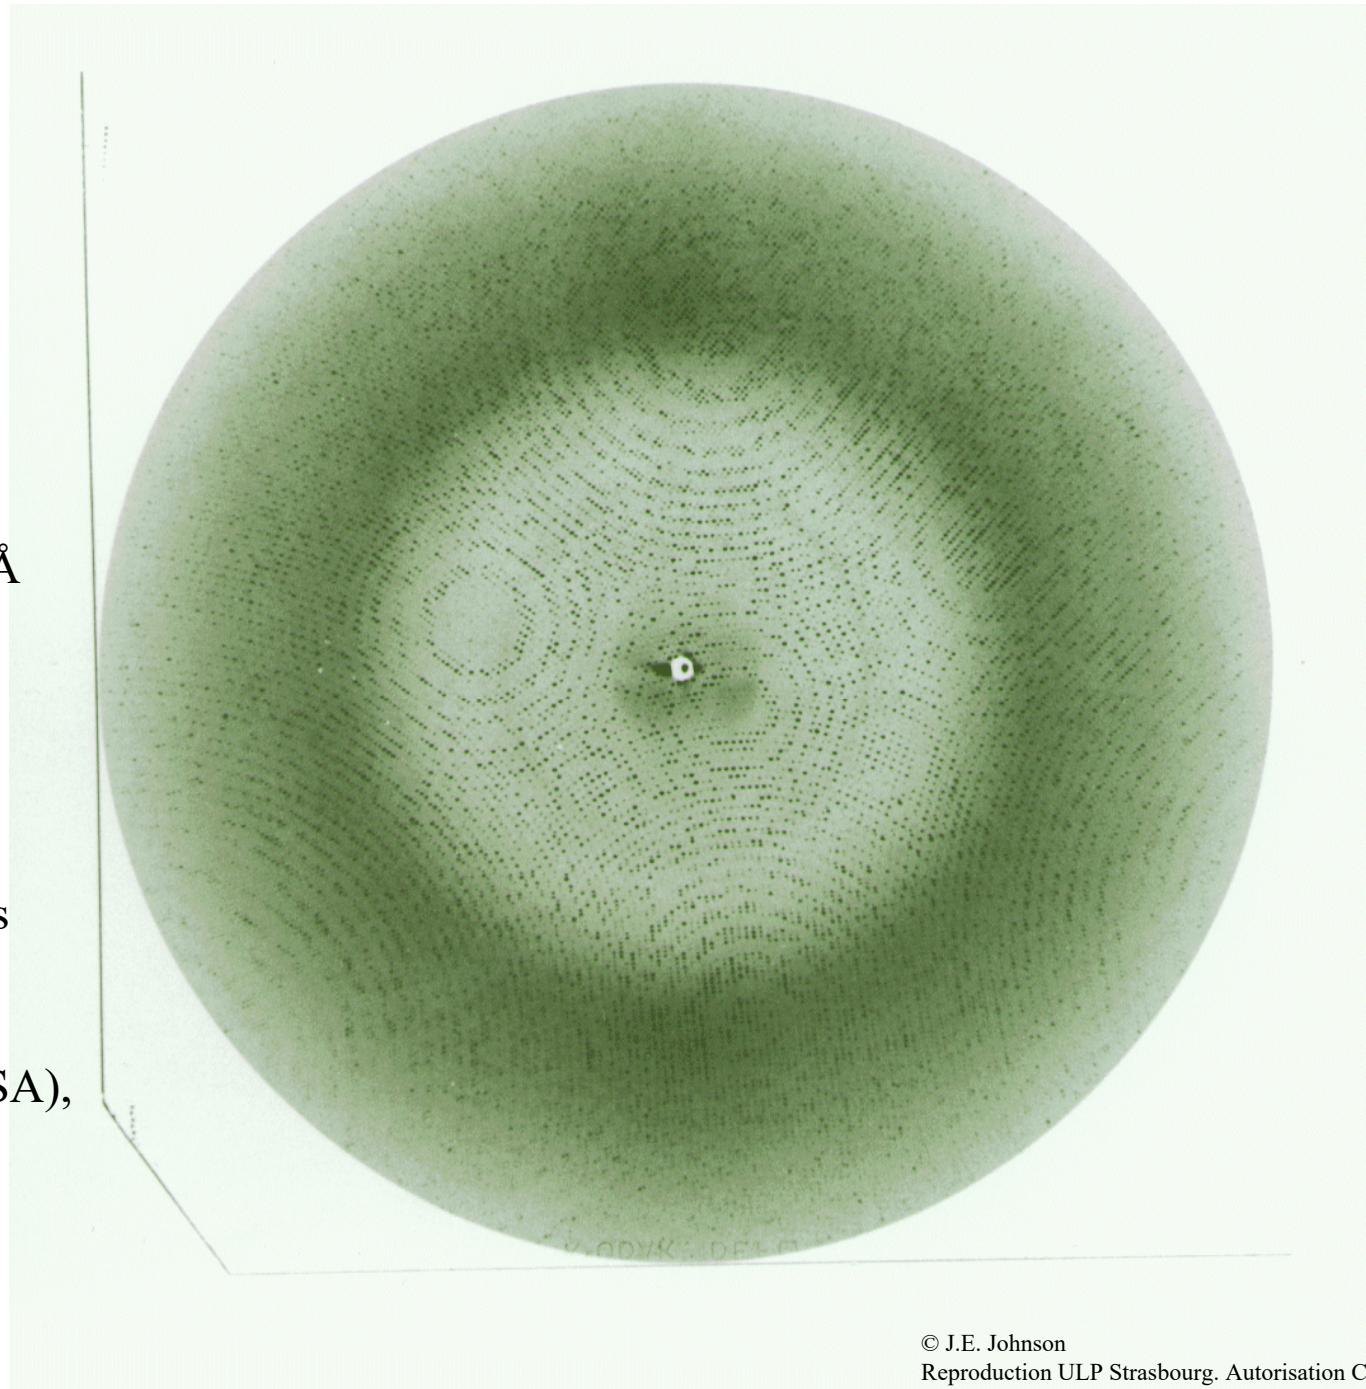
$\Delta\phi=0.3^\circ$

DF=120mm.

15245 réflexions

2.7 $\text{\AA}$

Brookhaven (USA),  
1988.



© J.E. Johnson

Reproduction ULP Strasbourg. Autorisation CFC-Paris

# Facteurs de Structure d'un cristal

$$\sum_{j=1}^{j=n} f_j \exp(2i\pi \vec{r}_j \cdot \vec{S})$$

$n_1$  mailles selon  $\vec{a}$ ,  $n_2$  mailles selon  $\vec{b}$ ,  $n_3$  mailles selon  $\vec{c}$

$$G(\vec{S}) = F(\vec{S}) L(\vec{S})$$

- $F(\vec{S})$  facteur de structure (pour une maille)
  - Dépend du contenu atomique de la maille, rend compte du déphasage entre atomes de la maille.
  - Indépendant de la taille du cristal.
- $L(\vec{S})$  facteur de forme
  - Amplitude diffusé par le cristal, en prenant comme unité celle diffusée par une maille. Dépend des dimensions ou de la forme du cristal, rend compte du déphasage entre les mailles.
  - Indépendant du contenu atomique de la maille.

$$L(\vec{S}) = \sum_{u=0}^{u=n_1-1} \sum_{v=0}^{v=n_2-1} \sum_{w=0}^{w=n_3-1} \exp(2i\pi(u\vec{a}.\vec{S} + v\vec{b}.\vec{S} + w\vec{c}.\vec{S}))$$

$$L(\vec{S}) = \sum_{u=0}^{u=n_1-1} \exp(2i\pi u\vec{a}.\vec{S}) \sum_{v=0}^{v=n_2-1} \exp(2i\pi v\vec{b}.\vec{S}) \sum_{w=0}^{w=n_3-1} \exp(2i\pi w\vec{c}.\vec{S})$$

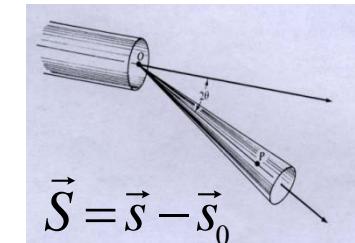
$$|L(\vec{S})|^2 = \left( \frac{\sin(n_1\pi\vec{a}.\vec{S})}{\sin(\pi\vec{a}.\vec{S})} \right)^2 \left( \frac{\sin(n_2\pi\vec{b}.\vec{S})}{\sin(\pi\vec{b}.\vec{S})} \right)^2 \left( \frac{\sin(n_3\pi\vec{c}.\vec{S})}{\sin(\pi\vec{c}.\vec{S})} \right)^2$$

Pour un cristal de dimension infinie

$$L(\vec{S}) \neq 0 \quad \text{si et seulement si} \quad \vec{S} = h\vec{a}^* + k\vec{b}^* + l\vec{c}^*$$

$$G(\vec{S}) \perp n_1^2 n_2^2 n_3^2 F(\vec{S})$$

Pour un cristal de dimension "infinie"



$$\vec{S} = \vec{s} - \vec{s}_0$$

$$G(\vec{S}) \propto F(\vec{S}) \neq 0$$

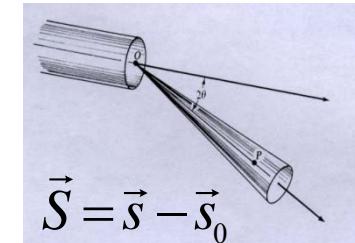
$$\text{si et seulement si } \vec{S} = h\vec{a}^* + k\vec{b}^* + l\vec{c}^*$$

$\{F(\vec{S})\}$  facteurs de structure

- dépend du contenu atomique de la maille
- rend compte du déphasage entre atomes de la maille
- Indépendant de la taille du cristal

## Facteur de structure

- N atomes dans la maille
- $(f_j, \vec{r}_j), j = 1, N$



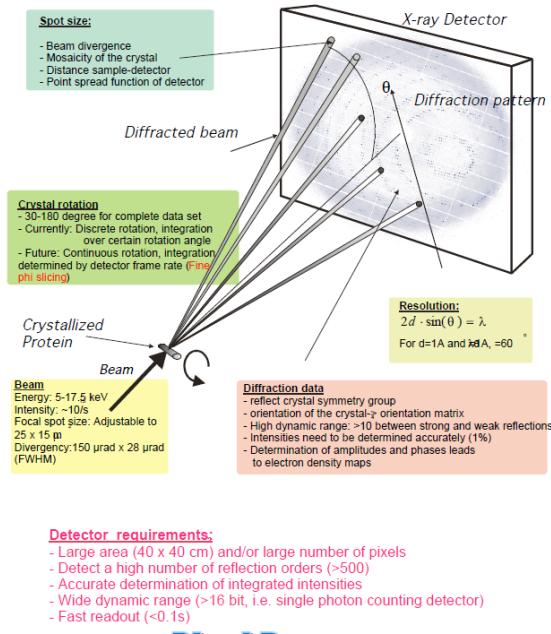
$$F(\vec{S}) = \sum_{j=1}^{j=N} f_j \exp(2\pi i \vec{S} \cdot \vec{r}_j)$$

$$\vec{r}_j = x_j \vec{a} + y_j \vec{b} + z_j \vec{c} \quad 0 \leq x_j, y_j, z_j < 1$$

$$\vec{S} = h\vec{a}^* + k\vec{b}^* + l\vec{c}^*$$

$$F(\vec{S}) = \sum_{j=1}^{j=N} f_j \exp(2\pi i(hx_j + ky_j + lz_j)) = F_{hkl}$$

### Data collection in protein crystallography



## Limite de diffraction du cristal

$$|\vec{S}| = |\vec{S}_{\max}|$$

Attention, on utilise dans la pratique

$$d_{\min} = \frac{1}{|\vec{S}_{\max}|}$$

La limite de diffraction n'est pas un critère fixé par l'utilisateur, mais dans les conditions les plus optimales, elle reflète la **qualité intrinsèque (ordre)** d'un cristal

# Relations entre facteurs de structures

**En absence de diffuseur anomal**

**Loi de Friedel** (Georges Friedel)



1865-1933

$$F_{hkl} = \sum_{j=1}^{j=N} f_j \exp(2\pi i(hx_j + ky_j + lz_j))$$

$$F_{\bar{h}\bar{k}\bar{l}} = \overline{F}_{hkl}$$

$$\left| F_{\bar{h}\bar{k}\bar{l}} \right| = \left| \overline{F}_{hkl} \right| \quad et \quad \phi_{\bar{h}\bar{k}\bar{l}} = -\phi_{hkl}$$

Pour un groupe d'espace donné,

- Espace direct : Opérateurs de symétrie :

$$C_s : (R_s, T_s), (s=1,n)$$

$$\vec{r}_{js} = R_S \vec{r}_j + T_S$$

- Espace réciproque : Contraintes correspondantes sur les facteurs de structure

$$F_{R_S^t H} = F_H \exp(-2i\pi H^t T_S)$$

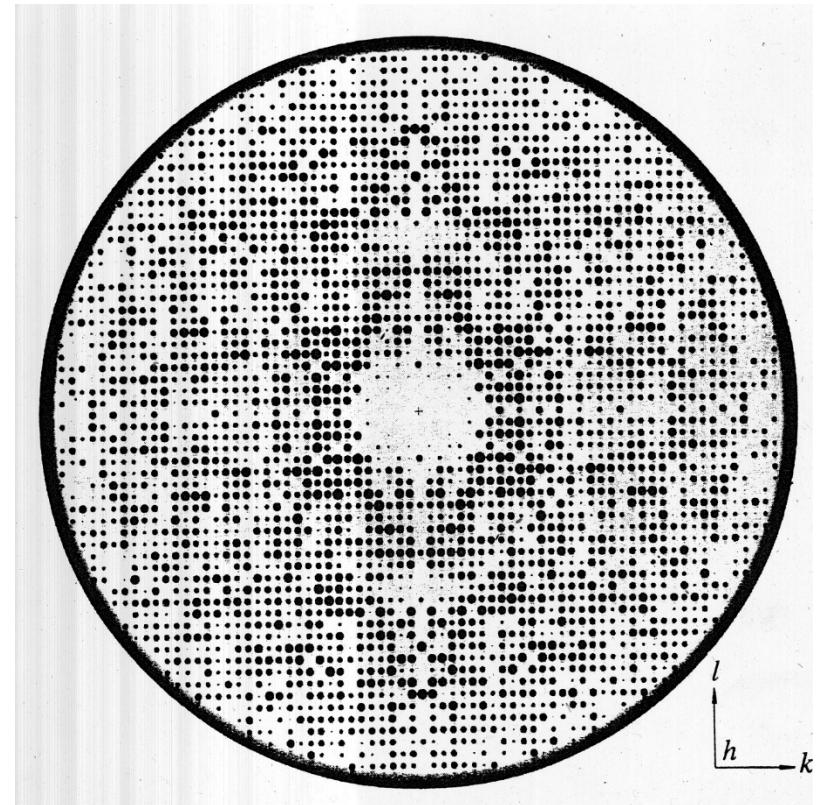
$$\left| F_{R_S^t H} \right| = \left| F_H \right| \quad et \quad \phi_{R_S^t H} \equiv \phi_H - 2\pi H^t T_S \quad [2\pi]$$

$$F_{R_S^t H} = F_H \exp(-2i\pi H^t T_S)$$

$$\left| F_{R_S^t H} \right| = \left| F_H \right| \quad \phi_{R_S^t H} = \phi_H - 2\pi H^t T_S$$

Réflexions équivalentes

Extinctions systématiques



# Exemple. Groupe P6<sub>1</sub>

- Positions équivalentes

$x, y, z$

$-y, x-y, z+1/3$

$y-x, -x, z+2/3$

$-x, -y, z+1/2$

$y, y-x, z+5/6$

$x-y, x, z+1/6$

- Réflexions équivalentes en absence de diffuseur anomal

$hkl$	$-h, -k, -l$
$k, (-h - k), l$	$-k, (h + k), -l$
$(-h - k), h, l$	$(h + k), -h, -l$
$-h, -k, l$	$h, k, -l$
$-k, (h + k), l$	$k, (-h - k), -l$
$(h + k), -h, l$	$(-h - k), h, -l$

## Contraintes sur les facteurs de structure : Extinctions systématiques

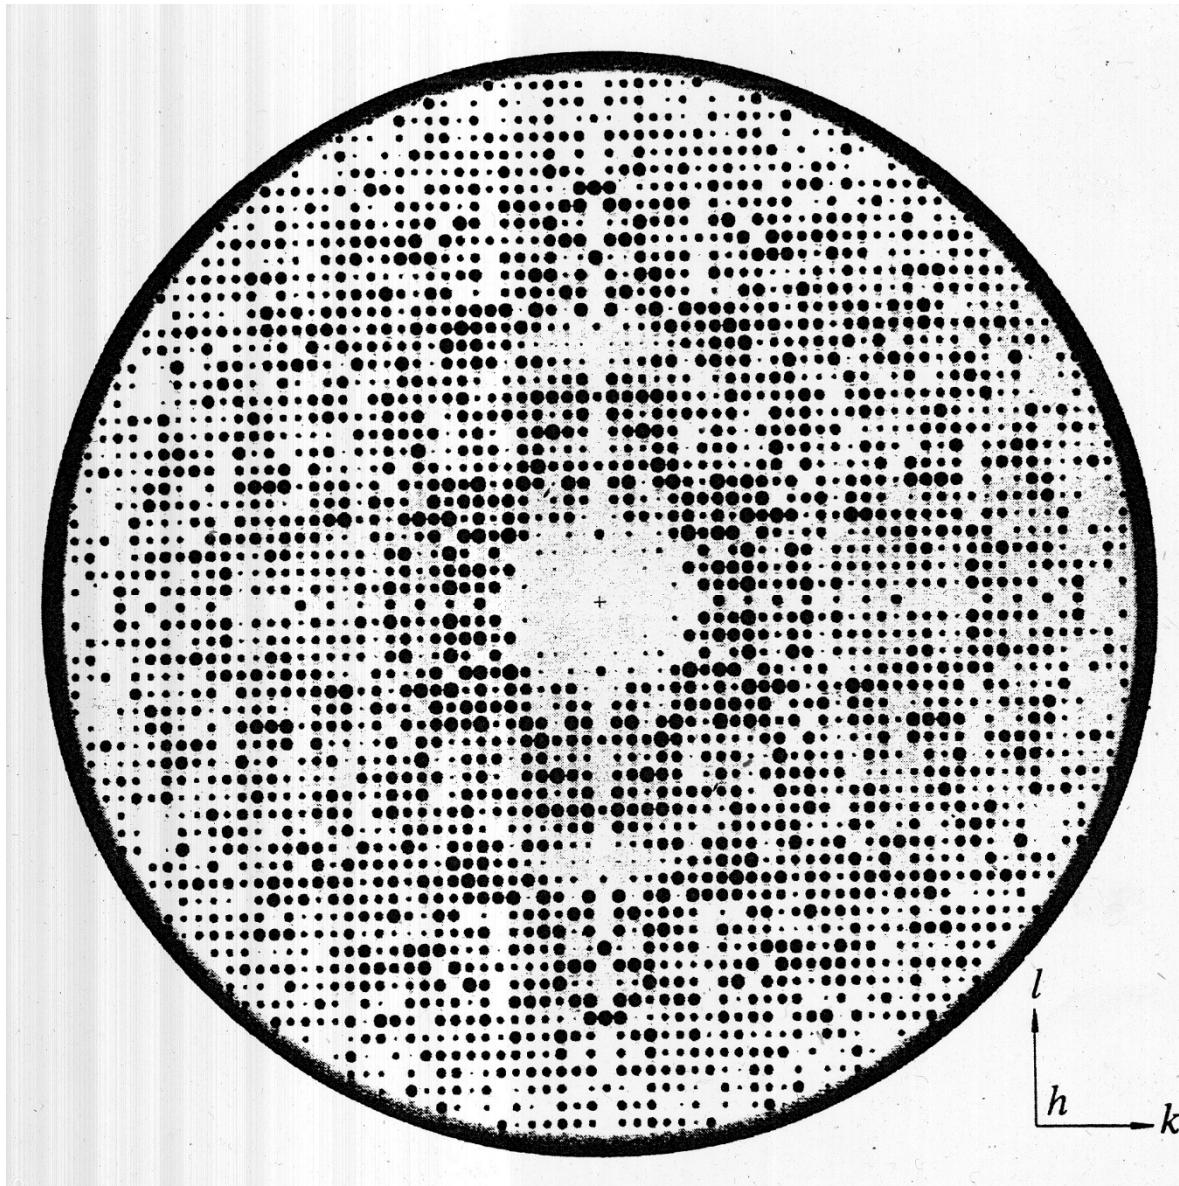
$$F_{R_S^t H} = F_H \exp(-2i\pi H^t T_S)$$

$$\left| F_{R_S^t H} \right| = \left| F_H \right| \quad \phi_{R_S^t H} = \phi_H - 2\pi H^t T_S$$

$$\text{si } H = R_S^t H \quad \text{et} \quad H^t T_S \text{ non entier} \Rightarrow \left| F_H \right| = 0$$

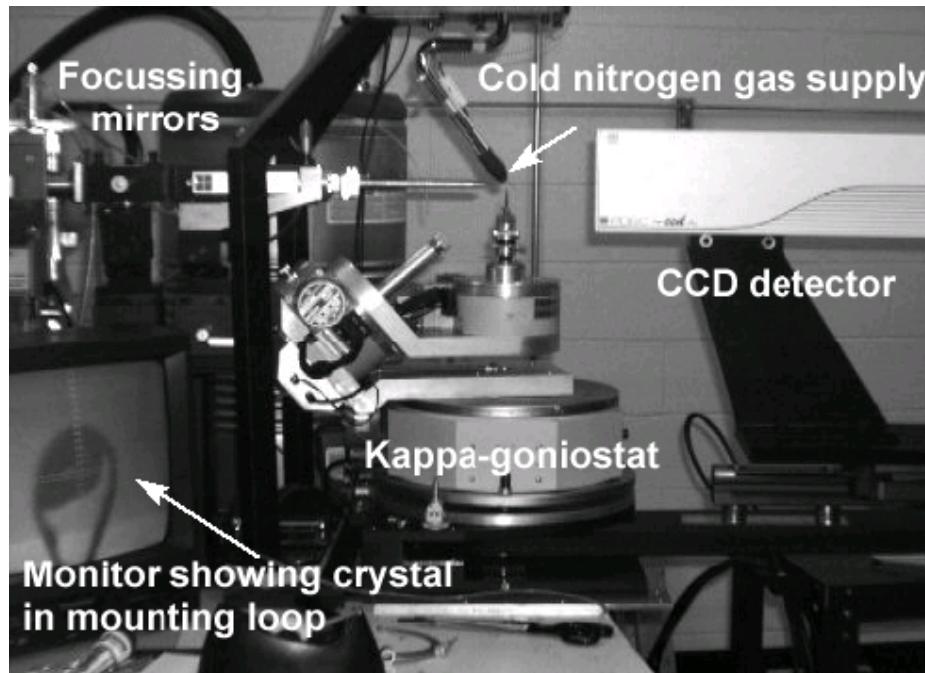
- **axes hélicoïdaux :**
  - extinctions à périodicité unidimensionnelle : situés sur une rangée particulière du réseau réciproque
- **plans de symétrie translatoires :**
  - extinctions à périodicité bidimensionnelle, situés sur un plan particulier du réseau réciproque
- **modes de réseau :**
  - extinctions à périodicité tridimensionnelle.

<b>Réflexions affectées</b>	<b>Conditions d'existence</b>	<b>Éléments de symétrie</b>
h00	$h=2n$	$2_1 // a, 4_2 // a$
0k0	$k=2n$	$2_1 // b, 4_2 // b$
00l	$l=2n$	$2_1$ ou $4_2$ ou $6_3 // c$
	$l=3n$	$3_1$ ou $3_2$ ou $6_2$ ou $6_4 // c$
	$l=4n$	$4_1$ ou $4_3 // c$
	$l=6n$	$6_1$ ou $6_5 // c$
hkl	$h+k=2n$	Mode C
	$h+l=2n$	Mode B
	$k+l=2n$	Mode A
	$h+k+l=2n$	Mode I
	$h,k,l$ , tous pairs ou impairs	Mode F



# Collecte des données de diffraction

1. cristal
2. source de Rayons X (cours Jean-Luc Ferrer)
3. détecteur
4. Méthode de collecte des données
5. Traitements des données

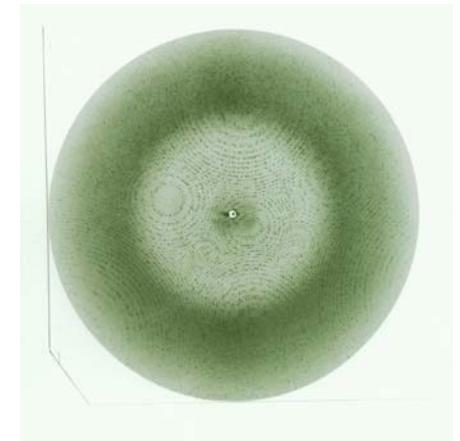


## Collecte des données de diffraction

$$I_{hkl}(\lambda) = K \frac{V_c}{V^2} I_0(\lambda) C(\lambda, r) \lambda^3 |F_{hkl}(\lambda)|^2$$

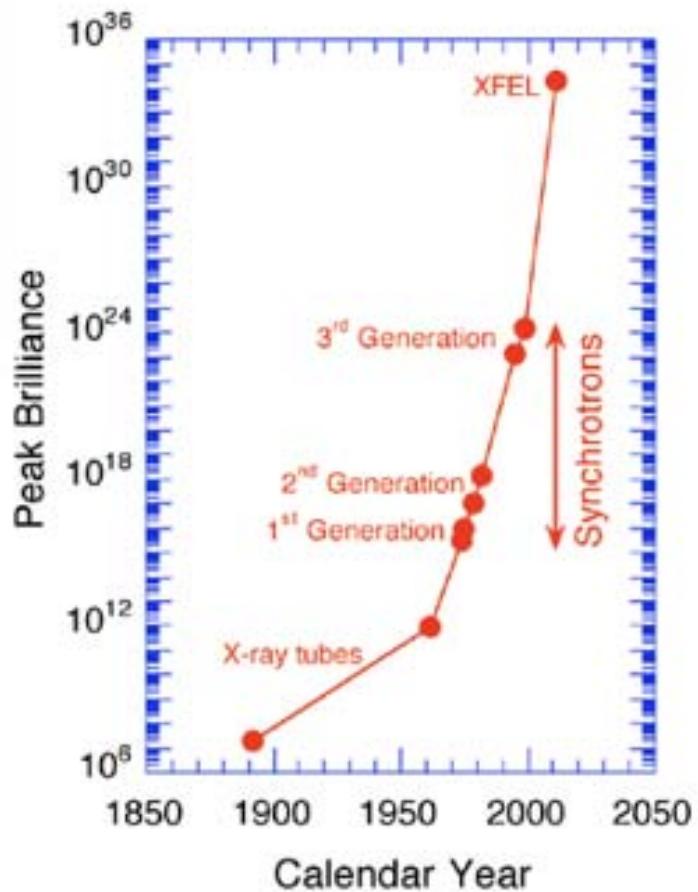
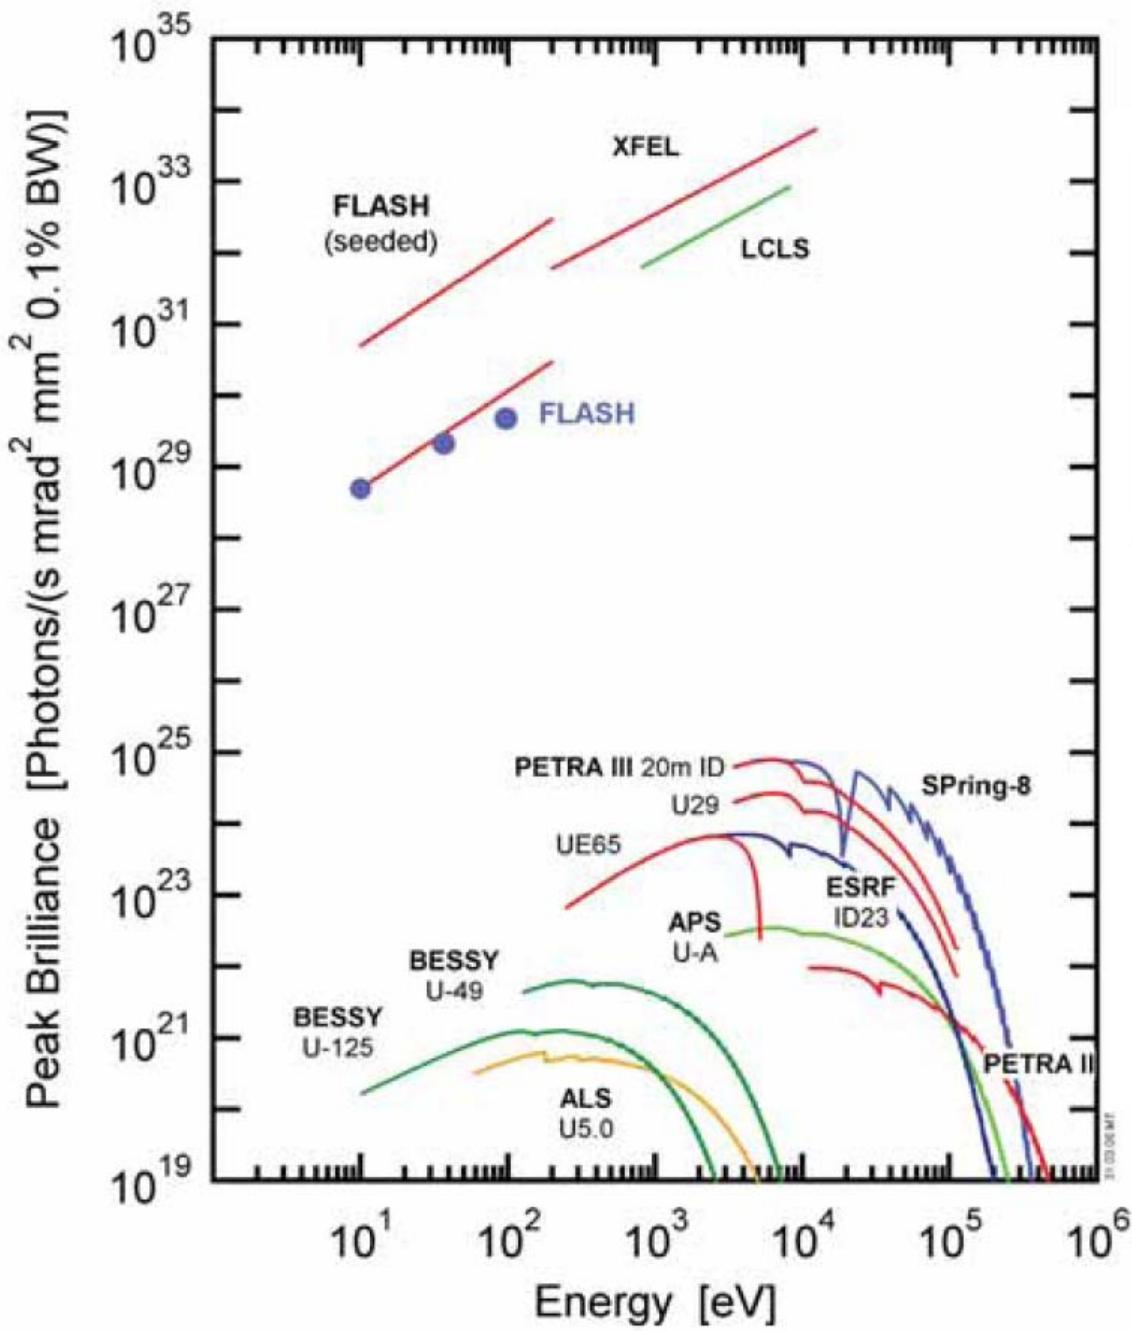
Spécificité des macromolécules biologiques

- Intensités faibles
- Réseaux réciproques fortement peuplés
- Dégradation du cristal dans faisceau de rayons X



Des progrès **technologiques** et **méthodologiques** à toutes les étapes du processus

- Source de Rayons X
- DéTECTEURS
- Méthodes de Collecte et de traitement des données
- Préparation des cristaux

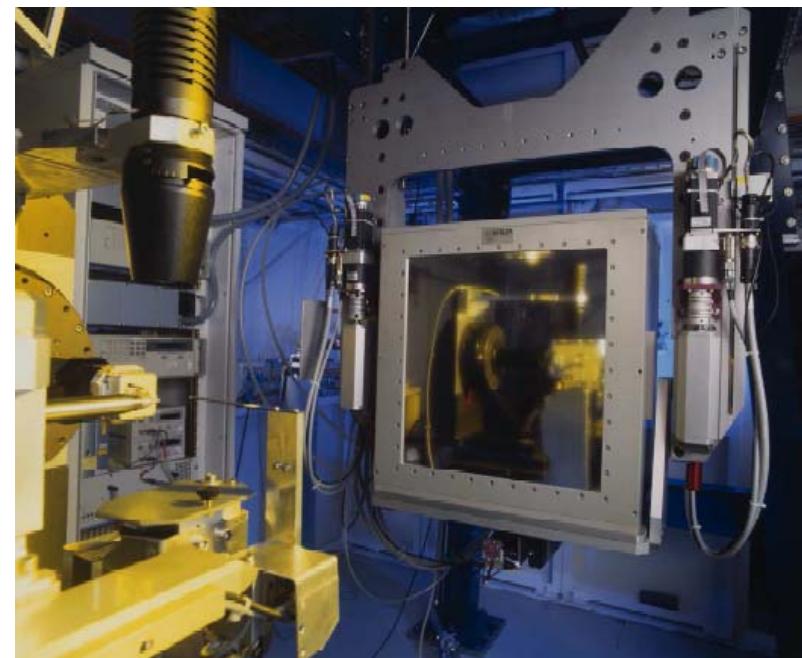
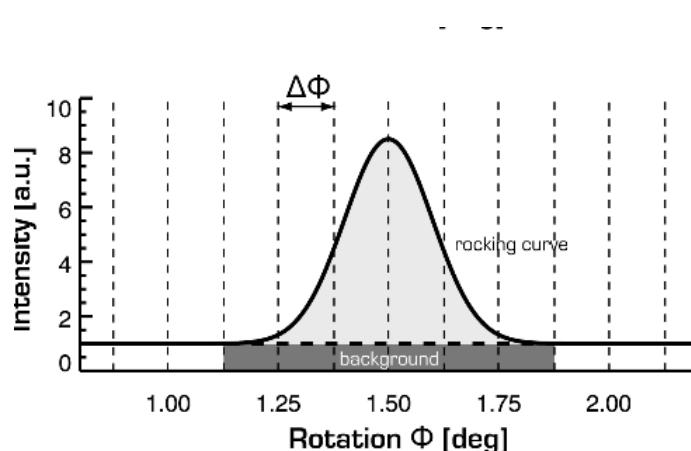


PILATUS La révolution de ces dernières années

# PIxel ApparATUs for the Swiss Light Source

Paul Scherrer Institut (PSI), CH-Villigen

- Qualités
  - Temps de lecture : quelques ms
  - Pas de bruit de fond
  - Grande dynamique
  - Collecte en continu possible
    - $0.02^\circ$ - $0.2^\circ$ , exposition 100ms
    - Lecture 3ms sans arrêt





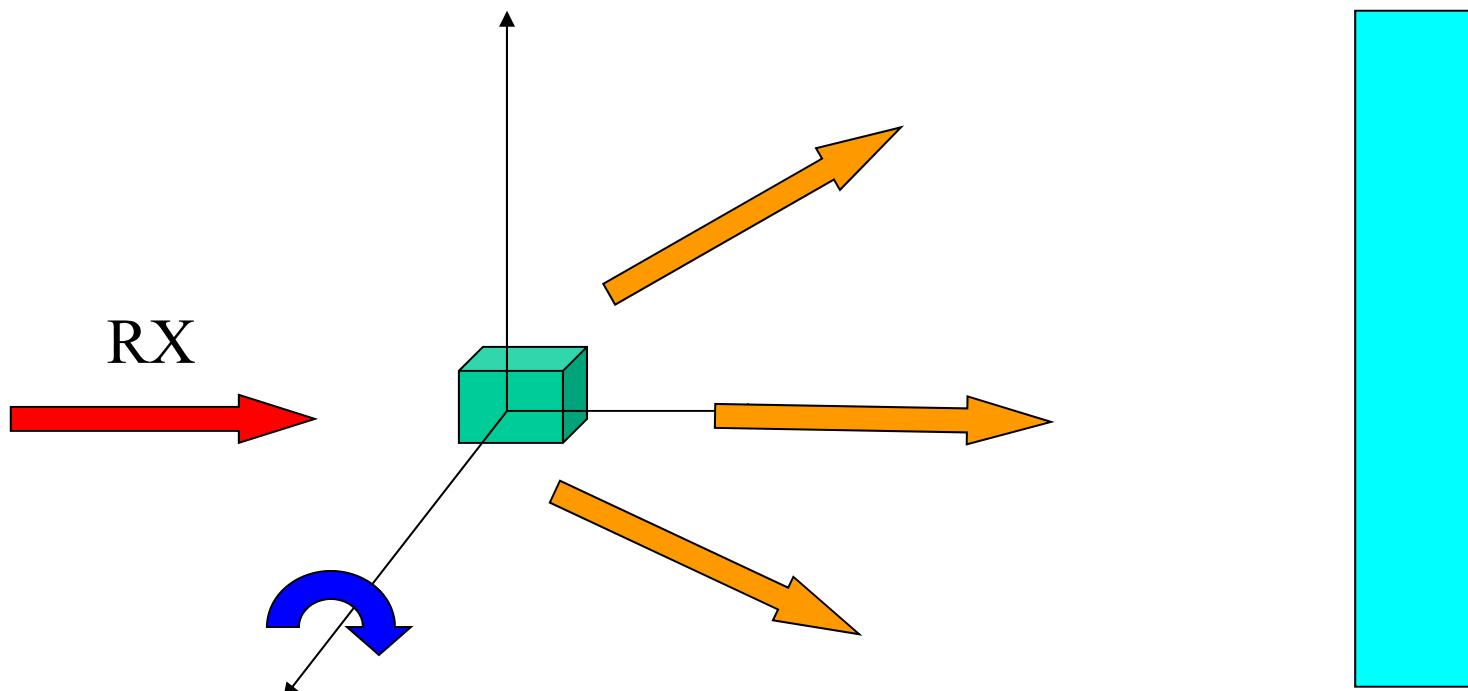
## Technical specifications

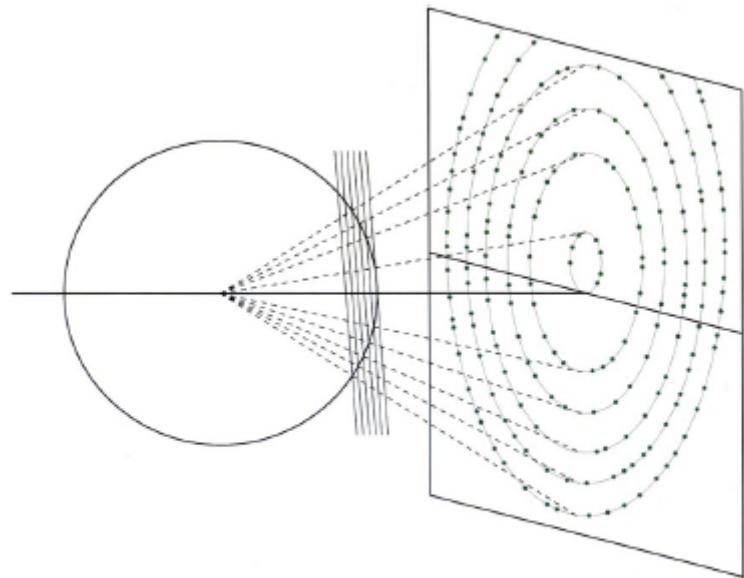
EIGER X	1M	4M	9M	16M
<b>Number of detector modules</b>	1 × 2	2 × 4	3 × 6	4 × 8
<b>Sensitive area, width × height [mm<sup>2</sup>]</b>	77.2 × 79.9	155.2 × 162.5	233.2 × 245.2	311.2 × 327.8
<b>Pixel size [μm<sup>2</sup>]</b>		75 × 75		
<b>Total number of pixels</b>	1030 × 1065 = 1,096,950	2070 × 2167 = 4,485,690	3110 × 3269 = 10,166,590	4150 × 4371 = 18,139,650
<b>Gap width, hor. / ver. [pixel]</b>	– / 37	10 / 37	10 / 37	10 / 37
<b>Inactive area [%]</b>	3.5	5.6	6.3	6.6
<b>Defective pixels [%]</b>		< 0.03		
<b>Maximum frame rate* [Hz]</b>	3000	750	238	133
<b>Readout time</b>	continuous readout, 3 μs dead time, duty cycle > 99 %			
<b>Point-spread function [pixel]</b>		1		
<b>Sensor thickness [μm]</b>		450		
<b>Threshold energy [keV]</b>		2.7 – 18		
<b>Maximum count rate [phts/s/mm<sup>2</sup>]</b>		5 · 10 <sup>8</sup>		
<b>Counter bit depth [bit]</b>		12		
<b>Image bit depth [bit]</b>		16 or 32		
<b>Data format</b>	HDF5 / NeXus			
<b>Dimensions (WHD) [mm<sup>3</sup>]</b>	114 × 133 × 240	235 × 237 × 372	340 × 370 × 500	400 × 430 × 500
<b>Weight [kg]</b>	3.9	15	41	55
<b>Power consumption [W]</b>	75	300	750	1200

\* Theoretical limit at maximum bandwidth

## Méthode d'oscillation

- Donner au cristal un **mouvement de rotation de faible amplitude** autour d'un axe
  - Amplitude de la rotation ( $\Delta\phi$ ) limitée par la superposition de réflexions différentes en un même endroit du détecteur
- L'espace complet de diffraction est enregistré en une succession de N "clichés", correspondant chacun à une oscillation  $\Delta\phi$

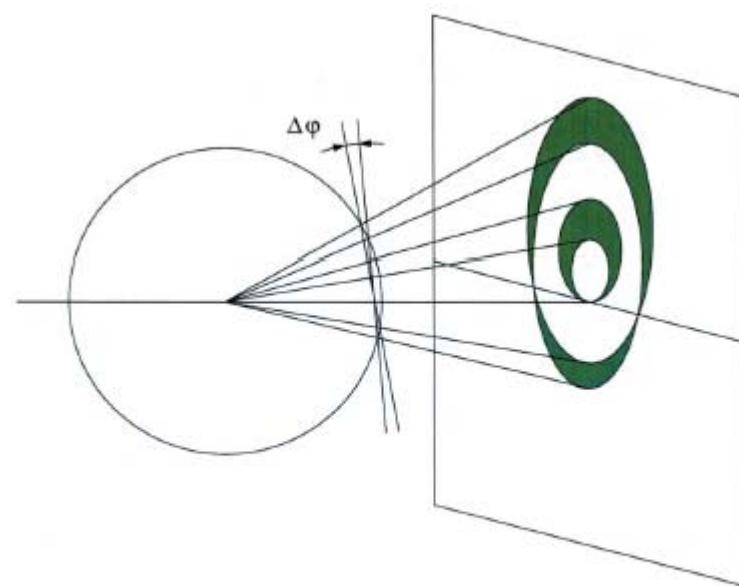
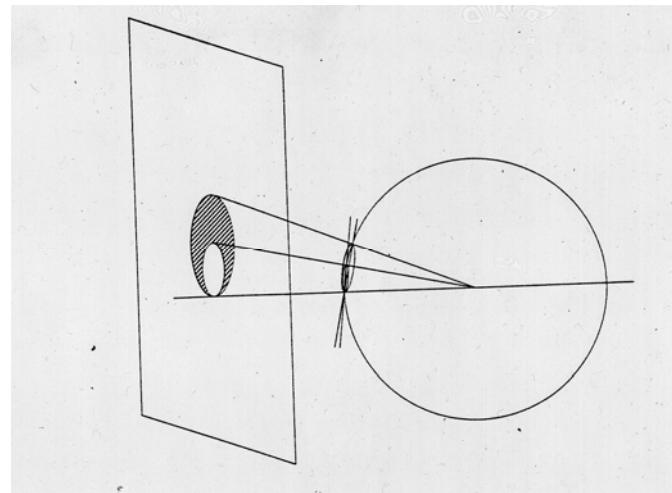




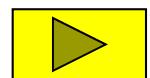
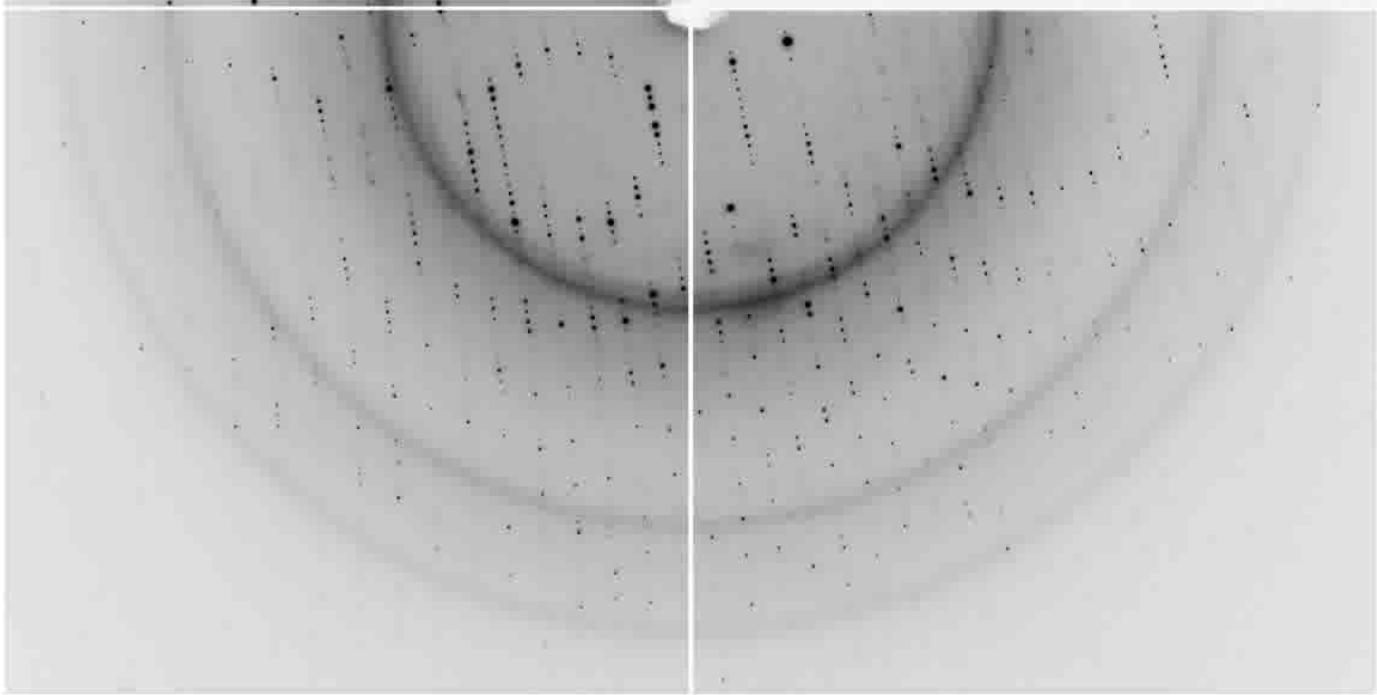
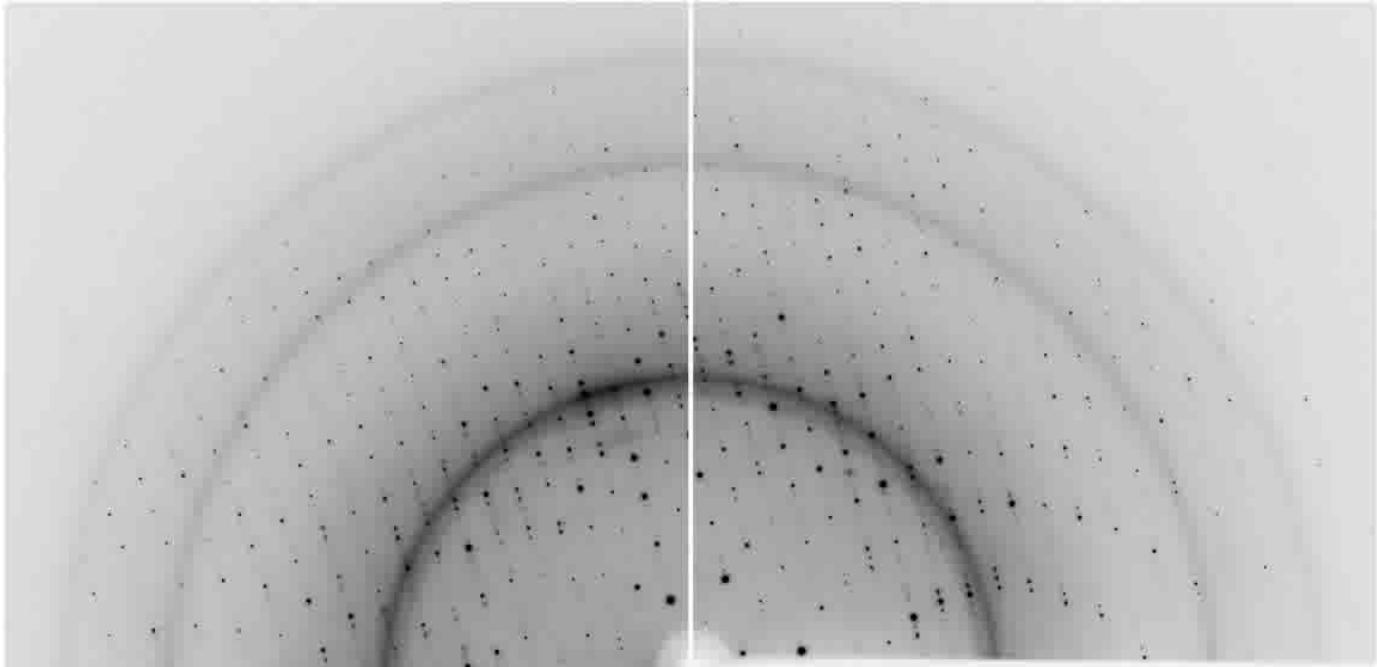
**Figure 3**  
A still exposure with a stationary crystal contains only a small number of reflections arranged in a set of narrow ellipses.

© Zauter, (1997) ,Methods in Enzymology, Vol 276  
Reproduction ULP Strasbourg. Autorisation CFC-Paris

© Zauter, (1999) , Acta Cryst., D55, 1703-1717  
Reproduction ULP Strasbourg. Autorisation CFC-Paris



**Figure 4**  
When the crystal is rotated, reflections from the same plane in the reciprocal lattice form a lune, limited by two ellipses corresponding to the start and end positions.

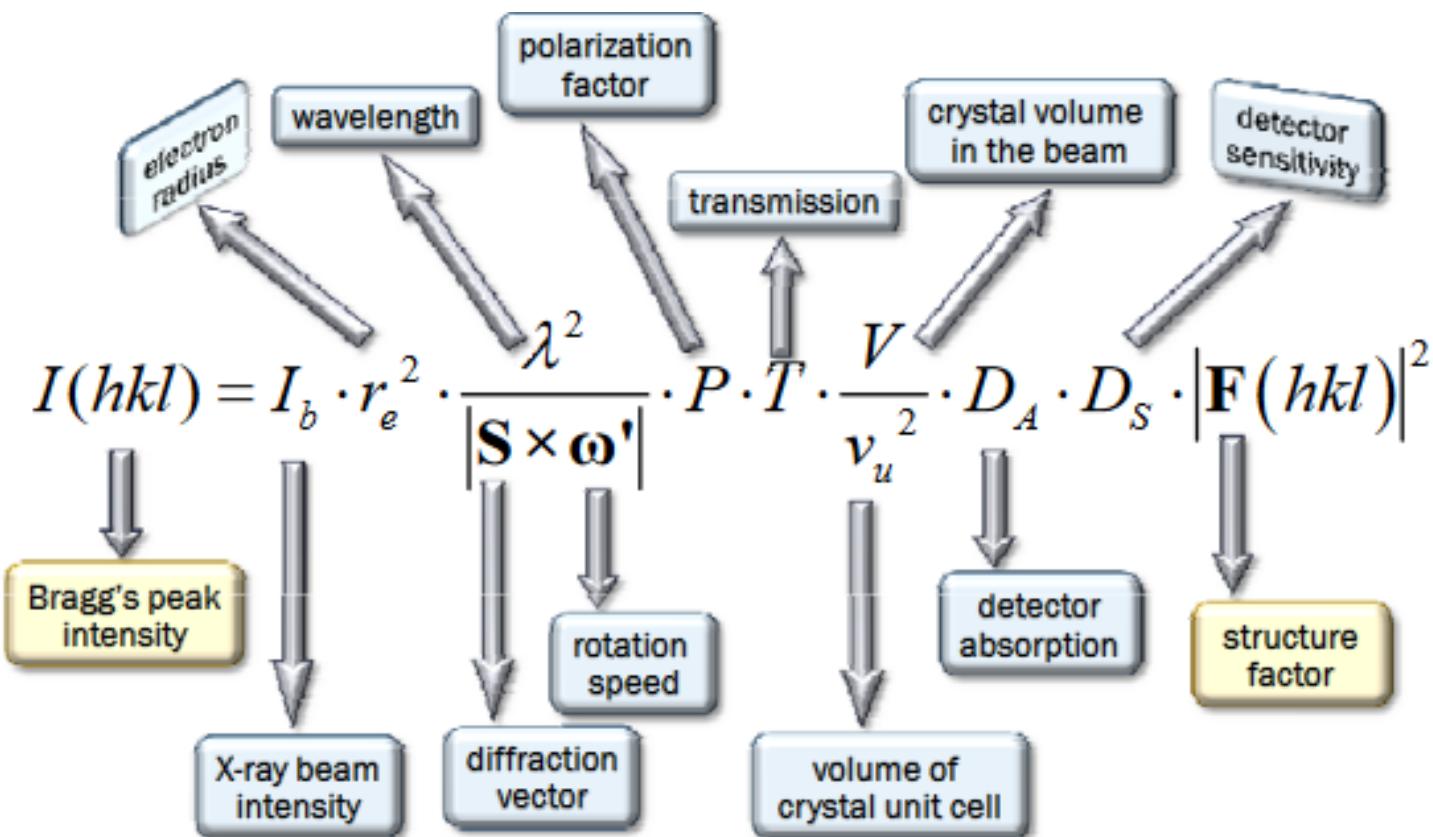


# Méthode d'oscillation

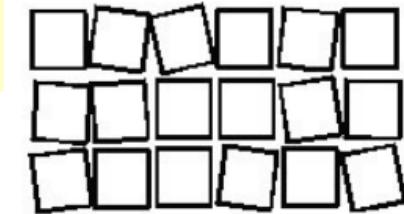
Enregistrement du signal pendant toute la durée du passage du volume à travers la sphère d'Ewald

$$I_{hkl} = \int \text{énergie reçue}$$

Pour un cristal parfaitement mosaïque

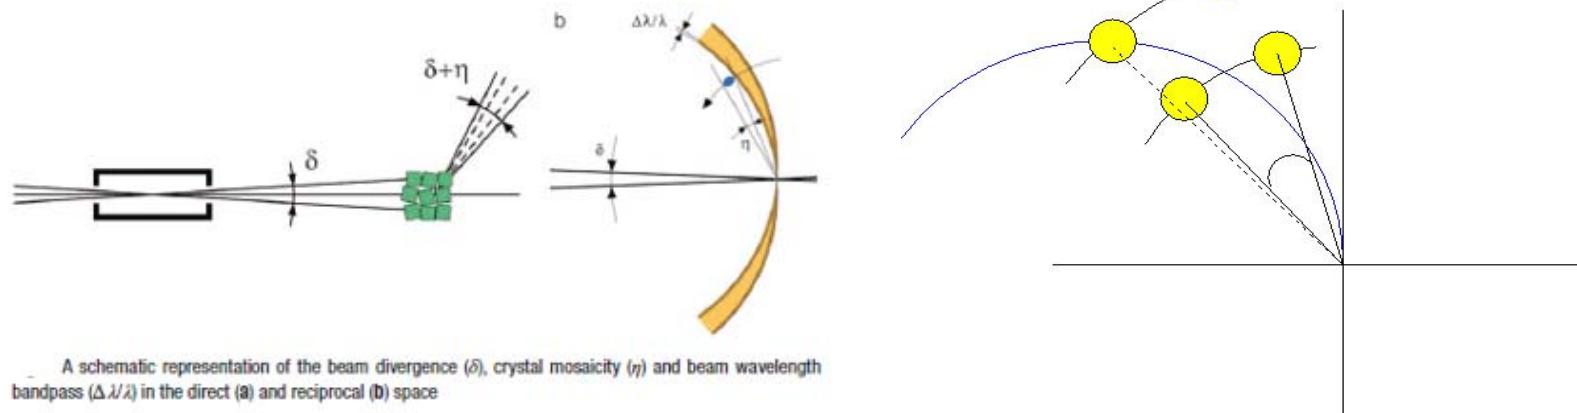


# Méthode d'oscillation

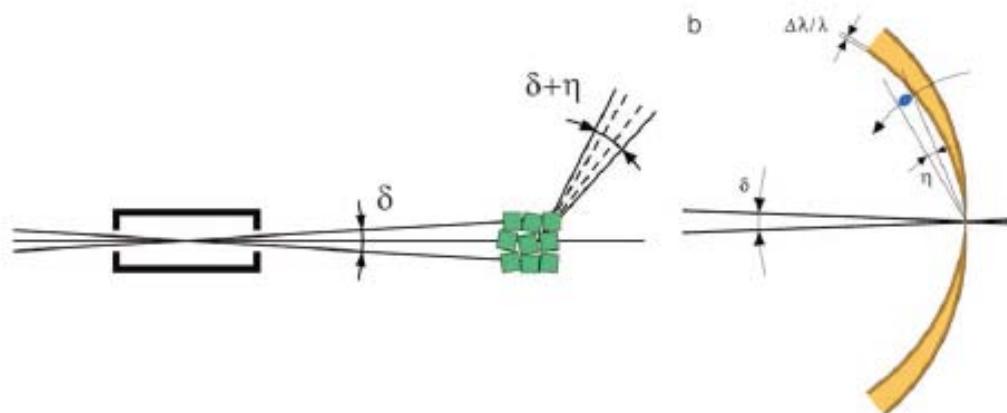


- Les réflexions sont en position de diffraction sur un certain domaine angulaire qui dépend :
  - **mosaïcité du cristal**
    - organisation du cristal en petits domaines cristallins désorientés les uns par rapport aux autres
  - **caractéristiques du faisceau de rayons X incidents**
    - divergence, dispersion en longueur d'onde, optique
- Modèle simple. Volume sphérique, de rayon  $\varepsilon$

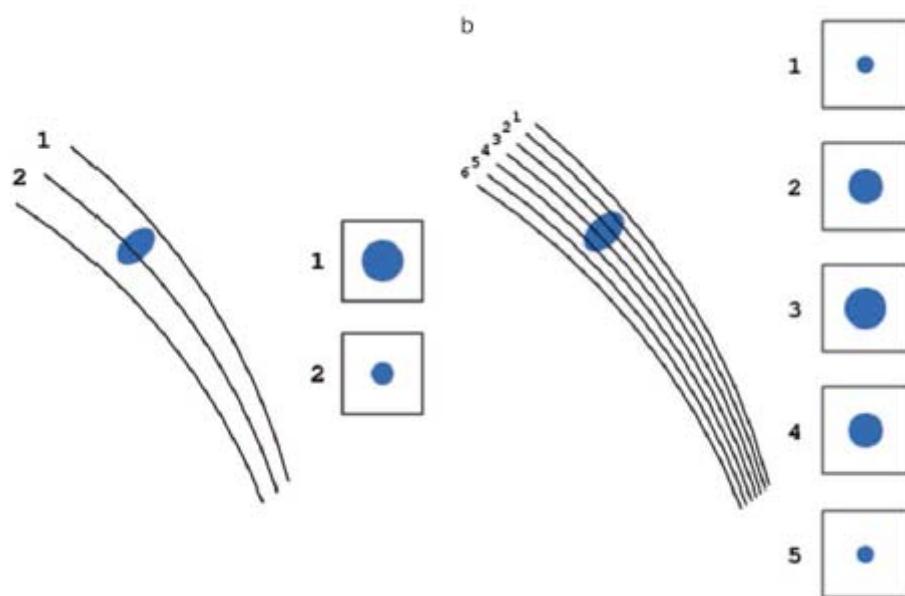
$$\varepsilon \approx (1/2) \Delta d^* \cos\theta$$



A schematic representation of the beam divergence ( $\delta$ ), crystal mosaïcity ( $\eta$ ) and beam wavelength bandpass ( $\Delta\lambda/\lambda$ ) in the direct (a) and reciprocal (b) space

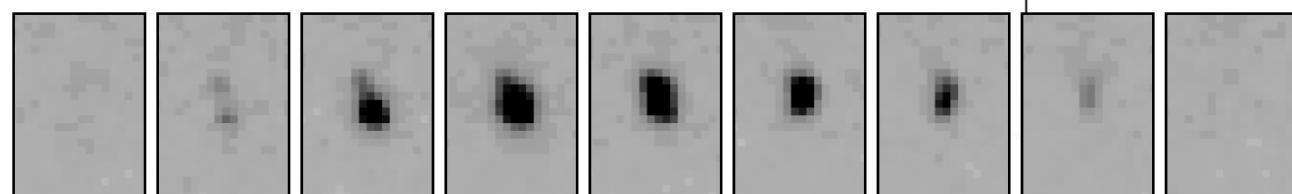
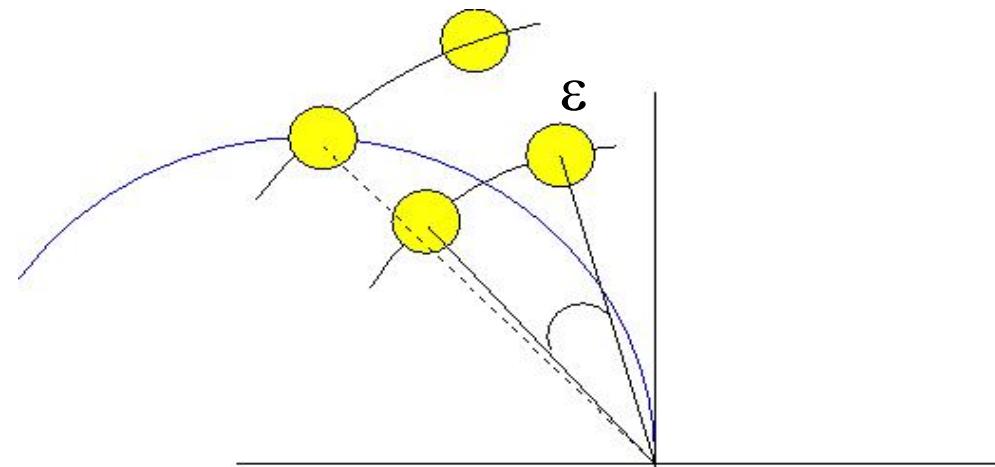
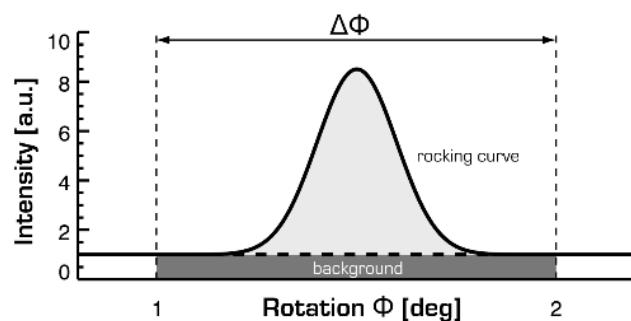


A schematic representation of the beam divergence ( $\delta$ ), crystal mosaicty ( $\eta$ ) and beam wavelength bandpass ( $\Delta\lambda/\lambda$ ) in the direct (a) and reciprocal (b) space

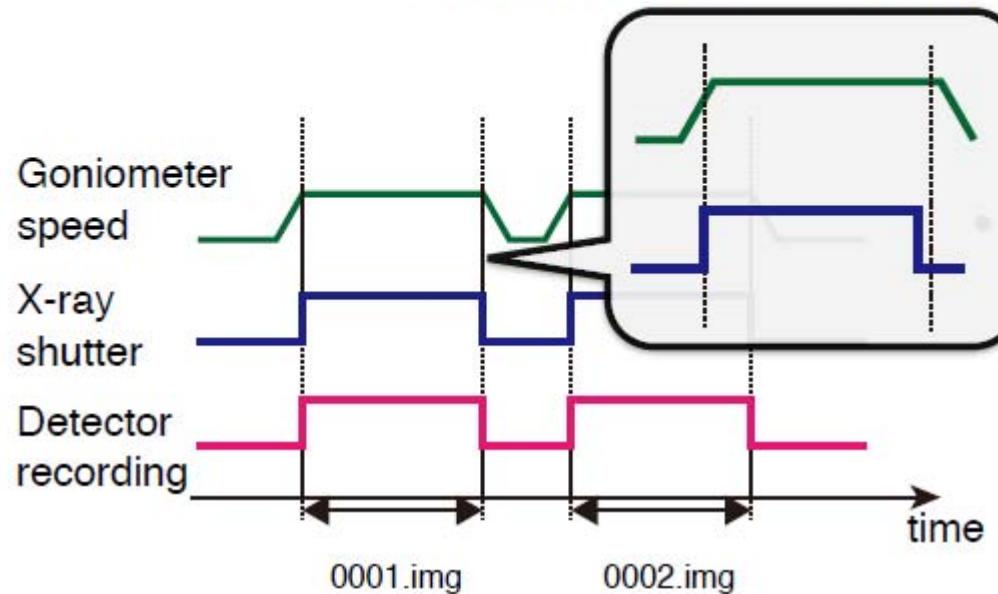


2 types de réflexions sur le cliché de diffraction :

- Réflexions entières
- Réflexions partielles

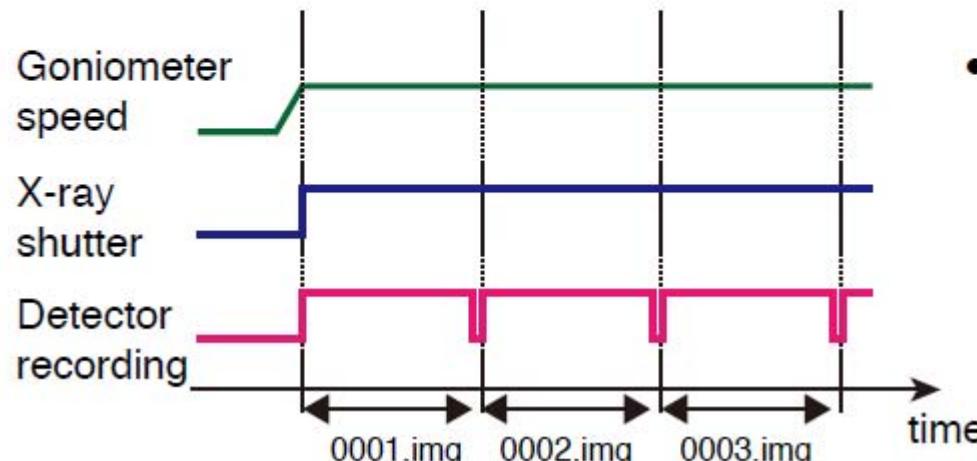


# What is 'shutterless'?



With-shutter data collection

- Slow.
- Goniometer/X-ray shutter synchronization error and shutter jitter may exist.



• Shutterless data collection

- Fast.
- No mechanical error.
- Requires detector with ignorable readout time.

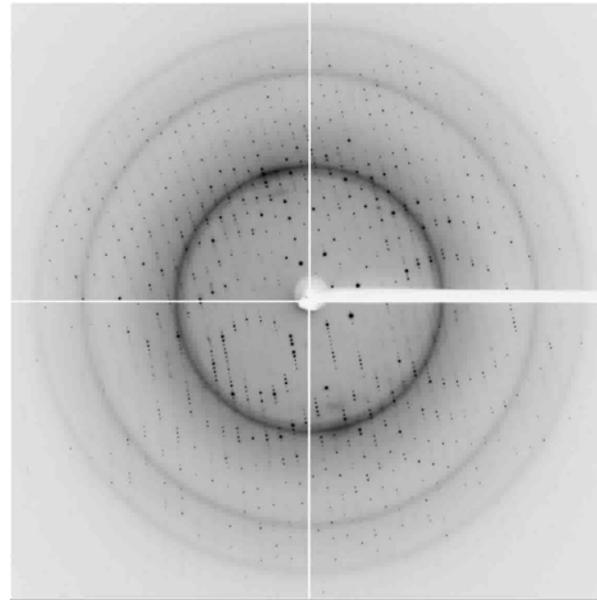
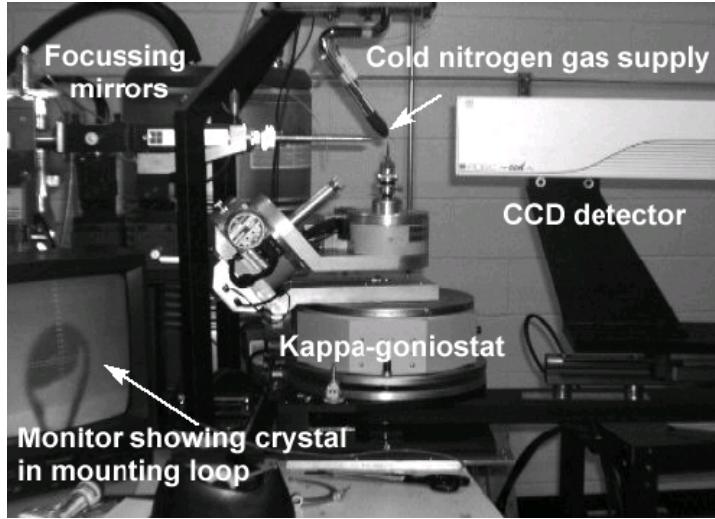
## La collecte des données

- **Un moment crucial :**
  - Obtenir un espace complet de diffraction sur toute la gamme de résolution
  - Des mesures précises et de qualité
- **Des choix et des compromis, des décisions à prendre rapidement :**
  - Paramètres géométriques de l'enregistrement
  - Domaine à enregistrer en priorité mais obtenir aussi la redondance maximale
  - Angle d'oscillation
  - Temps d'exposition
  - Un cristal à durée de vie limitée

Optimization of data collection taking radiation damage into account.

**Bourenkov GP, Popov AN.**

Acta Crystallogr D Biol Crystallogr. 2010 Apr;66(Pt 4):409-19. doi: 10.1107/S0907444909054961.



Data collection, especially at synchrotron sites, is the time where you may solve your structure in a few minutes or destroy months (or years) of work and waste a lot of money in a few seconds. **Be prepared !**

Crystallographic programs are now very easy to use, require few parameters but are based on complicated algorithms.

**Try to understand what is going on and where crucial decisions need to be done**

It may be fast to build 90% of a structure but it will take a longer time to finish the last 10%.

## Quelques logiciels :

- Denzo - HKL2000/HKL3000
  - <http://www.hkl-xray.com/>
- Mosflm (CCP4)
  - <http://www.mrc-lmb.cam.ac.uk/harry/mosflm>
- XDS
  - <http://xds.mpimf-heidelberg.mpg.de/>



Le traitement des données est de plus en plus intégré à la collecte.  
Résultats peu de temps (qq mn) après la collecte.

## Pipelines

Xia2 (CCP4)

```
xia2 pipeline=3d /here/are/my/images
```

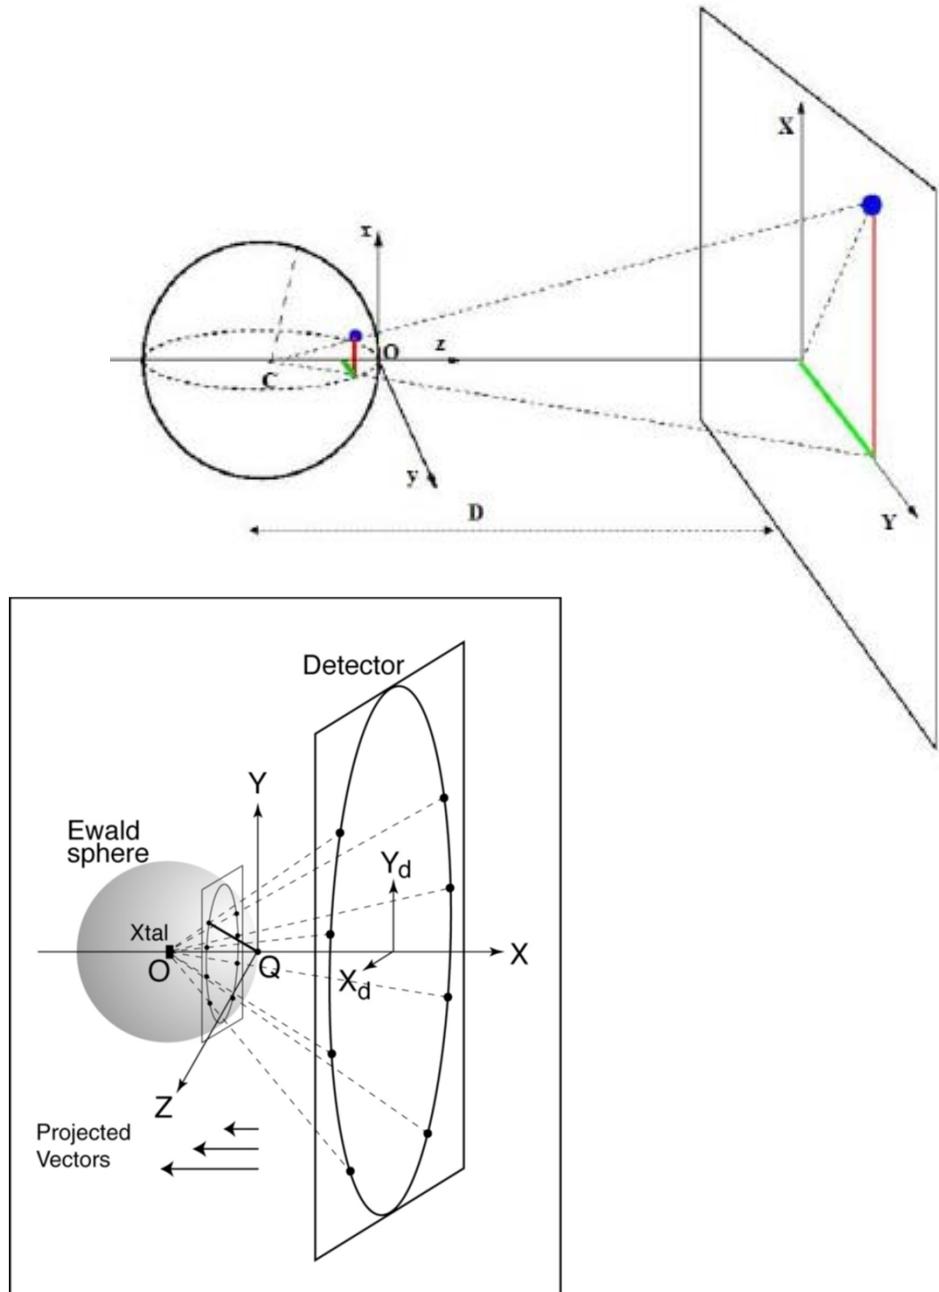
autoPROC (GlobalPhasing Ltd)

```
process -I /where/ever/images -d sub.dir > out.put
```

[http://jean.cavarelli.free.fr/igbmc/lab\\_services/xray\\_progs.html](http://jean.cavarelli.free.fr/igbmc/lab_services/xray_progs.html)

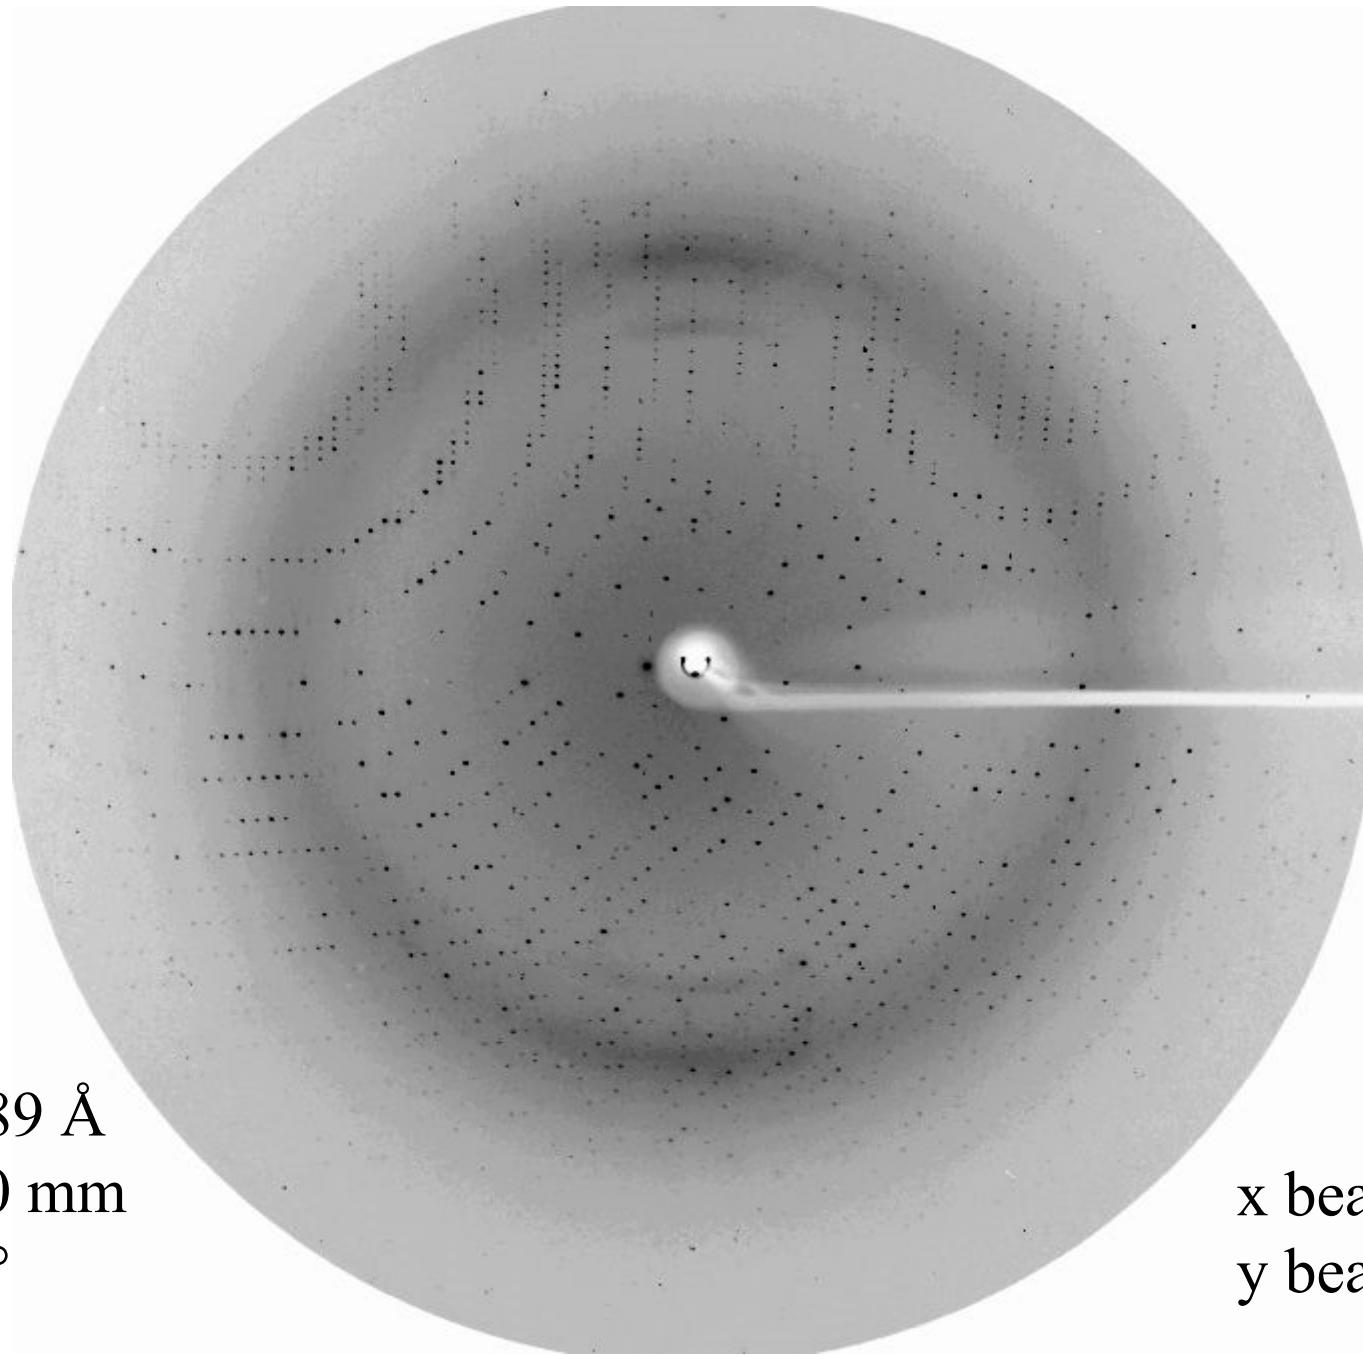
## Traitements des données de diffraction

1. Inspection visuelle d'une image de diffraction
2. Indexation initiale
3. Choix des paramètres optimaux d'enregistrement
4. Collecte d'un espace complet de diffraction
5. Affinement des paramètres  
$$\sum ((P,Q)^{hkl}_{\text{calc}} - (P,Q)^{hkl}_{\text{obs}}) = f(\text{param}(i), i=1,n)$$
6. mesures des intensités par cliché
7. Mises à l'échelle
8. Réduction des données, statistiques, erreurs
  - Réflexions équivalentes
  - Extinctions
9. Résultats



$$\vec{S} = \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \frac{1}{\lambda} \begin{pmatrix} \frac{X_d}{\sqrt{X_d^2 + Y_d^2 + D^2}} \\ \frac{Y_d}{\sqrt{X_d^2 + Y_d^2 + D^2}} \\ \frac{D}{\sqrt{X_d^2 + Y_d^2 + D^2}} - 1 \end{pmatrix}$$

$$\begin{pmatrix} x \\ y \\ z \end{pmatrix} = [A] \begin{pmatrix} h \\ k \\ l \end{pmatrix}$$

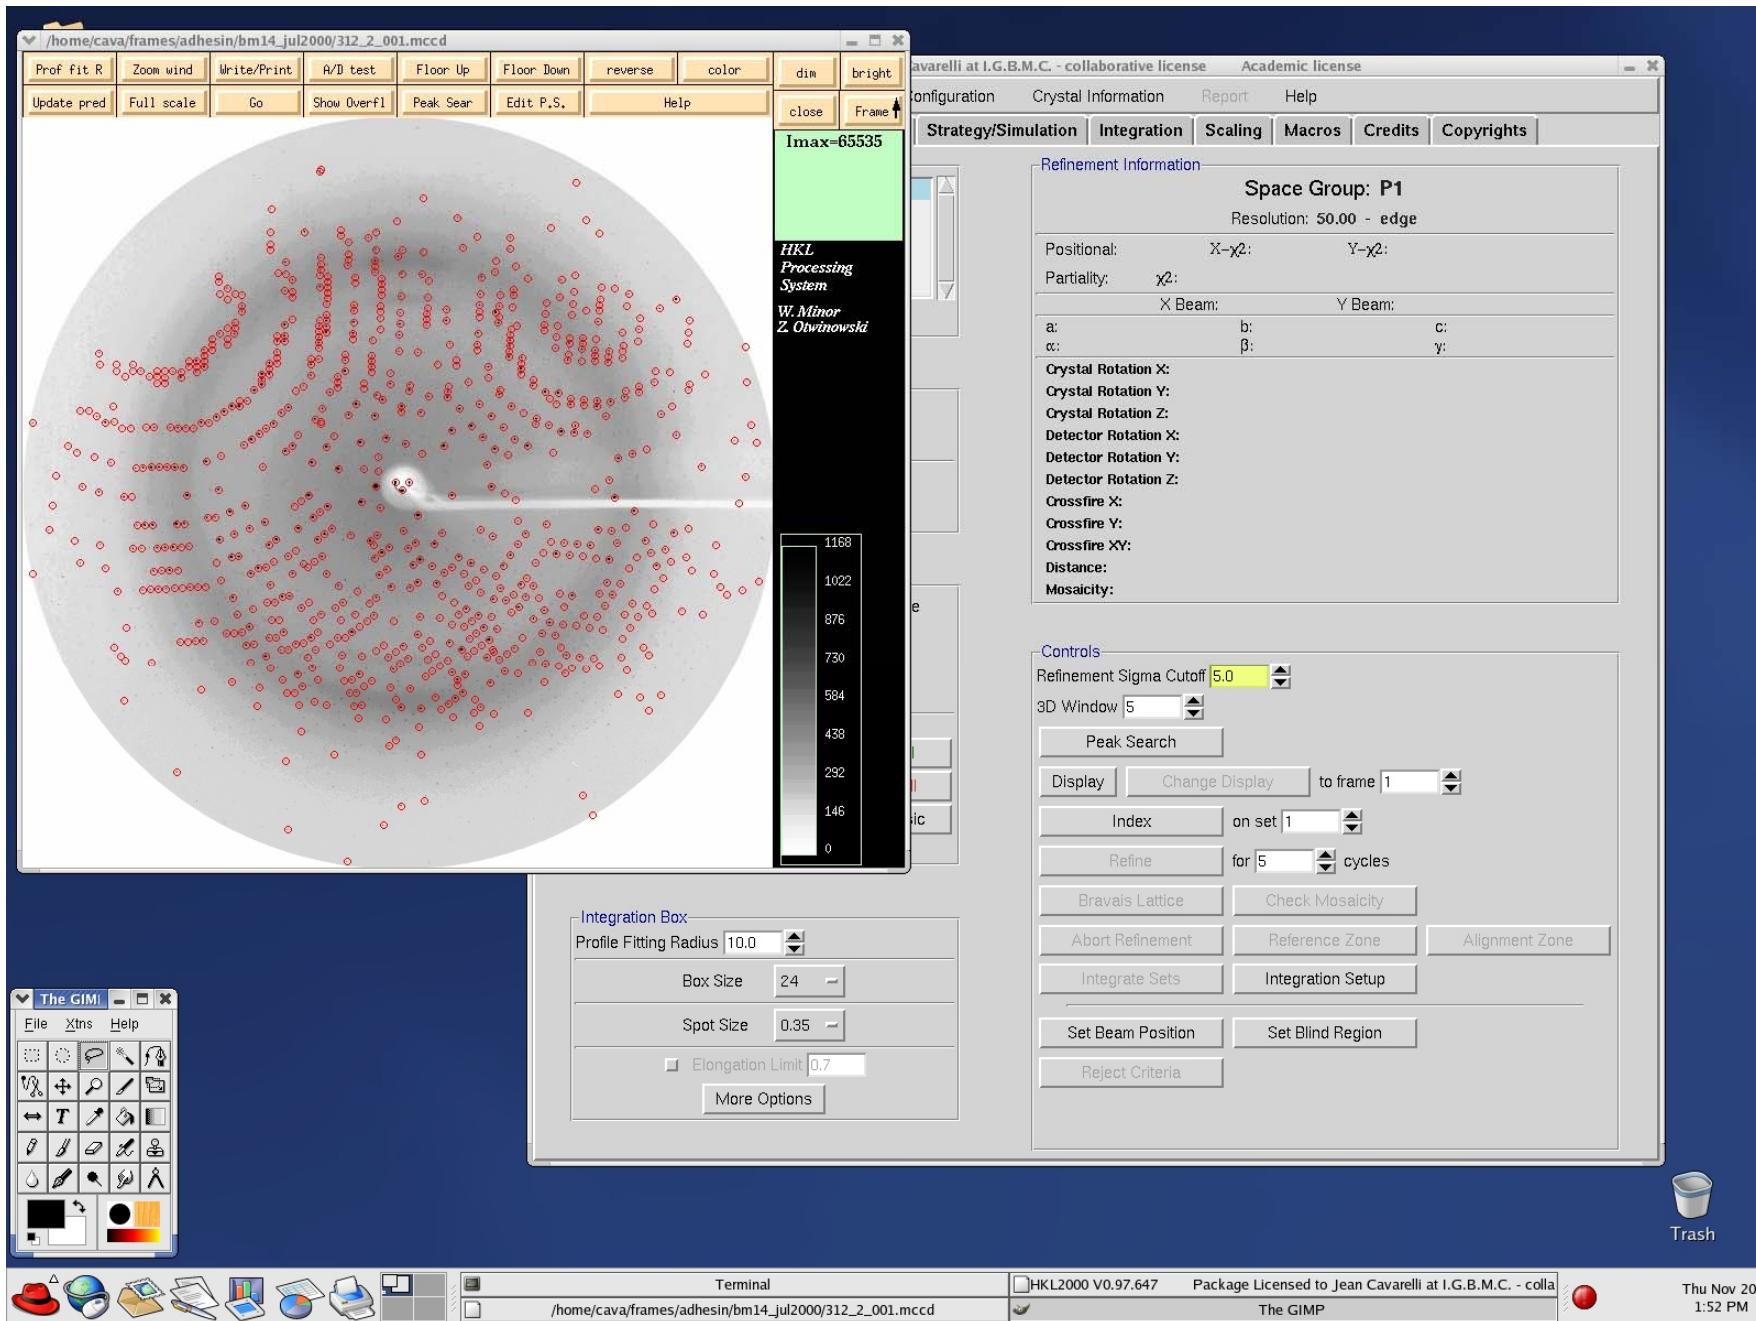


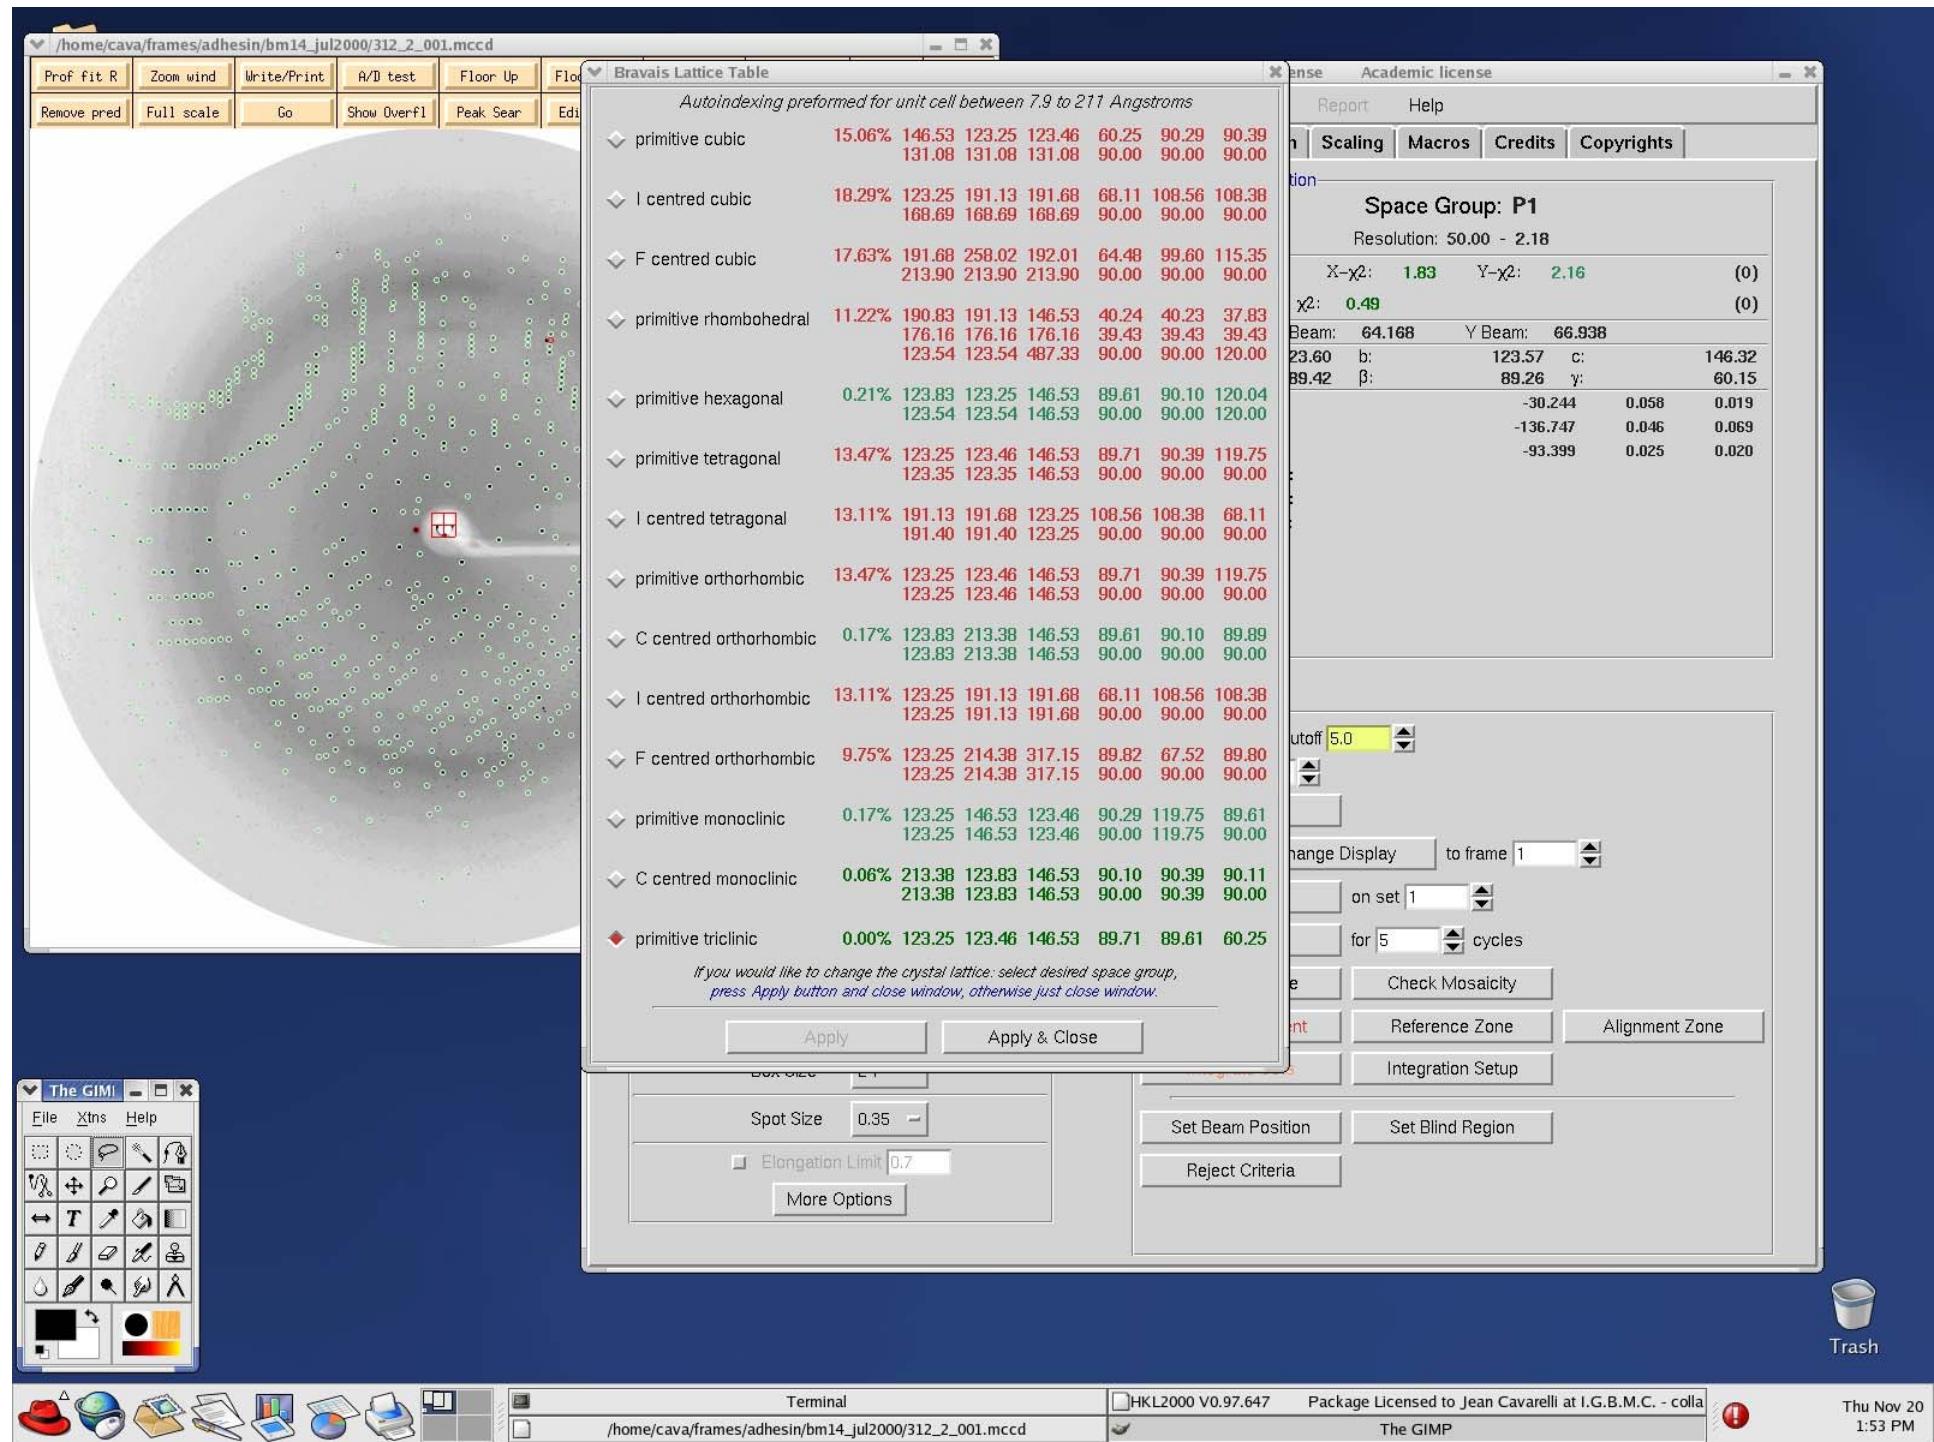
$\lambda = 0.9789 \text{ \AA}$

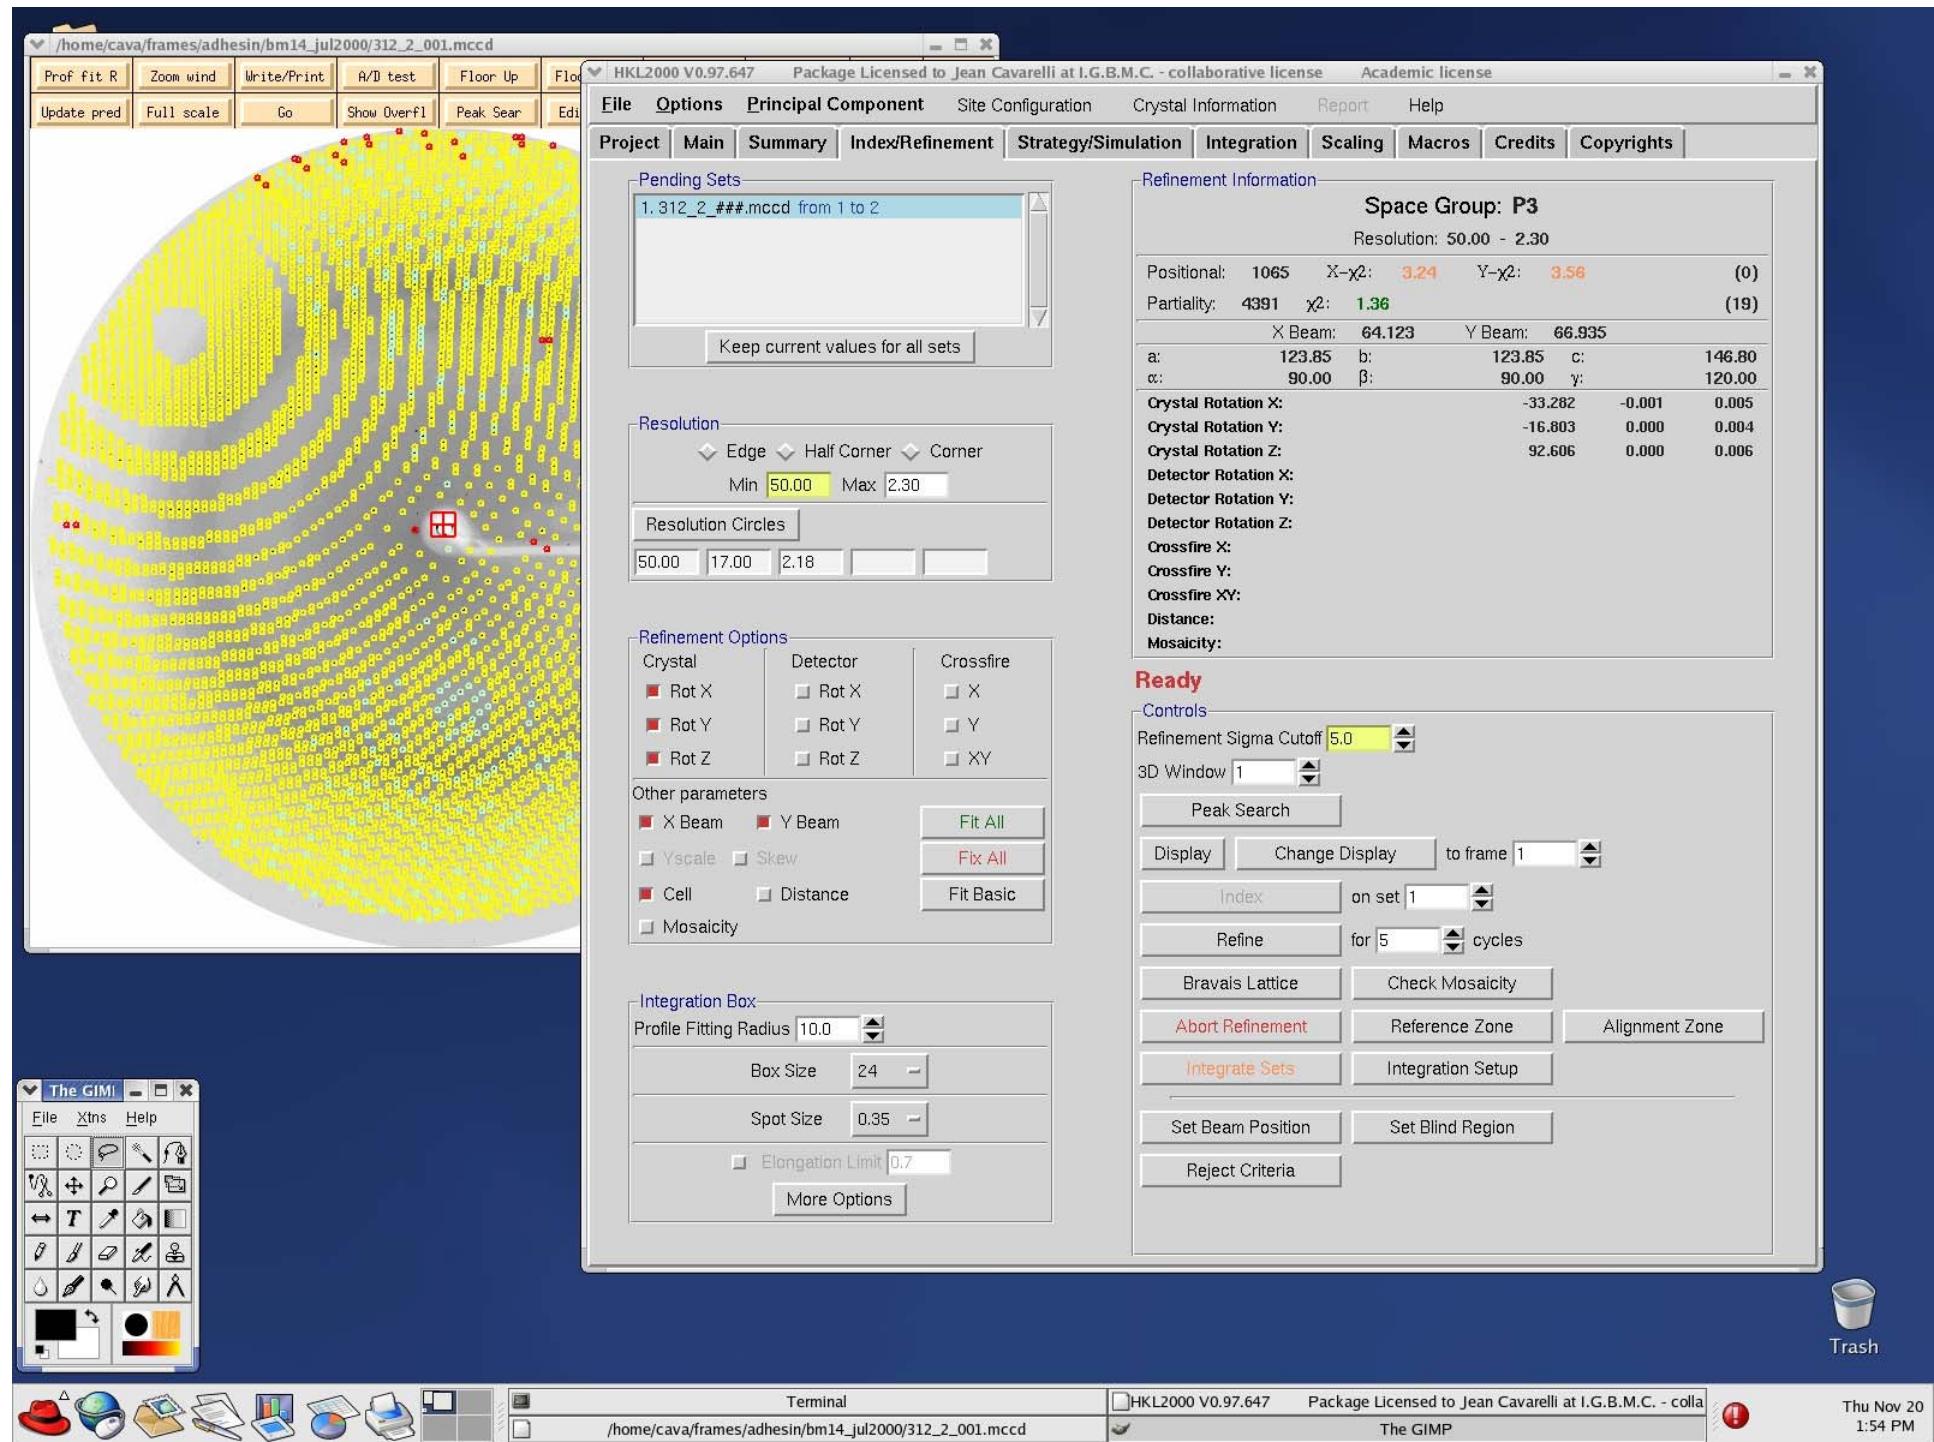
DF = 140 mm

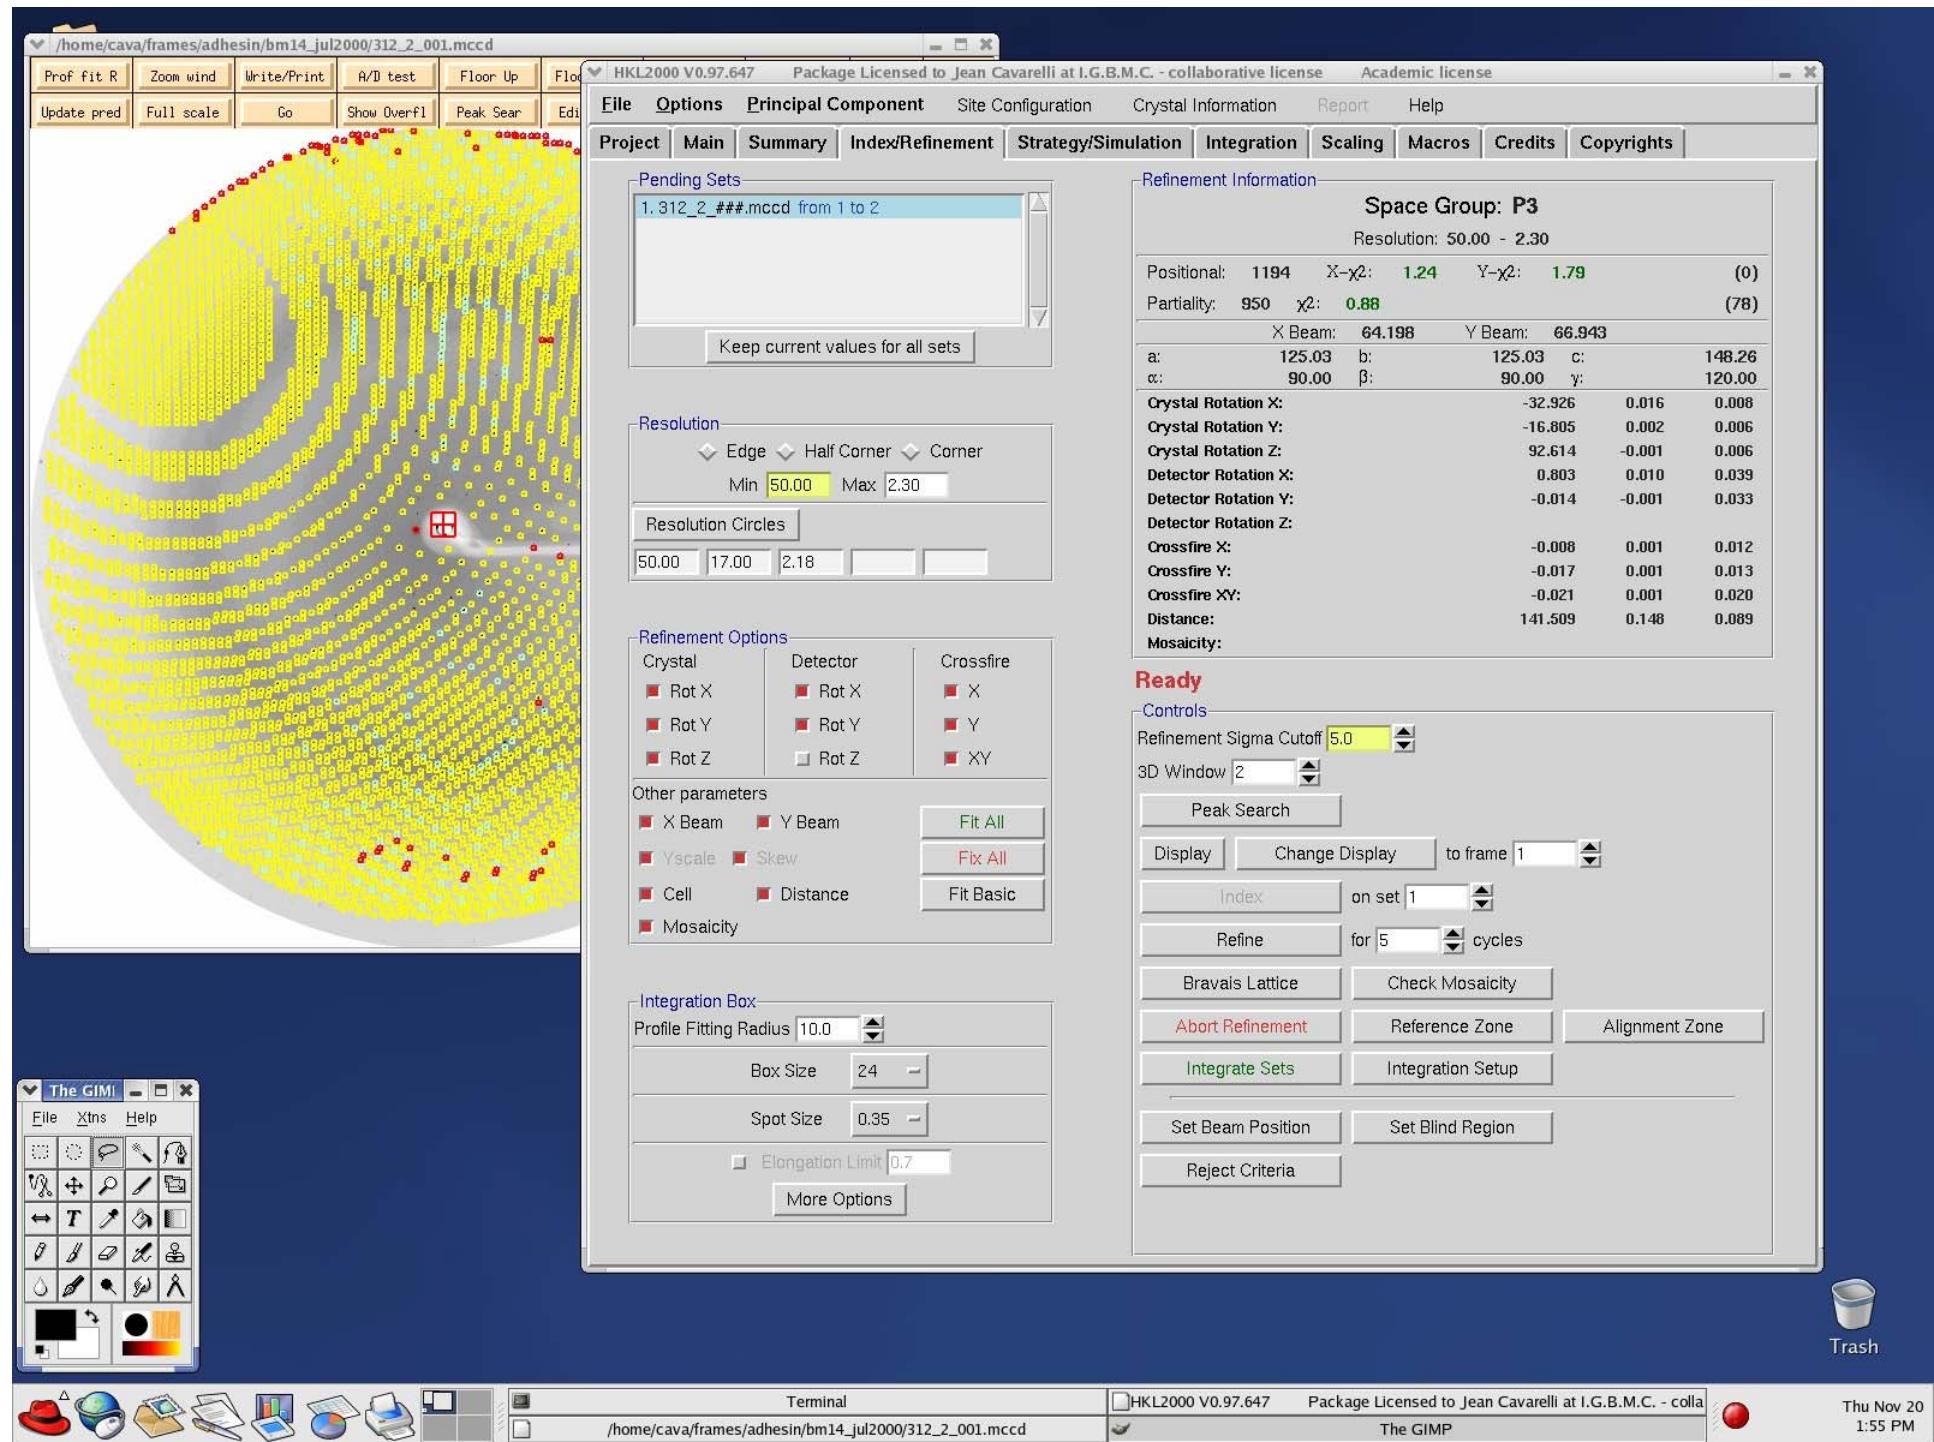
$\Delta\phi = 0.7^\circ$

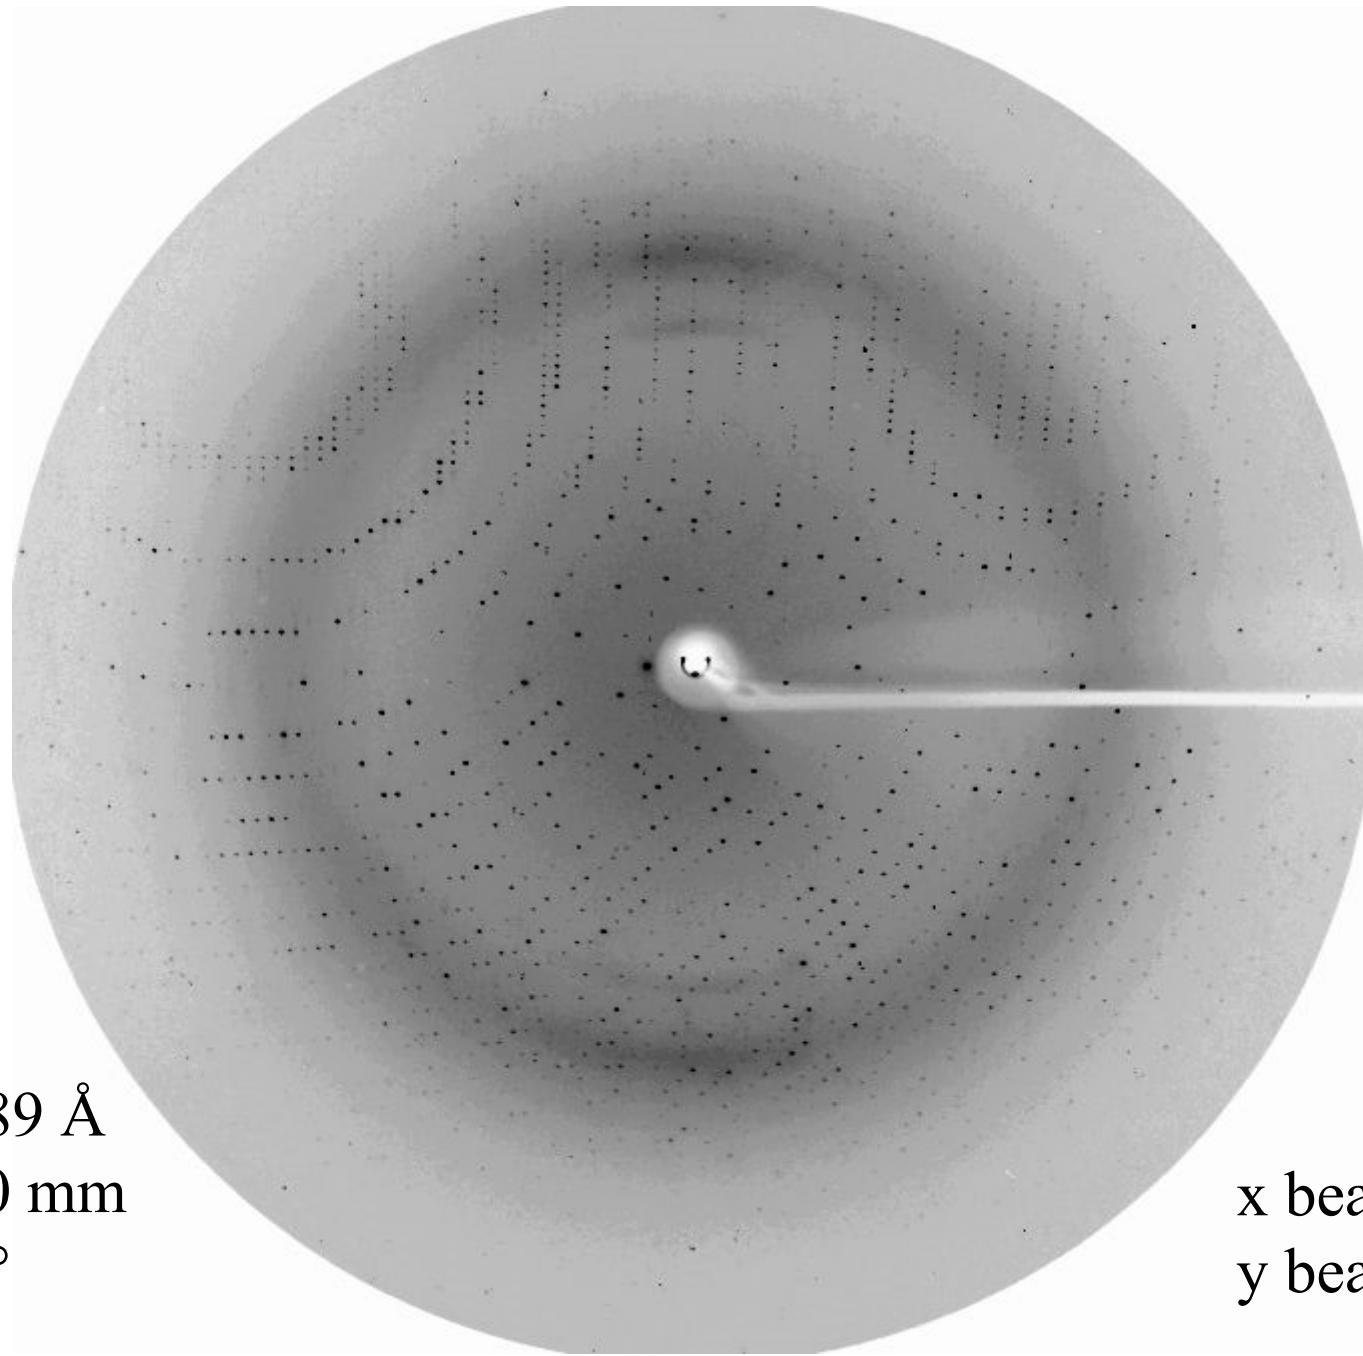
x beam 64.1  
y beam 66.9









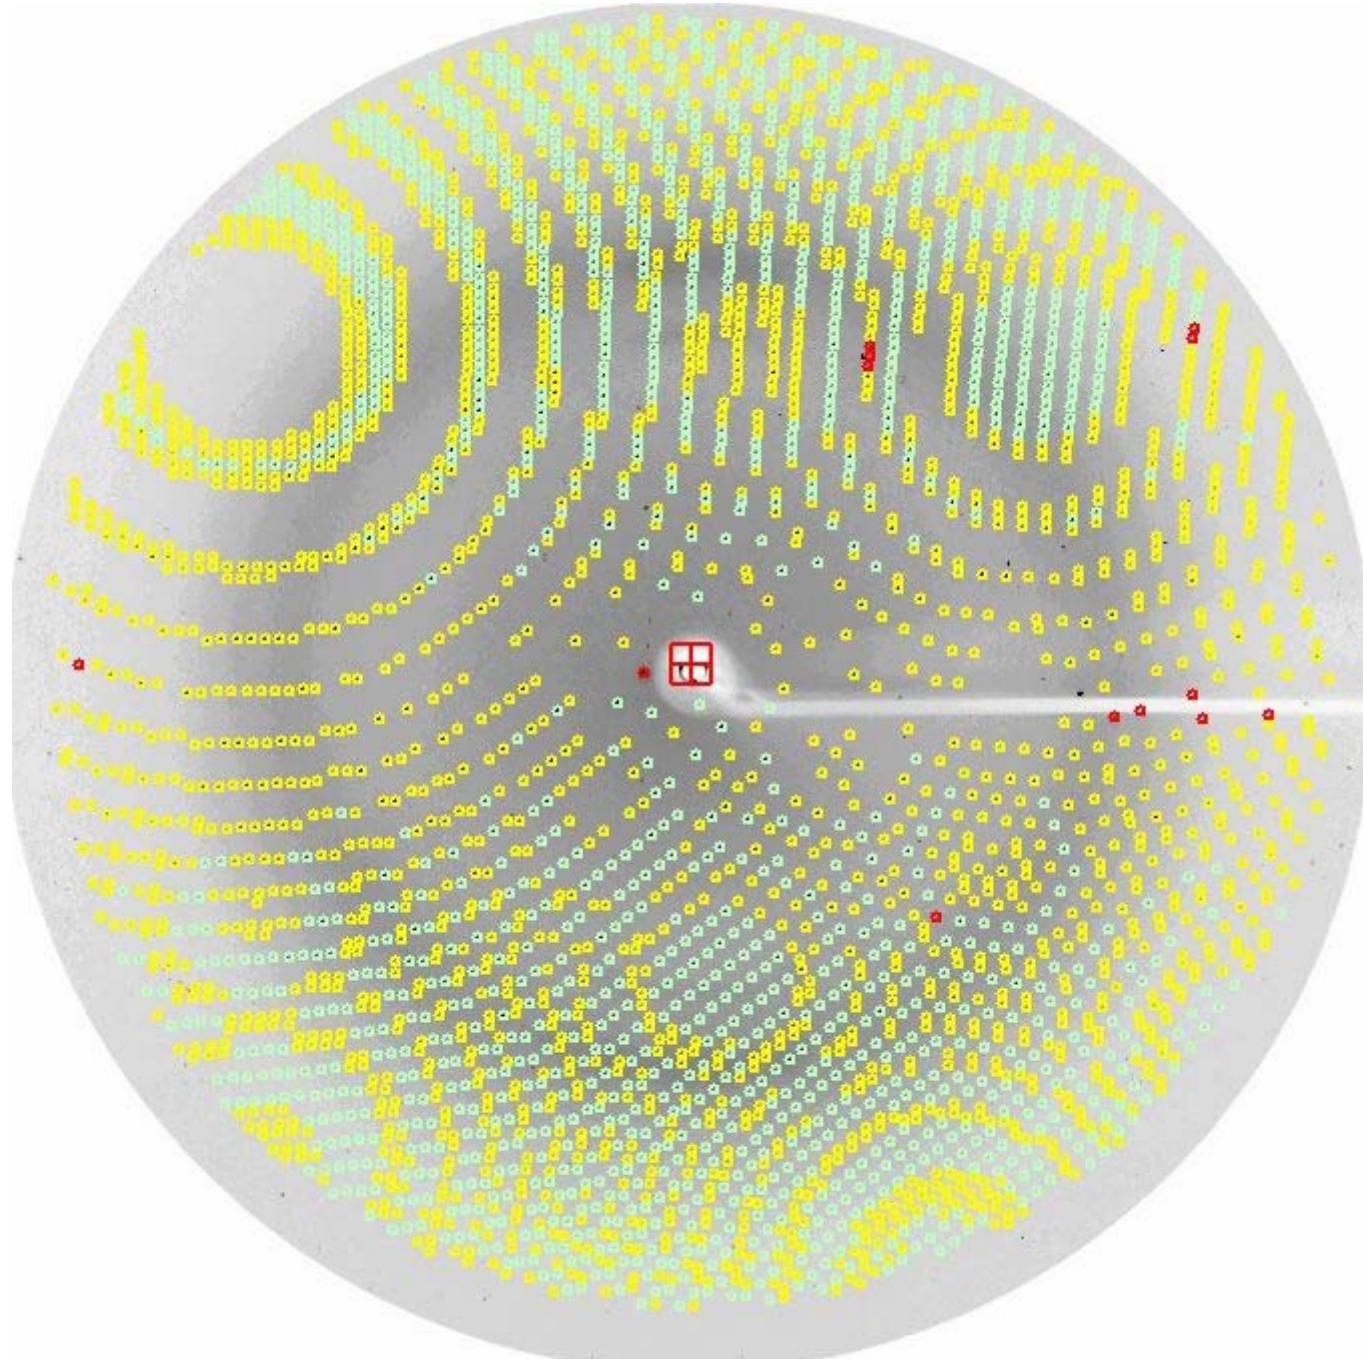


$\lambda = 0.9789 \text{ \AA}$

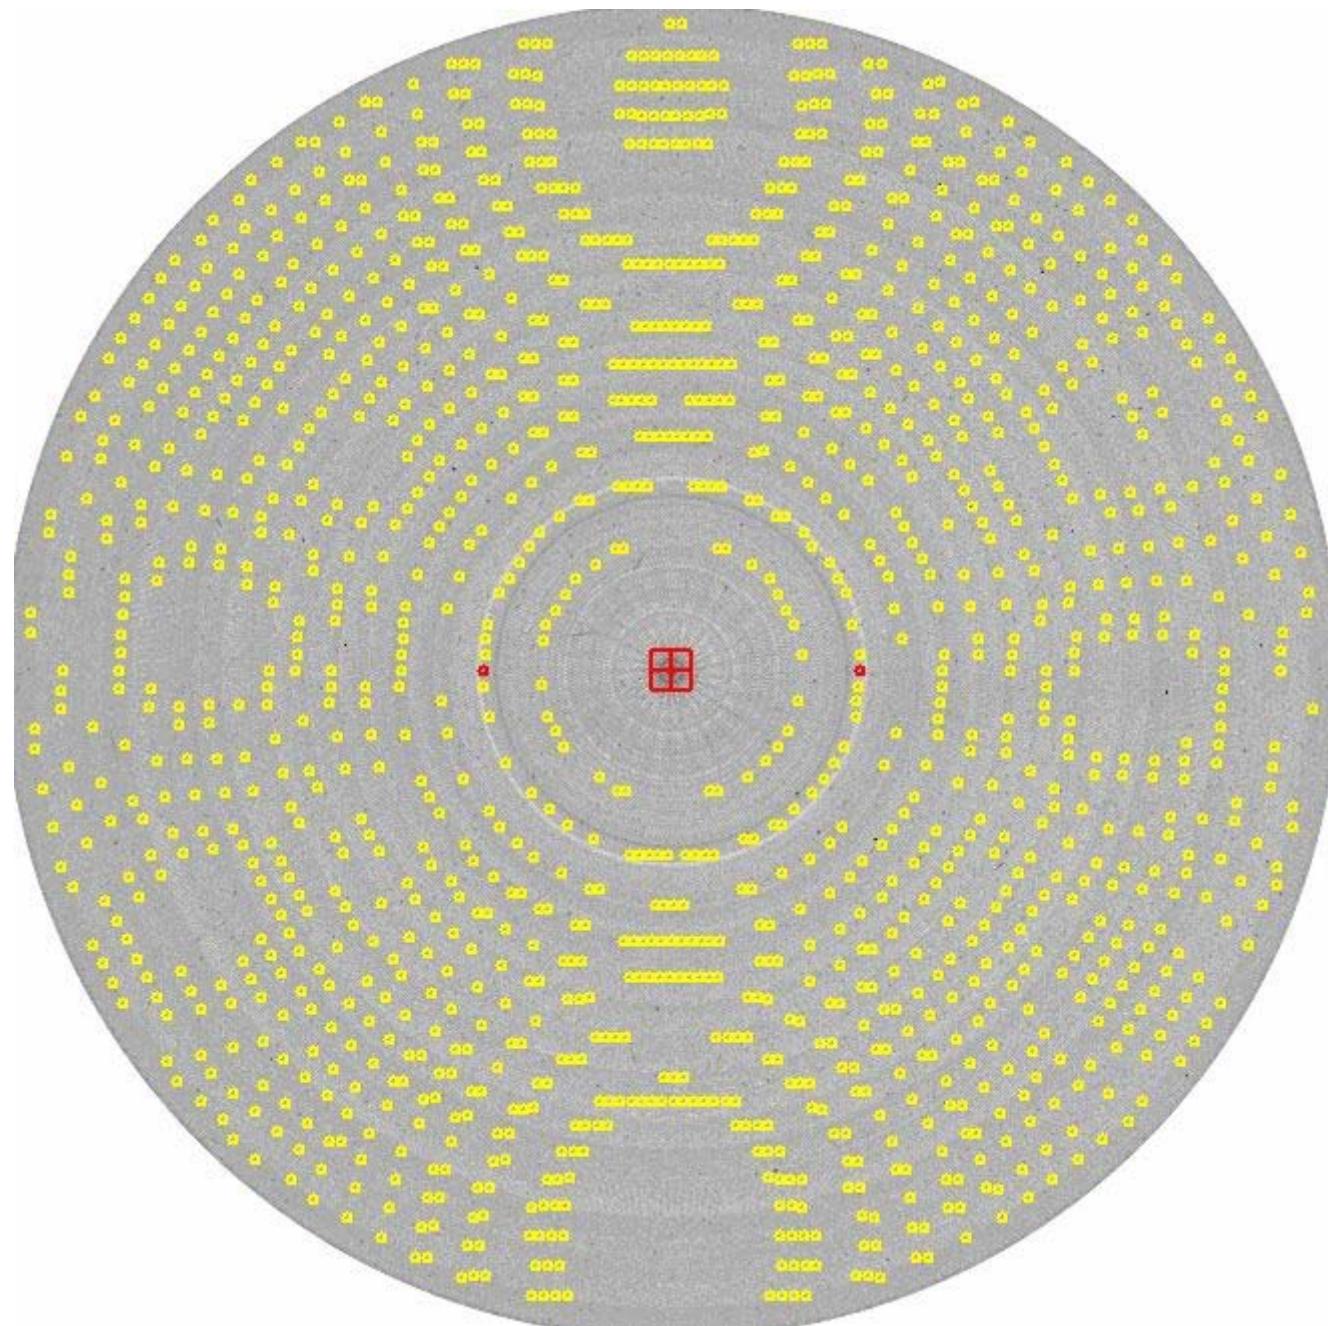
DF = 140 mm

$\Delta\phi = 0.7^\circ$

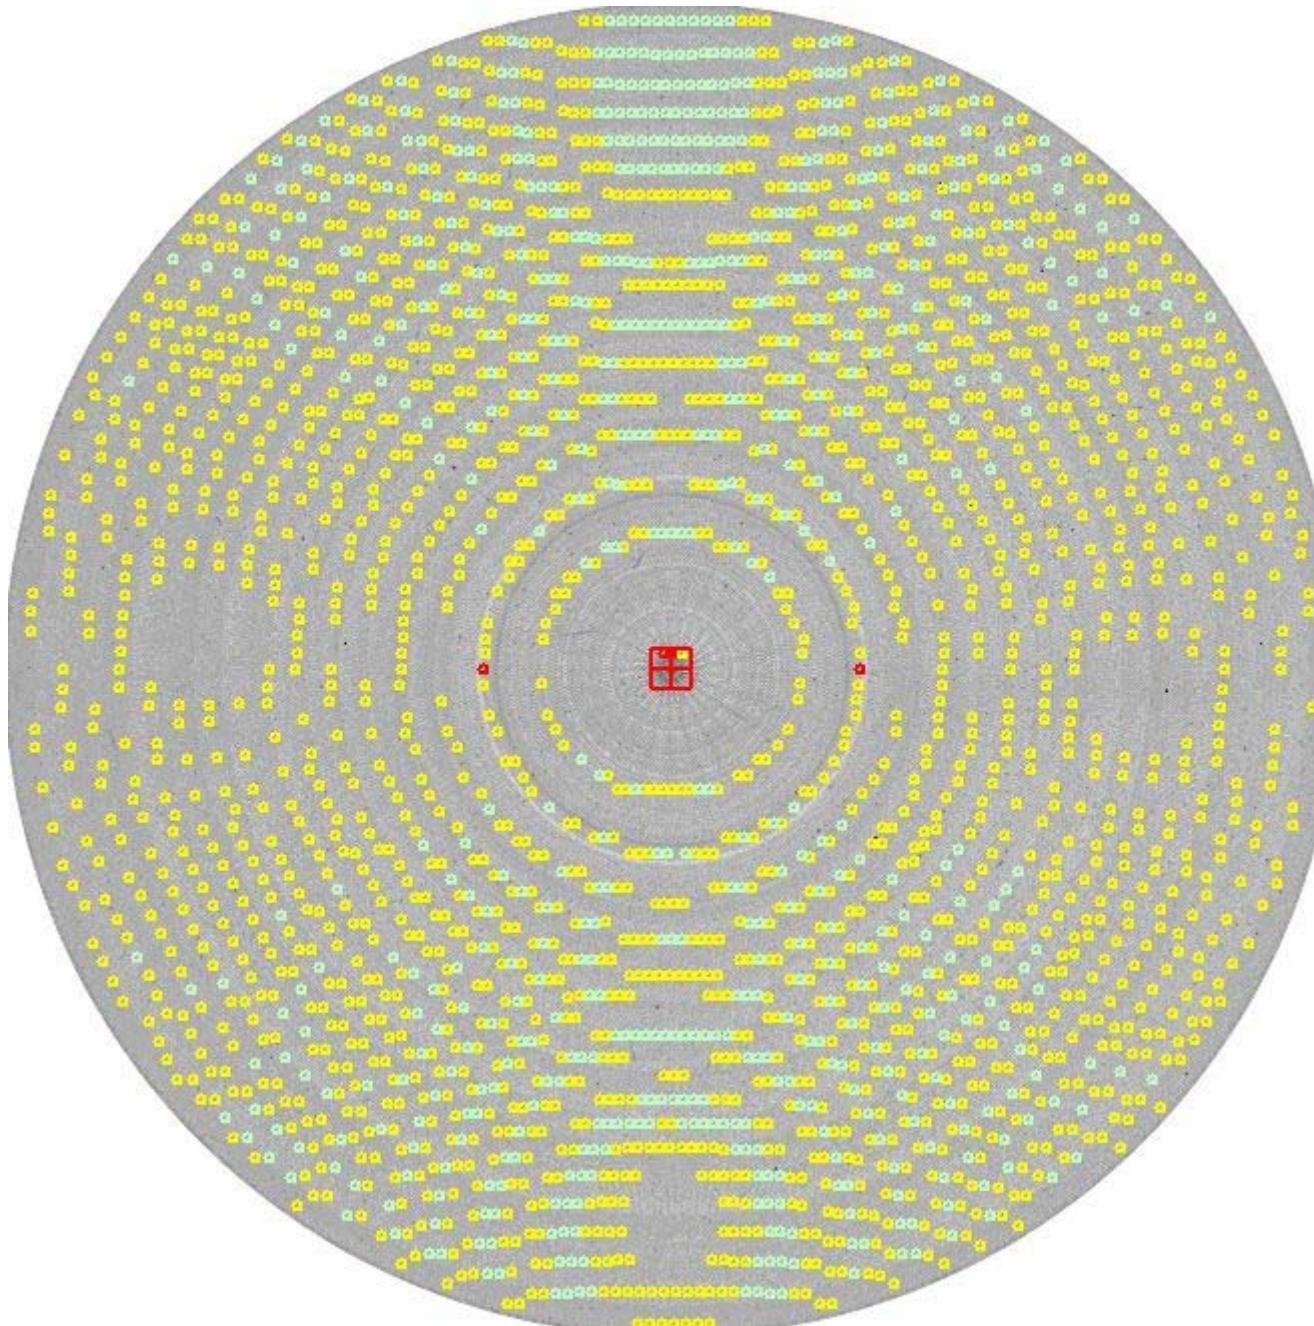
x beam 64.1  
y beam 66.9



$\Delta\phi = 0.2^\circ$



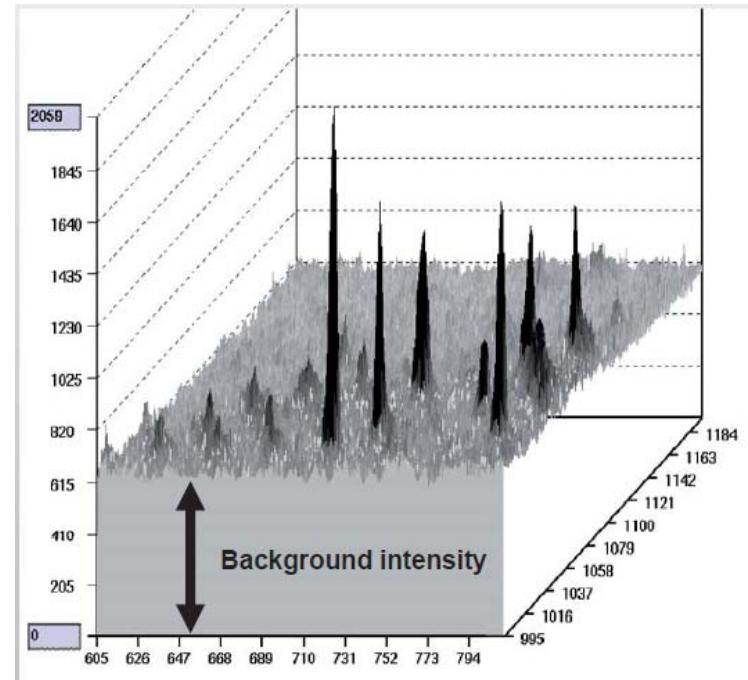
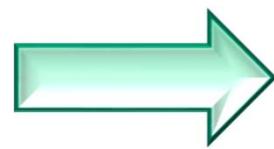
$\Delta\phi = 0.7^\circ$



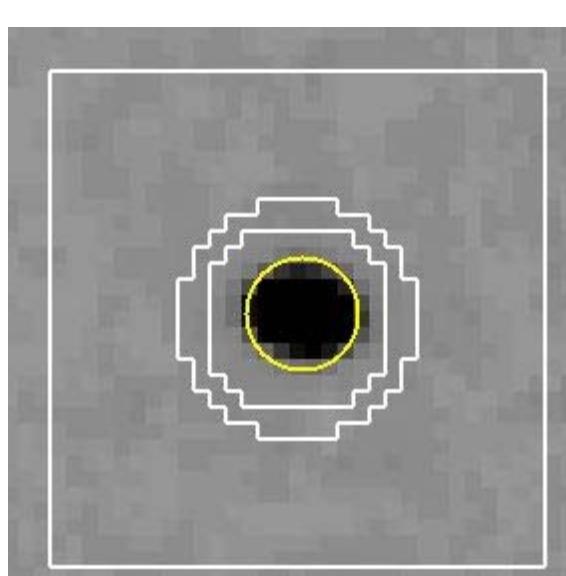
# Traitements des données de diffraction

1. Inspection visuelle d'une image de diffraction
2. Indexation initiale
3. Choix des paramètres optimaux d'enregistrement
  - Domaine angulaire à couvrir
  - Angle d'oscillation
  - Distance cristal détecteur
  - Temps d'exposition
4. **Collecte d'un espace complet de diffraction**
5. Affinement des paramètres
$$\sum ((P,Q)^{hkl}_{\text{calc}} - (P,Q)^{hkl}_{\text{obs}}) = f(\text{param}(i), i=1,n)$$
4. mesures des intensités par cliché (**Intégration 2D ou 3D**)
  - Méthode du profil "Profil fitting"
5. Mises à l'échelle
6. Post-Affinement
7. Réduction des données, statistiques, erreurs
8. Résultats

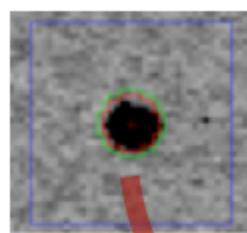
132	131	132	138	142	140	142	140	135	132	133
129	136	145	146	149	155	160	158	148	145	136
125	137	152	162	176	189	198	173	156	155	130
137	149	165	194	246	291	280	225	172	156	128
138	157	184	254	564	1022	997	389	227	164	139
137	150	189	315	2964	9804	10888	803	254	167	140
141	153	185	300	1828	5647	6284	686	251	166	149
140	145	166	236	618	1451	1590	396	217	162	143
129	137	150	181	238	287	284	222	176	153	138
122	132	141	155	175	186	181	167	154	147	138
124	128	135	143	151	158	157	151	145	143	135
127	128	134	135	136	139	143	143	139	130	128



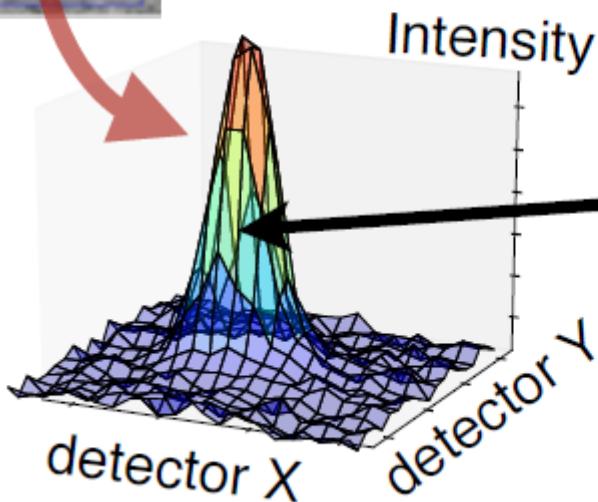
$$|F|^2 \pm \sigma_{|F|^2}$$



450	448	434	422	417	428	446	468	457	465	449	437	416	421	426	432
447	448	441	431	430	443	456	468	458	460	453	447	430	433	444	432
437	442	435	430	439	449	454	463	456	459	454	440	440	435	447	433
437	449	445	443	448	450	450	461	470	469	451	443	449	445	430	431
441	453	459	448	451	462	481	529	557	532	499	471	458	444	432	431
442	448	442	439	464	517	631	829	943	868	734	576	437	471	457	443
435	434	442	453	509	720	1280	2292	3086	2886	1894	935	568	488	461	441
436	443	482	477	567	1043	2438	5174	7991	8070	5185	1918	717	508	466	481
441	453	467	476	599	1040	2501	5452	8365	9846	6745	2509	803	518	463	452
438	447	462	462	493	636	1190	2165	3434	4224	3330	1647	679	514	463	451
415	432	446	449	462	505	612	804	1024	1123	975	703	521	477	456	452
417	440	441	447	459	464	490	531	570	587	543	480	450	448	454	449
437	444	438	448	455	464	460	457	471	466	446	454	444	440	458	454
430	444	436	455	456	453	452	445	448	434	426	433	440	436	452	453
420	434	438	446	455	460	452	455	453	421	408	425	434	435	442	433
423	427	429	430	436	444	455	463	447	422	414	431	445	447	443	449



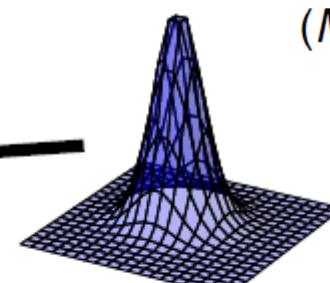
Bragg peak



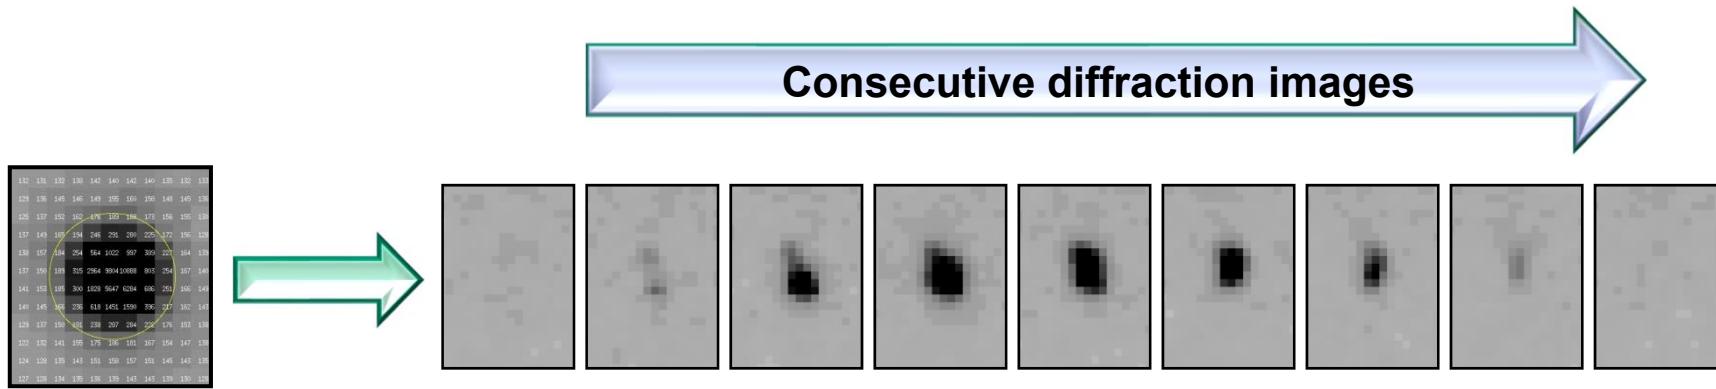
Fit

## 2D profile

(MOSFLM, DENZO)



Reference  
profile



**Indexing =  
Assigning hkl  
index to each  
reflection**

*hkl*

**Merging = Combining intensities  
for symmetrically equivalent  
reflections**

$$\langle I_{hkl} \rangle \pm \sigma_{\langle I_{hkl} \rangle}$$

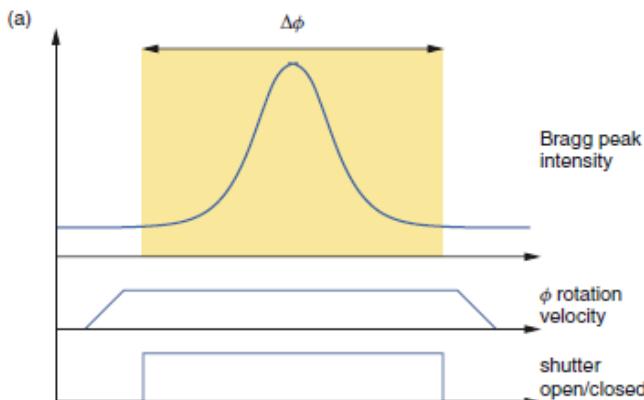
**Integration = Calculating intensities and their  
uncertainties and adding intensities between  
images**

$$I_{hkl,1} \pm \sigma_{I_{hkl,1}}$$

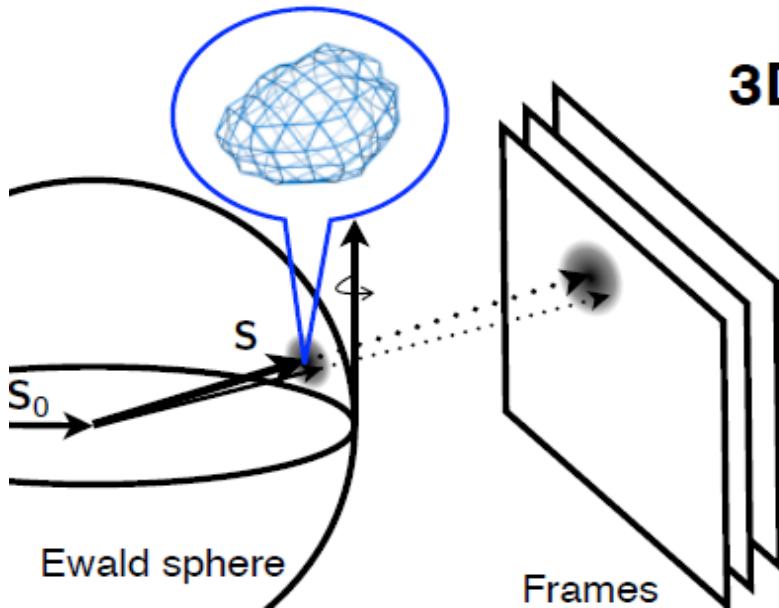
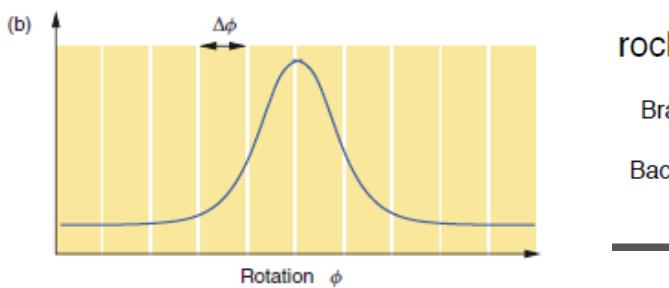
$$I_{hkl,2} \pm \sigma_{I_{hkl,2}}$$

**Scaling = Applying scale factor to  
integrated intensities to correct  
for various experimental factors  
changing between diffraction  
images**

$$I_{hkl} \pm \sigma_{I_{hkl}}$$

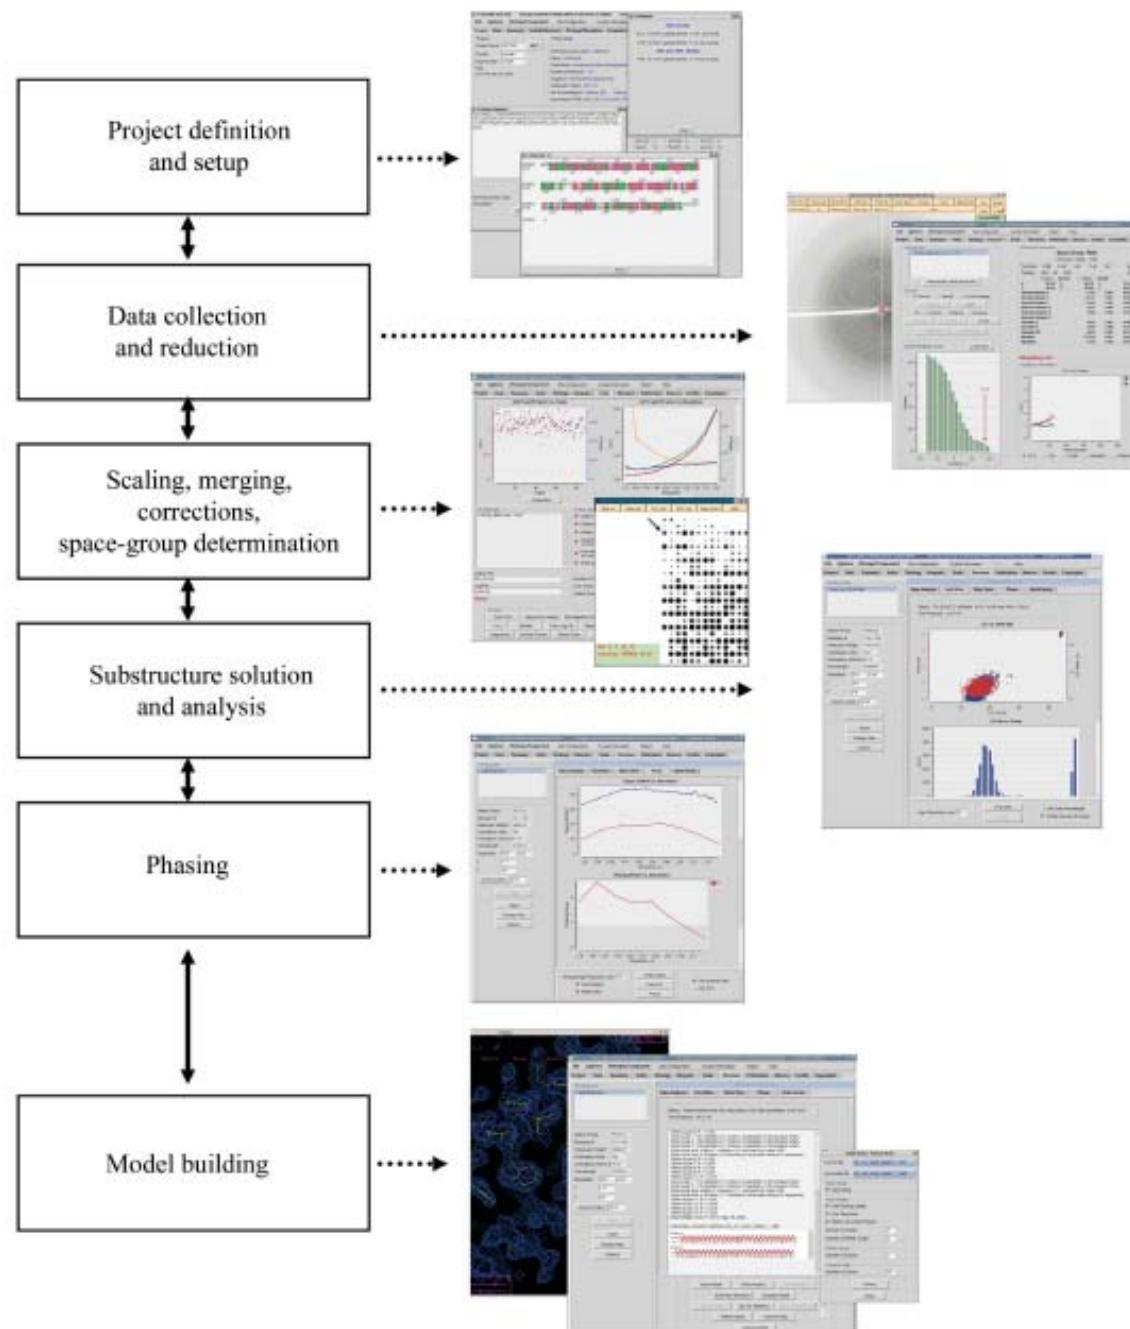


Recording single-crystal diffraction data. (a) In the ‘oscillation’ method, signal is integrated over an angle  $\Delta\phi$ , chosen to be large enough to include entire Bragg peaks, but not so large so as to make the recorded image overcrowded. After the exposure, the image is read out, which typically takes a second or more. This process is repeated until the entire required  $\phi$ -range is covered. (b) In the fine phi-slicing mode using modern photon-counting detectors, the readout time is insignificant compared to the typical times the  $\phi$ -motor needs to move over a small  $\Delta\phi$ , in which case no x-ray shutter is needed, the  $\phi$ -motor runs constantly, and data acquisition is quasi-continuous, with only ms-dead times between exposures.



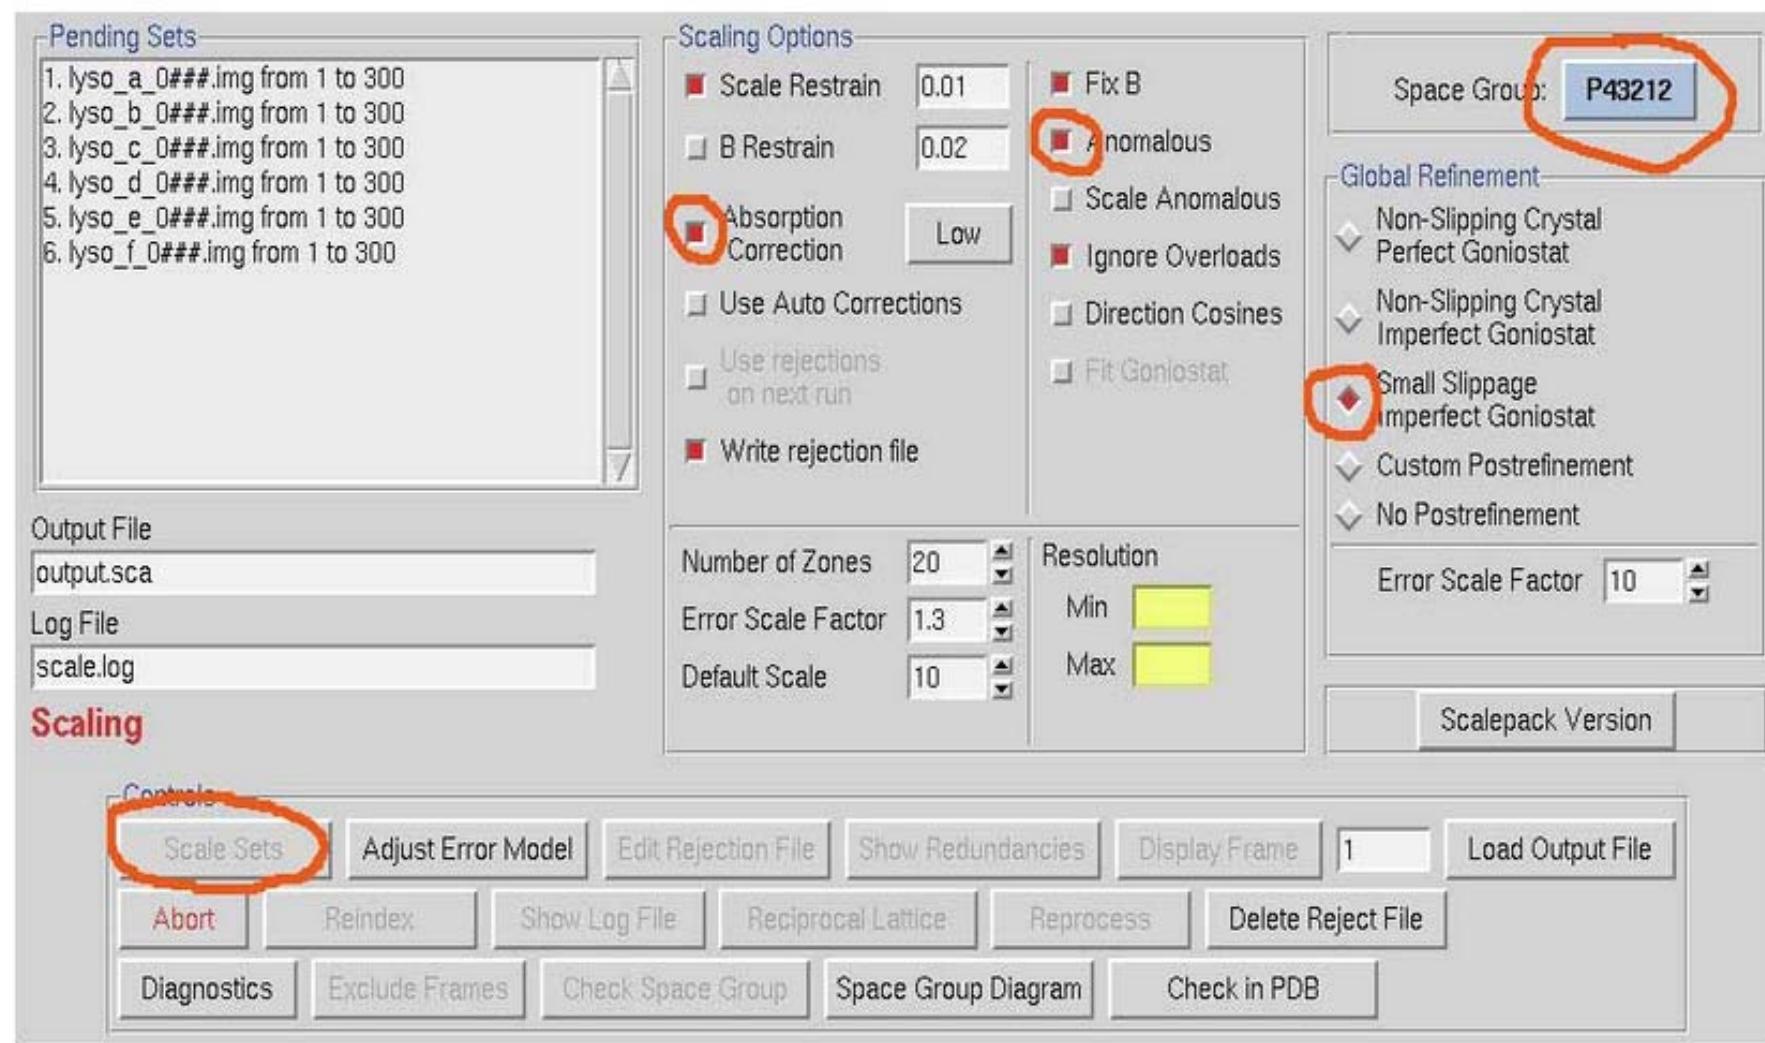
## 3D profile (XDS, $d^*TREK$ )

- Consider angular direction as well as detector surface (1+2D)
- Partial reflections are summed during integration.



## Traitements des données de diffraction

1. Inspection visuelle d'une image de diffraction
2. Indexation initiale
3. Choix des paramètres optimaux d'enregistrement
4. Collecte d'un espace complet de diffraction
5. Affinement des paramètres
4. Mesures des intensités par cliché
5. Mises à l'échelle entre tous les clichés
6. Réduction des données, statistiques, erreurs
7. Résultats
  - Maille, groupe(s) d'espace(s)
  - N réflexions
    - $h, k, l, I_{hkl}, \sigma(I_{hkl})$



Système	Groupe Ponctuel	Groupes chiraux
Triclinique	1	P1
Monoclinique	2	P2      P <sub>2</sub> <sub>1</sub> C2
Orthorhombique	222	P222      P222 <sub>1</sub> P <sub>2</sub> <sub>1</sub> 2 <sub>1</sub> 2      P <sub>2</sub> <sub>1</sub> 2 <sub>1</sub> 2 <sub>1</sub> C222      C222 <sub>1</sub> I222      I <sub>2</sub> <sub>1</sub> 2 <sub>1</sub> 2 <sub>1</sub> F222
Quadratique	4, 422	P4      P4 <sub>1</sub> P4 <sub>2</sub> P4 <sub>3</sub> P422      P42 <sub>1</sub> 2      P4 <sub>1</sub> 22      P4 <sub>3</sub> 22      P4 <sub>2</sub> 22      P4 <sub>2</sub> 2 <sub>1</sub> 2      P4 <sub>1</sub> 2 <sub>1</sub> 2      P4 <sub>3</sub> 2 <sub>1</sub> 2 I4      I4 <sub>1</sub> I422      I4 <sub>1</sub> 22
Trigonal / Rhomboédrique	3, 32	P3      P3 <sub>1</sub> P3 <sub>2</sub> P312      P3 <sub>1</sub> 12      P3 <sub>2</sub> 12 P321      P3 <sub>1</sub> 21      P3 <sub>2</sub> 21 R3 R32
Hexagonal	6, 622	P6      P6 <sub>1</sub> P6 <sub>2</sub> P6 <sub>3</sub> P6 <sub>4</sub> P6 <sub>5</sub> P622      P6 <sub>1</sub> 22      P6 <sub>2</sub> 22      P6 <sub>3</sub> 22      P6 <sub>4</sub> 22      P6 <sub>5</sub> 22
Cubique	23, 432	P23      P2 <sub>1</sub> 3      P432      P4 <sub>2</sub> 32      P4 <sub>3</sub> 32      P4 <sub>1</sub> 32 I23      I2 <sub>1</sub> 3      I432      I4 <sub>1</sub> 32 F23      F432      F4 <sub>1</sub> 32

Pour un espace complet et redondant de diffraction pour une forme cristalline donnée :

1. A partir des positions géométriques des réflexions
  - Forte présomption  $a=b,c$ ,  $\alpha=\beta=90^\circ$   $\gamma=120^\circ$
  - Système hexagonal si la symétrie d'ordre 6 est présente
  - Système trigonal si seulement une symétrie d'ordre 3 est présente
2. A partir des intensités des réflexions
  - Validation (ou non) de l'axe d'ordre 6
    - Validation (ou non) de l'axe d'ordre 3
  - Recherche d'axe d'ordre 2
3. A partir des extinctions systématiques
  - $6, 6_1$  (ou  $6_5$ ),  $6_2$  (ou  $6_4$ ),  $6_3$  selon c
4. Pas de possibilités à ce stade de distinguer les groupes ayant même symétries et même extinctions
  - $P6_1/P6_5, P6_2/P6_4, P6_122/P6_522, P6_222/P6_422$

" Rsym" classique

$$R_{\text{sym}}(I) = \frac{\sum_{hkl} \sum_{j=1}^{n_{hkl}} |< I_{hkl} > - I_{hkl,j}|}{\sum_{hkl} < I_{hkl} >} \quad < I_{hkl} > = \frac{1}{n_{hkl}} \sum_{j=1}^{n_{hkl}} I_{hkl,j}$$

" Rrim ", "Redundancy-independant merging R factor "

$$R_{r.i.m}(I) = \frac{\sum_{hkl} \sqrt{\frac{n_{hkl}}{n_{hkl}-1}} \sum_{j=1}^{n_{hkl}} |< I_{hkl} > - I_{hkl,j}|}{\sum_{hkl} \sum_{j=1}^{n_{hkl}} I_{hkl,j}}$$

$$\mathbf{R}_{\text{rim}} = \mathbf{R}_{\text{meas}}$$

The redundancy-independent merging R factor gives the precision of individual intensity measurements, independent of multiplicity – hence, shows how broad the distribution is. This is particularly useful to evaluate low-resolution data quality, for example in experimental phasing.

" Rpim" , "Precision-indicating merging R factor "

$$R_{p.i.m}(I) = \frac{\sum_{hkl} \sqrt{\frac{1}{n_{hkl}-1}} \sum_{j=1}^{n_{hkl}} |< I_{hkl} > - I_{hkl,j}|}{\sum_{hkl} \sum_{j=1}^{n_{hkl}} I_{hkl,j}}$$

$$\mathbf{R}_{\text{pim}}$$

The precision indicating merging R factor describes the precision of the **averaged** intensity measurements: it gives you the standard error of the mean - How precisely the center of the distribution is known. Like  $R_{\text{meas}}$ , it needs to be calculated before symmetry equivalents are merged.

Weiss, (2001), J. Apply. Cryst., 34, 130-135.

Data collection	
X-ray source	ESRF ID29
Wavelength (Å)	0.97625
Data collection temperature (K)	100
Detector	Pilatus 6MF
Crystal-detector distance (mm)	383.18
Total rotation range (°)	180
Exposure range (°) and time (s) per image	0.1, 0.04
Mosaicity (°)	0.474
Cell parameters (Å)	$a = 100.36, b = 100.36,$ $c = 105.04, \alpha = \beta = \gamma = 90^\circ$
Space group	P4 <sub>1</sub> 2 <sub>1</sub> 2
Resolution range (outer shell) (Å)	46.50-2.10 (2.23-2.10)
Total number of reflections	404573 (61254)
Number of unique reflections	31973 (4976)
Completeness (%)	99.7 (98.4)
Multiplicity	12.7 (12.2)
$\langle I/\sigma(I) \rangle$	19.2 (1.1)
Rmerge	0.074 (2.2)
$R_{\text{meas}}$	0.077 (2.320)
CC <sub>1/2</sub>	0.999 (0.436)

# Linking Crystallographic Model and Data Quality

P. Andrew Karplus<sup>1</sup> and Kay Diederichs<sup>2\*</sup>

In macromolecular x-ray crystallography, refinement  $R$  values measure the agreement between observed and calculated data. Analogously,  $R_{\text{merge}}$  values reporting on the agreement between multiple measurements of a given reflection are used to assess data quality. Here, we show that despite their widespread use,  $R_{\text{merge}}$  values are poorly suited for determining the high-resolution limit and that current standard protocols discard much useful data. We introduce a statistic that estimates the correlation of an observed data set with the underlying (not measurable) true signal; this quantity,  $\text{CC}^*$ , provides a single statistically valid guide for deciding which data are useful.  $\text{CC}^*$  also can be used to assess model and data quality on the same scale, and this reveals when data quality is limiting model improvement.

25 MAY 2012 VOL 336 SCIENCE [www.sciencemag.org](http://www.sciencemag.org)

Cysteine DiOxygenase (CDO; PDB 3ELN) re-refined against 15-fold weaker data

Karplus, Diederichs (2012). Science, 336, 1030-1033.

"Coefficients de corrélation"  $CC_{\frac{1}{2}}$ ,  $CC^*$

To determine where to cut the data, results from Student's t-test can indicate where statistical significance ends (as a rule-of-thumb data are usually insignificant if  $CC_{1/2} < 0.15$  or lower).

$$CC = \frac{\sum_{i=1}^{i=n} (x_i - \langle x \rangle)(y_i - \langle y \rangle)}{\sqrt{\sum_{i=1}^{i=n} (x_i - \langle x \rangle)^2 \sum_{i=1}^{i=n} (y_i - \langle y \rangle)^2}}$$

$$CC^* = \sqrt{\frac{2 CC_{\frac{1}{2}}}{1 + CC_{\frac{1}{2}}}}$$

**CC of the full dataset against the true Intensities (usually unmeasurable)**

- Data should be used to higher resolution than the conservative cutoff suggests
- $CC_{\frac{1}{2}}$  directly assesses significance of data
- $CC^*$  predicts the agreement of data and truth
- $CC^*$  provides a statistic that not only assesses data quality but also allows direct comparison of crystallographic model quality and data quality on the same scale
- Crystallographic models at high resolution have  $F_{calc}^2$  closer to the true data than the experimental data are.

# Traitements des données de diffraction

1. Inspection visuelle d'une image de diffraction
2. Indexation initiale
3. Choix des paramètres optimaux d'enregistrement
4. Collecte d'un espace complet de diffraction
5. Affinement des paramètres
4. Mesures des intensités par cliché
5. Mises à l'échelle
6. Réduction des données, statistiques, erreurs
  - Réflexions équivalentes
  - Extinctions

## 7. Résultats



- Maille, groupe(s) d'espace(s)
- N réflexions
  - $h, k, l, I_{hkl}, \sigma(I_{hkl})$
  - $h, k, l, |F_{hkl}|, \sigma(|F_{hkl}|)$



## Traitements des données de diffraction

Résultats. Un fichier de réflexions avec les mesures  
différents formats selon les programmes

- Maille, groupe(s) d'espace(s)
- N réflexions :  $h, k, l, I_{hkl}, \sigma(I_{hkl})$
- Pour la suite du processus,  $h, k, l, |F_{hkl}|, \sigma(|F_{hkl}|)$
- **Calcul des modules des facteurs de structures**
  - Approche simpliste
  - Approches Statistiques
- **Analyses des données**
- Fichier final :  $h, k, l, |F_{hkl}|, \sigma(|F_{hkl}|)$  différents formats
  - Une norme : format CCP4

## Calcul des modules des facteurs de structures

Expérience de diffraction = Mesure de  $I_{hkl}$  et calcul  $\sigma(I_{hkl})$

$$I_{hkl} \propto \begin{cases} |F_{hkl}|^2 = F_{hkl}\overline{F_{hkl}} & \text{cristal "idéalement imparfait"} \\ & ("parfaitement mosaique") \\ |F_{hkl}| & \text{cristal parfait} \end{cases}$$

A partir des données,  $|F_{hkl}| = \sqrt{I_{hkl}}$        $\sigma(|F_{hkl}|) = \frac{1}{2} \frac{\sigma(I_{hkl})}{\sqrt{I_{hkl}}}$

Problèmes :

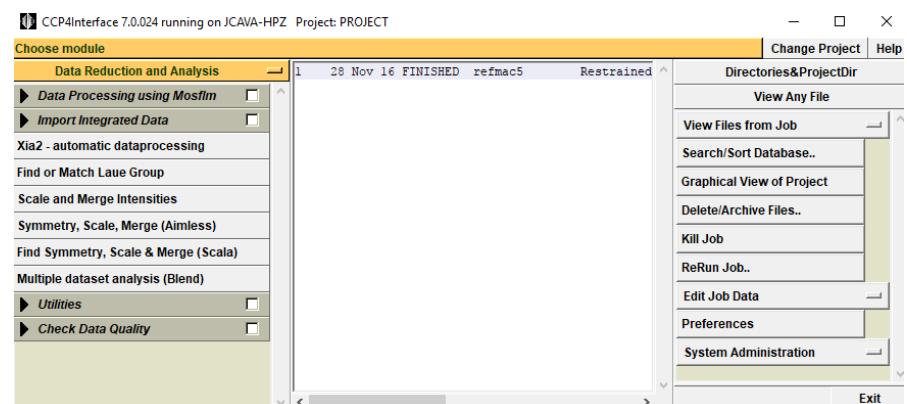
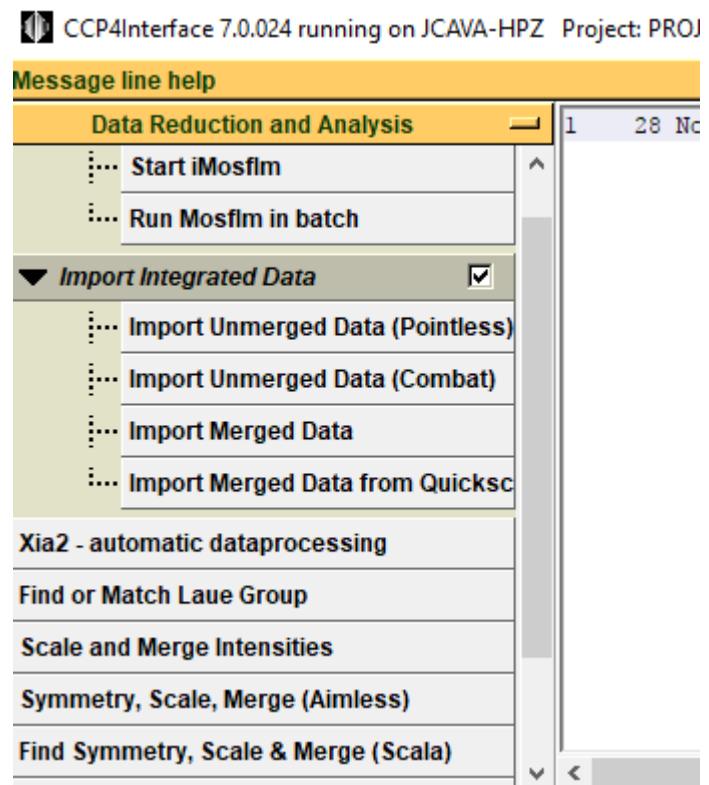
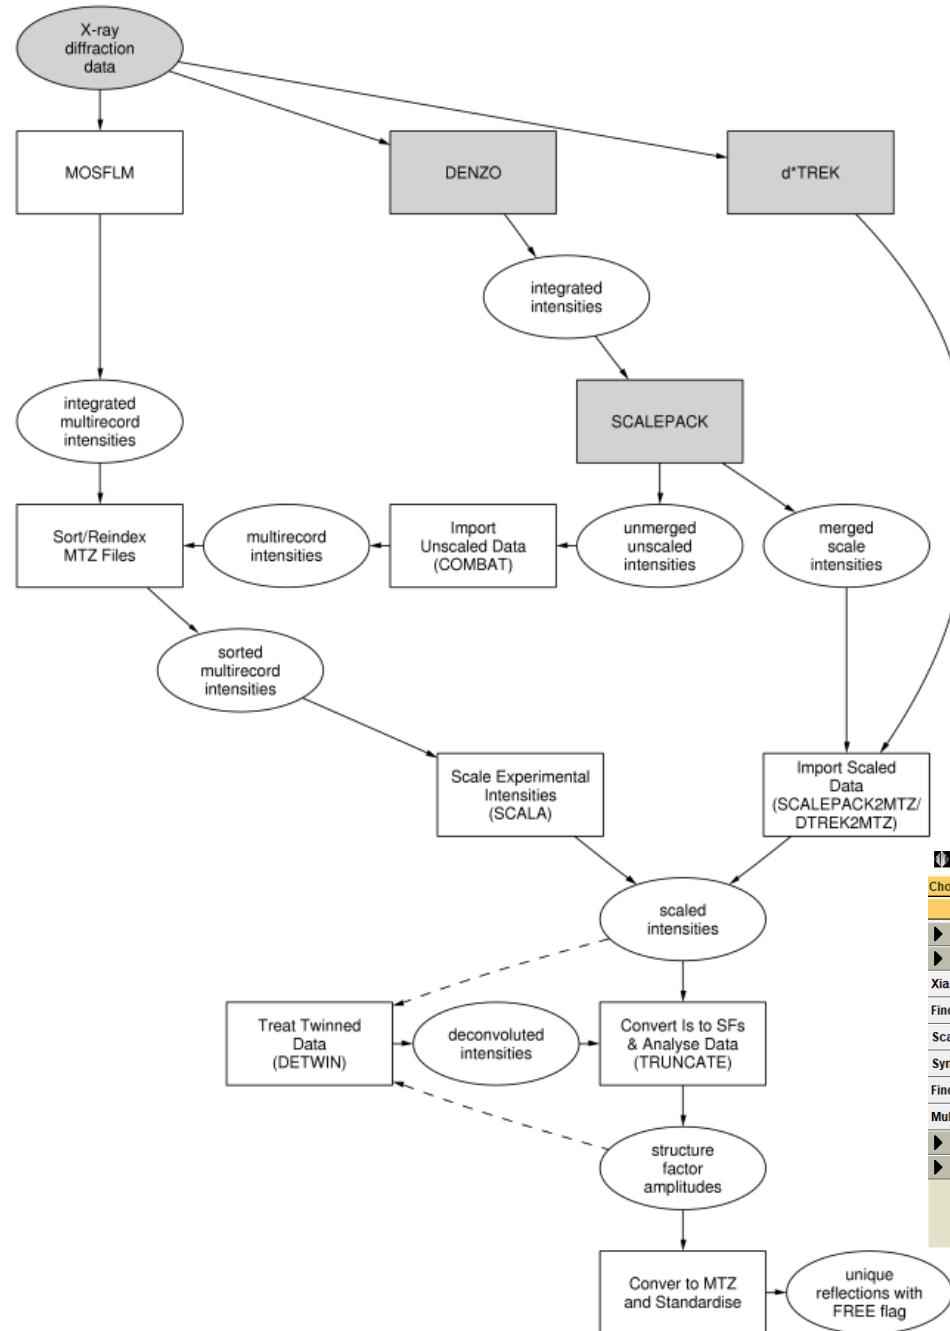
Calcul de  $|F_{hkl}|$  pour les réflexions mesurées négatives

Calcul de  $\sigma(|F_{hkl}|)$  pour les réflexions faibles

Approche statistique Bayésienne :

- French, Wilson, (1978), Acta Cryst. A34, 517-525. Program Truncate (CCP4)
- Sivia and David, (1994), Acta Cryst. A50, 703-714.

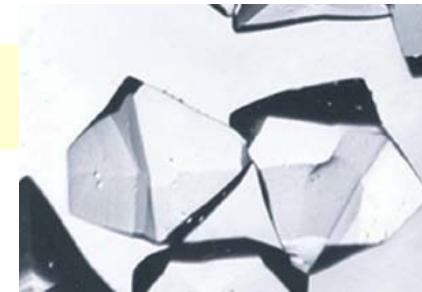
$$|F_{hkl}| = \frac{1}{2} \sqrt{2I_{hkl} + \sqrt{4I_{hkl}^2 + 8\sigma_{I_{hkl}}^2}} \quad \sigma(|F_{hkl}|) = \left( \frac{1}{F_{hkl}^2} + \frac{2(3F_{hkl}^2 - I_{hkl})}{\sigma_{I_{hkl}}^2} \right)^{-\frac{1}{2}}$$



SUBSET OF INTENSITY DATA WITH SIGNAL/NOISE >= -3.0 AS FUNCTION OF RESOLUTION											
RESOLUTION LIMIT	NUMBER OF REFLECTIONS OBSERVED	NUMBER OF UNIQUE REFLECTIONS	NUMBER OF POSSIBLE REFLECTIONS	COMPLETENESS OF DATA	R-FACTOR observed	R-FACTOR expected	R-FACTOR COMPARED I/SIGMA	R-meas	CC(1/2)	Anomalous Correlation	
3.39	43959	7862	7879	99.8%	3.3%	3.3%	43901	45.93	3.7%	99.9*	15*
2.40	78904	14040	14053	99.9%	4.1%	3.9%	78859	35.17	4.5%	99.8*	13*
1.96	103441	18058	18058	100.0%	5.5%	5.3%	103418	25.92	6.0%	99.7*	10
1.69	120608	21306	21319	99.9%	9.2%	9.0%	120560	15.15	10.1%	99.5*	6
1.52	133927	24143	24147	100.0%	16.5%	16.8%	133866	8.69	18.2%	98.3*	3
1.38	147353	26645	26649	100.0%	28.7%	29.5%	147313	5.14	31.7%	95.7*	2
1.28	157651	28885	28893	100.0%	48.4%	50.0%	157573	3.09	53.6%	88.1*	2
1.20	152989	31082	31095	100.0%	74.2%	76.2%	152814	1.88	83.2%	73.5*	0
1.13	87972	31089	33018	94.2%	90.9%	95.4%	83292	1.01	110.5%	50.5*	-2
total	1026804	203110	205111	99.0%	6.7%	6.6%	1021596	10.69	7.4%	99.9*	4

	Overall	InnerShell	OuterShell
<b>Low resolution limit</b>	44.22	44.22	1.84
<b>High resolution limit</b>	1.80	9.00	1.80
<b>Rmerge (within I+ / I-)</b>	0.082	0.032	1.672
<b>Rmerge (all I+ and I-)</b>	0.088	0.033	1.816
<b>Rmeas (within I+ / I-)</b>	0.097	0.037	1.972
<b>Rmeas (all I+ &amp; I-)</b>	0.095	0.036	1.967
<b>Rpim (within I+ / I-)</b>	0.051	0.020	1.029
<b>Rpim (all I+ &amp; I-)</b>	0.037	0.015	0.752
<b>Rmerge in top intensity bin</b>	0.036	-	-
<b>Total number of observations</b>	308208	2484	18911
<b>Total number unique</b>	47105	440	2780
<b>Mean((I)/sd(I))</b>	11.7	37.8	1.0
<b>Mn(I) half-set correlation CC(1/2)</b>	0.999	0.998	0.470
<b>Completeness</b>	100.0	98.9	100.0
<b>Multiplicity</b>	6.5	5.6	6.8

## Analyse des données de diffraction

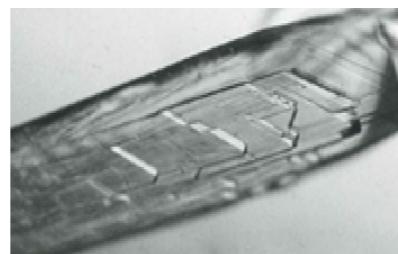


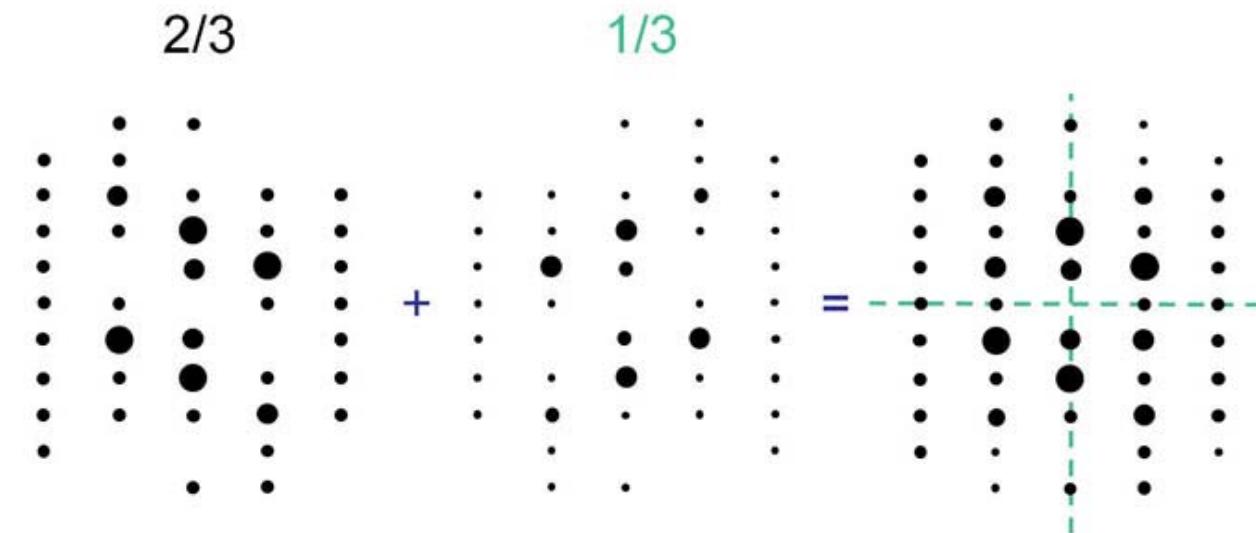
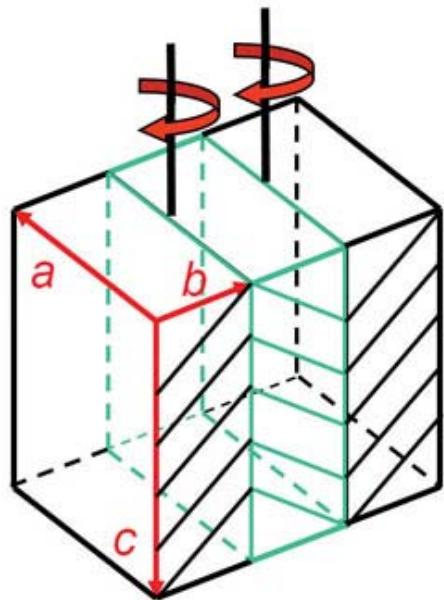
### Analyse statistique des données

- Un contrôle qualité
- Éventuellement mise en évidence de défauts cristallins.

### Défauts cristallins :

- Échantillon polycristallin. Identifier avant.
- Les défauts peuvent ne pas être visibles et l'aspect extérieur peut apparaître comme monocristallin " twinning "
- Un échantillon cristallin consistant en N domaines qui ont une orientation mutuelle donnée par une opération de symétrie qui n'appartient pas au groupe ponctuel du cristal mais qui est reliée à la symétrie du réseau correspondant.





L'analyse statistique de la distribution des intensités permet de mettre en évidence et de tenir compte du phénomène

Moments de la distribution des intensités, " Britton plot ", " Rees N(z) plot ", "Yeates S(H) plot " , " L-function"

Voir Truncate, CCP4, phenix.xtriage

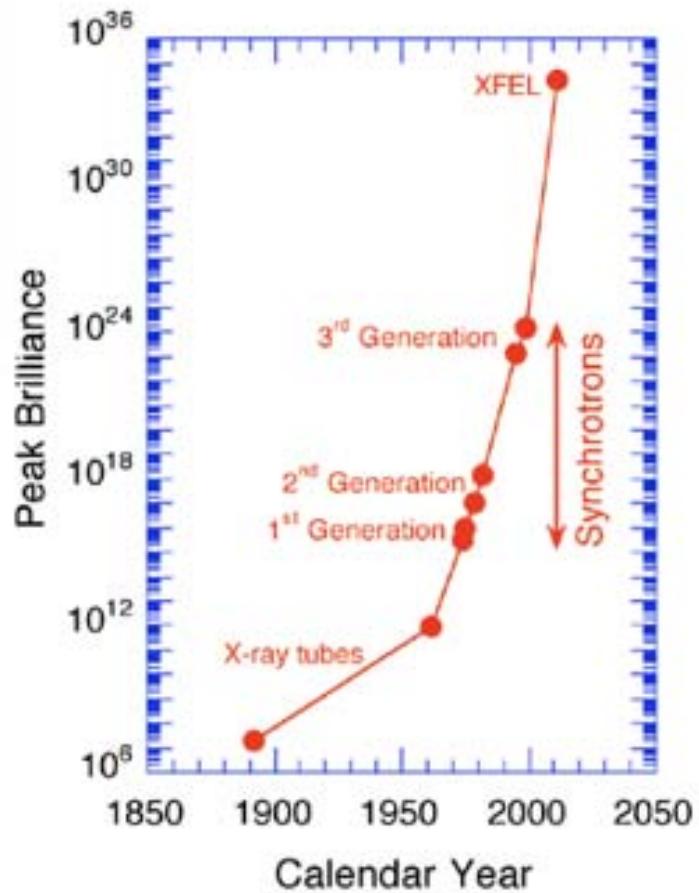
## Collecte des données de diffraction

### Collecte des données de diffraction

- Un processus crucial
- Un processus de plus en plus automatisé
- Un processus rapide : un espace complet en quelques minutes
  - Matériel : Utilisation de robots
  - Logiciels
    - Des algorithmes complexes avec une utilisation de plus en plus simple
    - Un traitement des données " synchronisé " avec la collecte.
- "Collecte MAD/SAD. Une carte peut être obtenue rapidement sur le site

### Des progrès énormes au cours des dernières années

- Obtenir une structure à partir de "cristaux inutilisables" hier
- De nouvelles possibilités

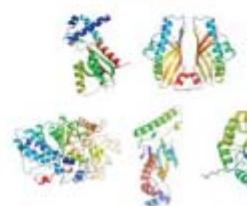
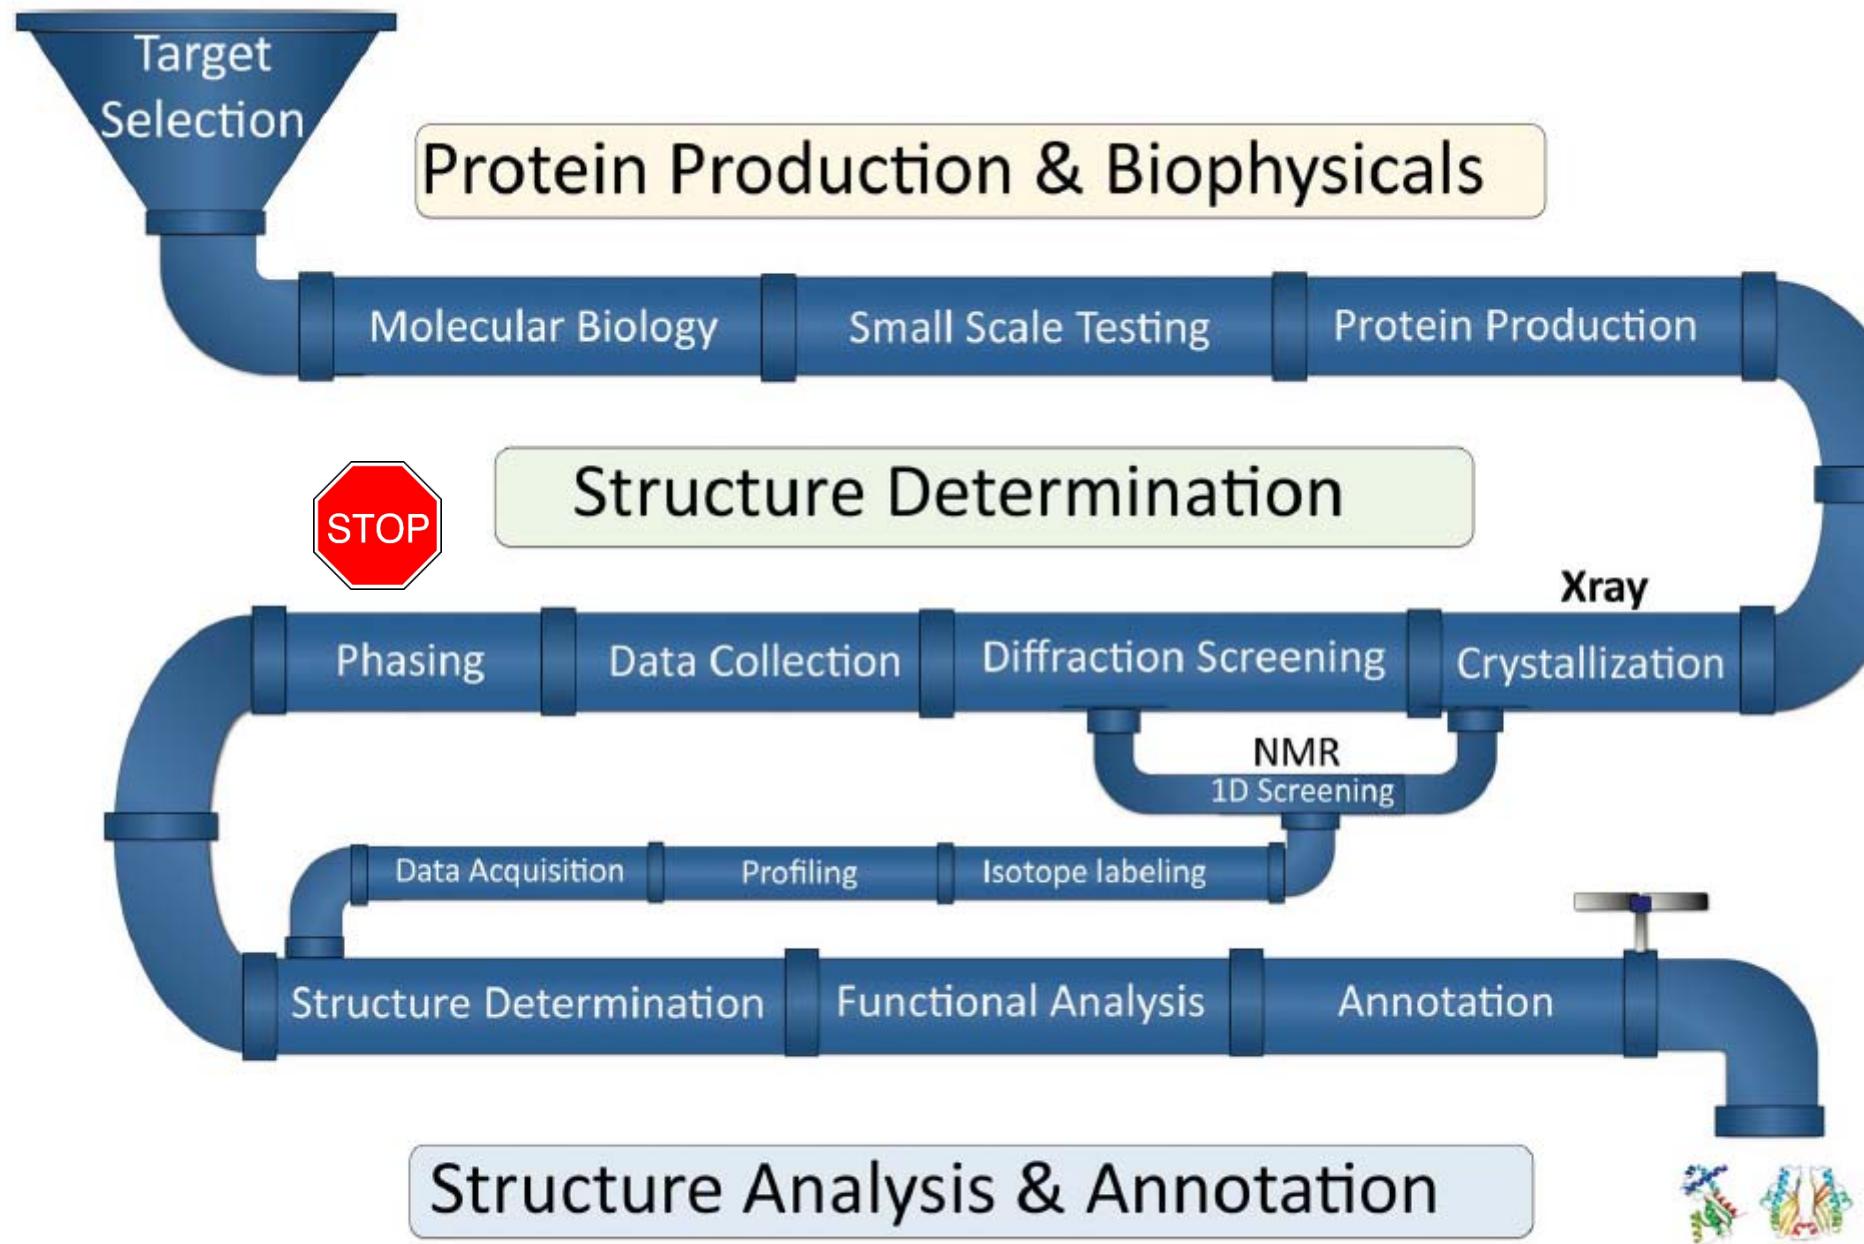


## Serial synchrotron crystallography

- From micro to nano-crystallography

## XFELs

- From nano to femtosecond crystallography
- structure determination without crystallization



## Méthodes de détermination des phases

- Utiliser des contraintes entre facteurs de structure
  - Méthodes directes.

1934 Fonction de Patterson, 1948 inégalités Harker-Kasper, 1950 déterminants de Karle-Hauptman, 1951 équation de Sayre, 1953 invariants et semi-invariants de Hauptman et Karle, 1956-1958 Hauptman et Karle Formule de la tangente et théorie probabilistique, 1960s "symbolic addition" Karle and Karle, ...,  
**1985 Hauptman and Karle Prix Nobel Chimie , ...**
- Utiliser des variations de modules de facteurs de structure (pour chaque réflexion)
  - Remplacement isomorphe multiple, "Multiple Isomorphous Replacement" (MIR)
  - Utilisation de la diffusion anomale,
    - Travail à plusieurs longueurs d'onde, "Multi-wavelength Anomalous Scattering" (MAD)
    - Travail à une longueur d'onde, "Single wavelength Anomalous Scattering" (SAD)
  - Utilisation de la dégradation de la structure.
    - "(site-specific) Radiation damage-Induced Phasing" (RIP)

Quelques exemples de modifications de structures. "X-Ray RIP" : ruptures de points di-sulfures, decarboxylations Asp, Glu ; pertes de OH de Tyr; pertes de S-CH3 de Met ; pertes de Se de SeMet ; pertes de metals, de Br-AN.
- Utiliser un modèle de molécule parente correctement orientée et positionnée
  - Rem-placement Moléculaire

Obtention d'un jeu de phases initiales qui seront le plus souvent améliorées (pour chaque réflexion, diminution de l'erreur par rapport à la phase exacte)

- Méthodes de modifications de densité

Les méthodes "expérimentales" de phasage. Utilisation de variations de modules de chaque facteur de structure

Pour chaque réflexion "indépendante" notée H,

$N_H$  mesures,  $|F_{H,j}|$ ,  $j = 1 \rightarrow N_H$

$$F_{H,j} = P_H + V_{H,j}$$

- $P_H$  une partie constante, inconnue, la même pour toutes les sources de données j
- $V_{H,j}$  une partie variable, due à un sous-groupe d'atomes donnés

$V_{H,j}$  reflète **une structure atomique** (positions atomiques, facteurs de déplacements atomiques, ...), qui peut être représenté par une variable vectorielle  $\theta$ ,

$$|F_{H,j}(\theta)| = |P_H + V_{H,j}(\theta)|, \quad j = 1 \rightarrow N_H$$

$$|F_{H,j}(\theta)| = |P_H + V_{H,j}(\theta)|, \quad j = 1 \rightarrow N_H$$

en théorie, chaque équation peut être résolue très simplement dans le plan complexe.

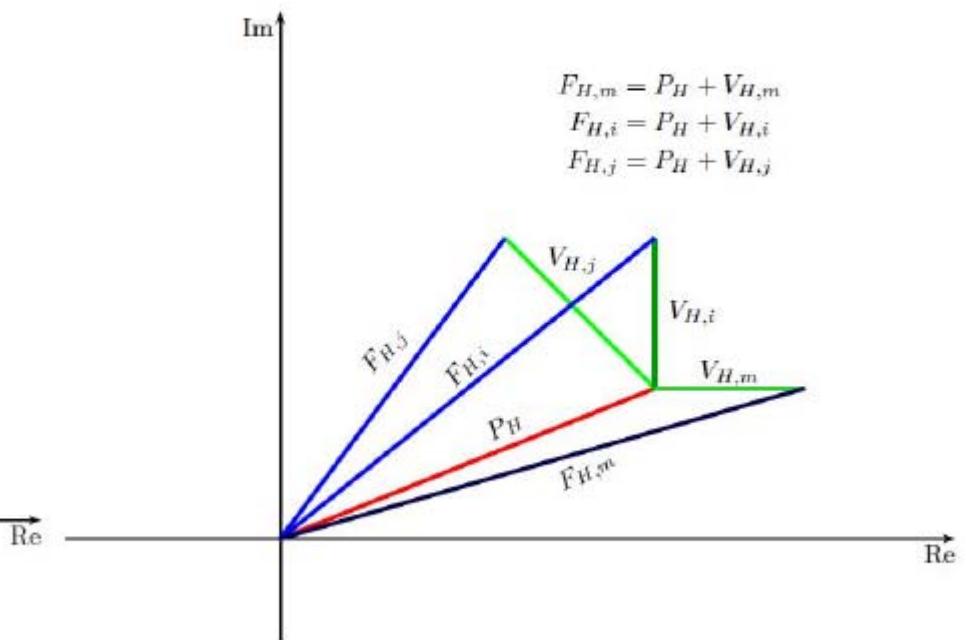
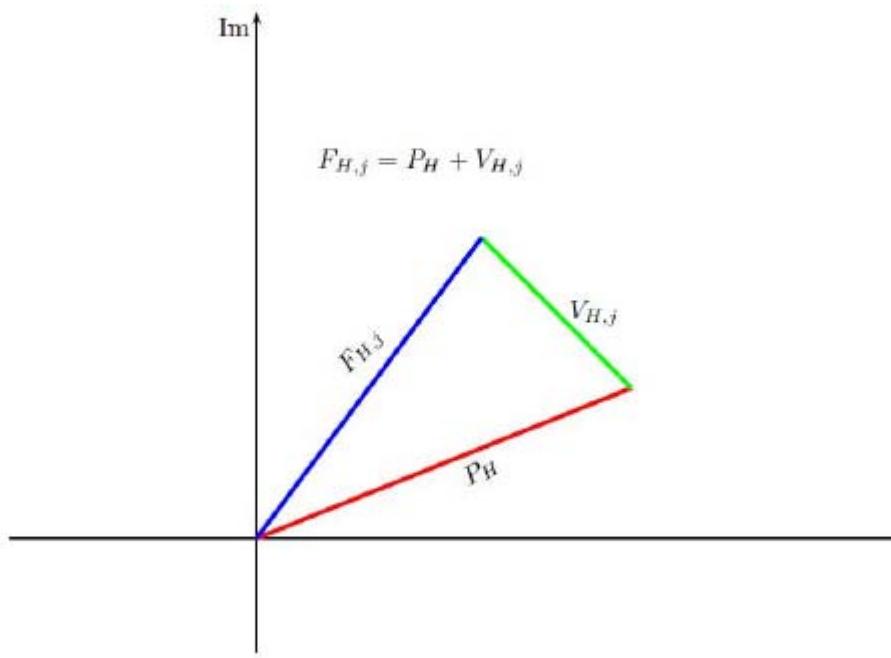
### Construction de Harker

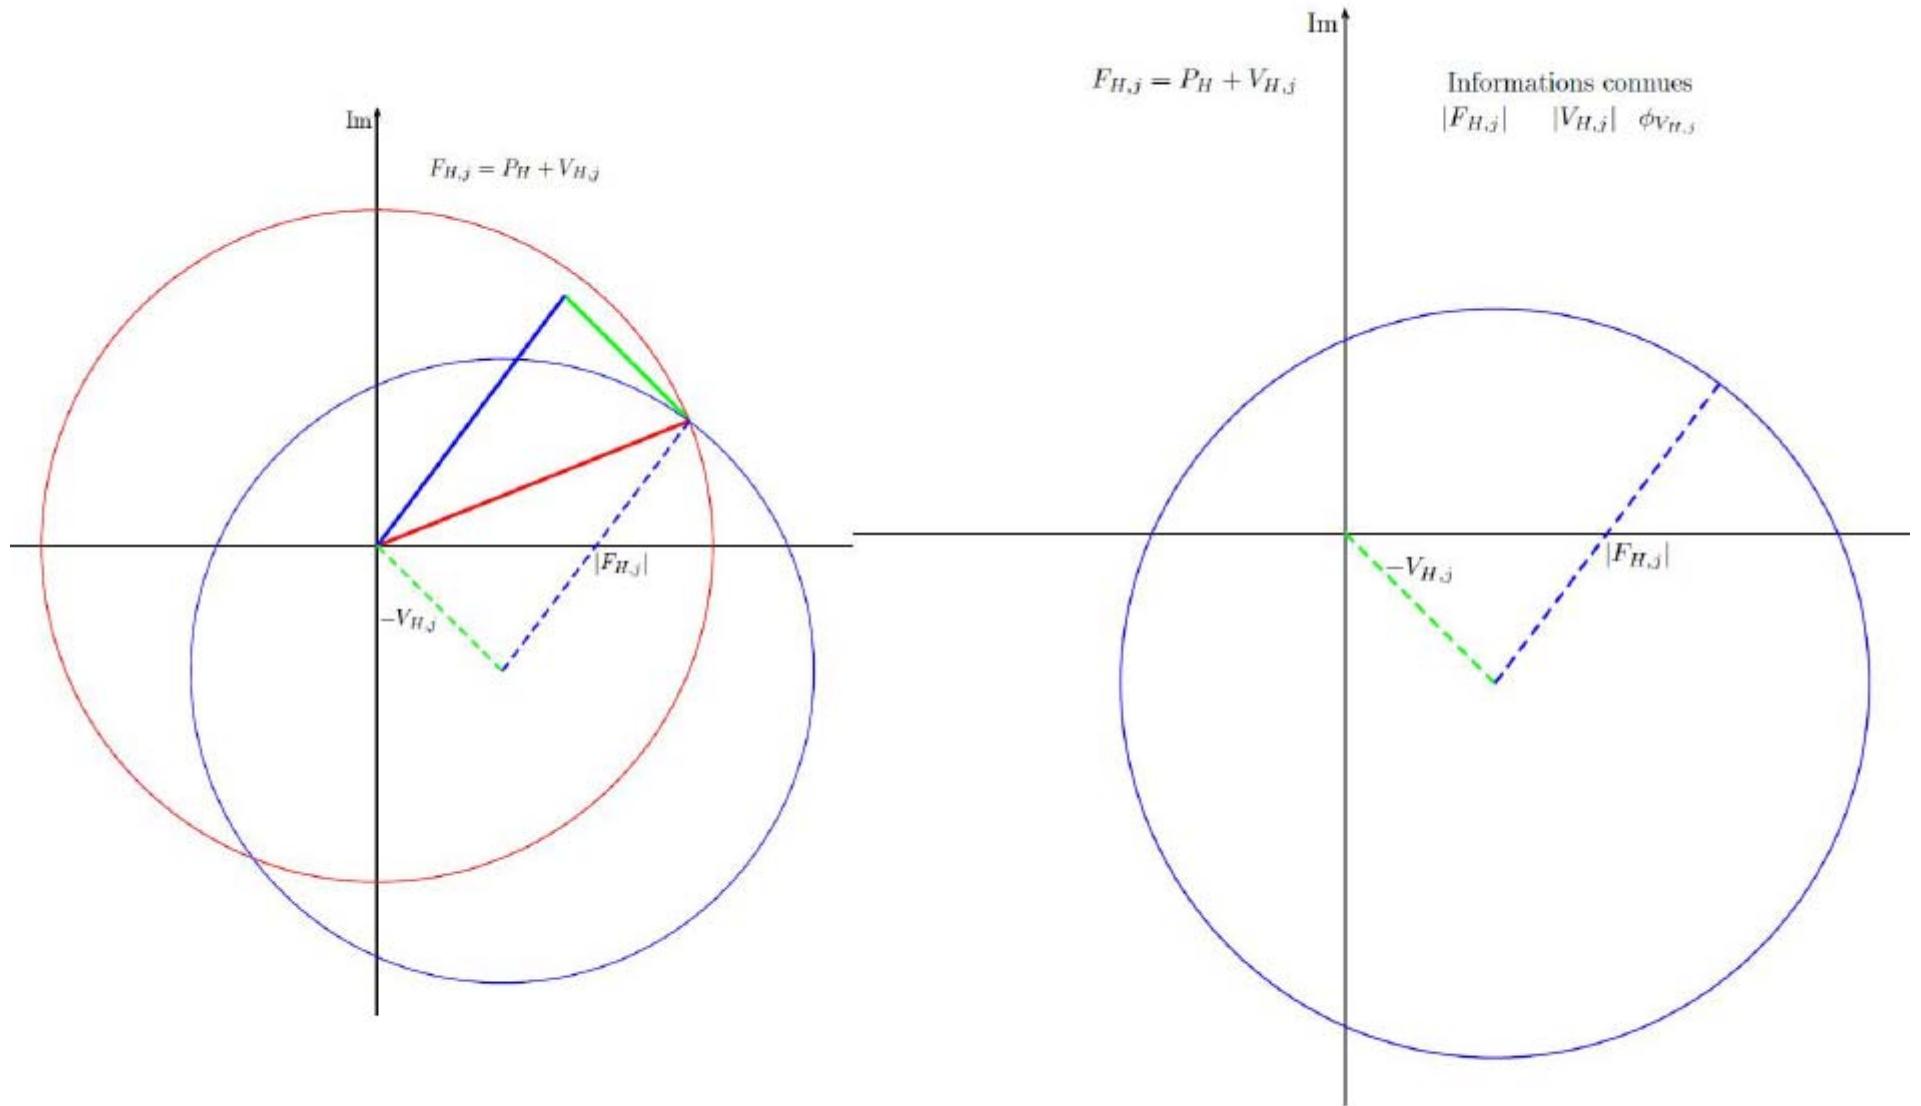
Intersection de  $N_H$  cercles centrés en  $-V_{H,j}$  et de rayon  $|F_{H,j}|$

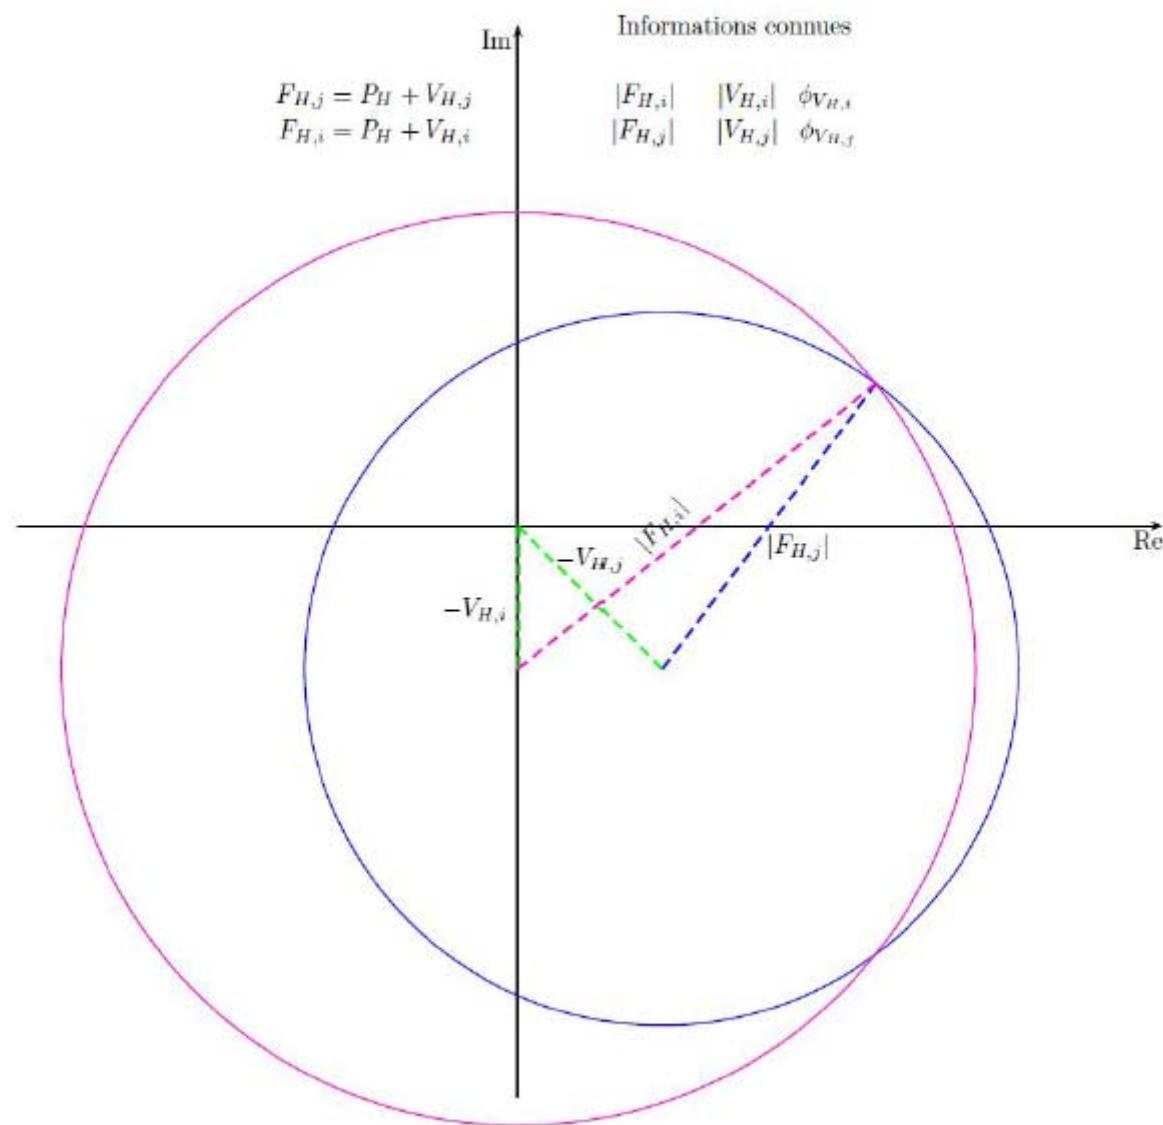
Si les  $V_{H,j}$  ne sont pas colinéaires, Les systèmes d'équations sont résolus si :

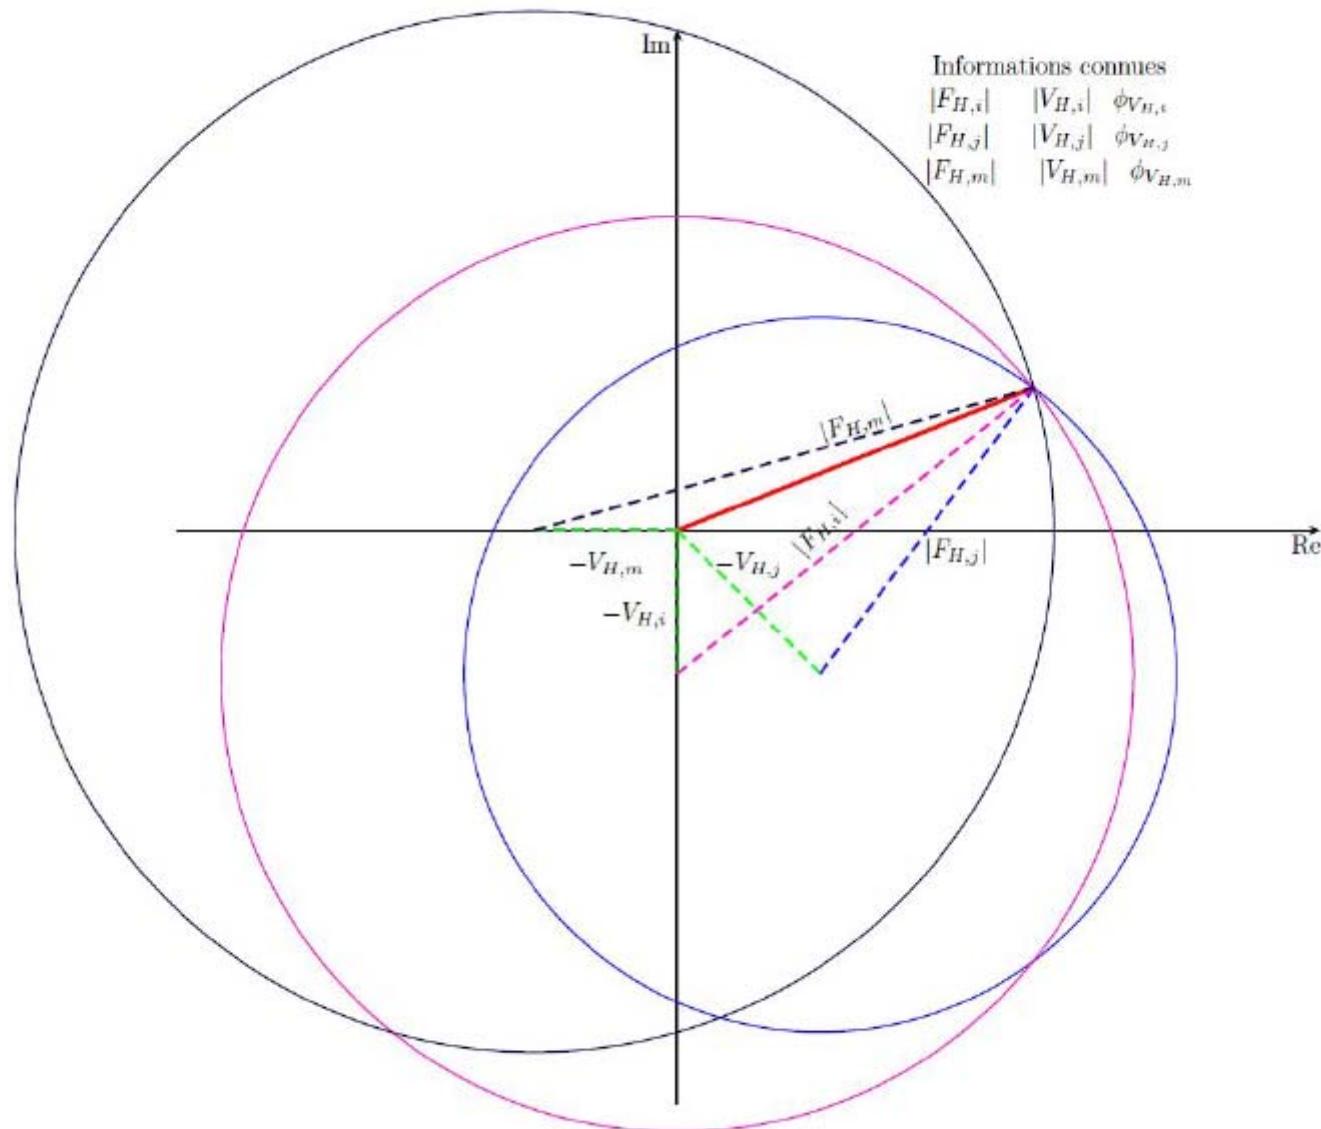
- réflexions centriques,  $N_H > 1$
- réflexions non-centriques,  $N_H > 2$

Dans le cas réel, plusieurs catégories d'erreurs vont polluer la simplicité des équations et nécessiter un traitement statistique complexe.









$$|F_{H,j}(\theta)| = |P_H + V_{H,j}(\theta)|, \quad j = 1 \rightarrow N_H$$

Dans le cas général, le problème des phases est résolu si  $N_H > 2$ .

Le processus de phasage :

- ① Collecte des  $N_H \quad j = 1 \rightarrow N_H$  jeux de diffraction
- ② Détermination des sous-structures  $V_{H,j}$ , en particulier les positions atomiques,
- ③ Détermination de la "main" des sous-structures,
- ④ Calculs et interprétation des cartes de densité électronique : est-ce interprétable ?
  - Méthodes de modifications de densité,
- ⑤ Construction, Affinement de la structure,
- ⑥ Validation et contrôle qualité.

Des programmes de plus en plus performants et automatisés

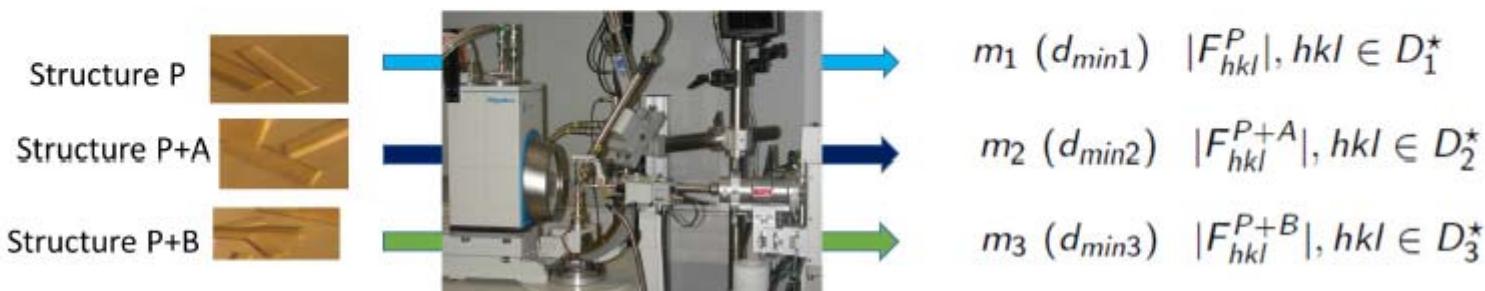
- Des données de diffraction à un premier modèle construit dans une carte de densité électronique modifiée.
- Quelques exemples : CCP4, PHENIX, HKL3000,CNS

$$|F_{H,j}(\theta)| = |P_H + V_{H,j}(\theta)|, \quad j = 1 \rightarrow N_H$$

- "Single Isomorphous Replacement (SIR), Multiple Isomorphous Replacement (MIR)"  
j fait référence aux différents dérivés lourds
- "Single-wavelength anomalous diffraction (SAD), Multi-wavelength anomalous diffraction (MAD)"  
j fait référence aux différences de "Bijvoet"
- "(site specific) Radiation damage-Induced phasing (RIP)"  
j fait référence aux degrés d'irradiations

### Méthode du remplacement isomorphe

$$F_{hkl} = \sum_{j=1}^{N+m} q_j f_j w_j e^{2i\pi(hx_j+ky_j+lz_j)} = \sum_{j=1}^N q_j f_j w_j e^{2i\pi(hx_j+ky_j+lz_j)} + \sum_{j=1}^m q_j f_j w_j e^{2i\pi(hx_j+ky_j+lz_j)}$$



### Méthode de la diffusion anomale

$$F_{hkl} = \sum_{j=1}^N \left( {}^0 f_j + {}^\lambda f_j' + i {}^\lambda f_j'' \right) q_j w_j^{hkl} e^{2i\pi(hx_j+ky_j+lz_j)}$$



$$\lambda_1 |F_1^+| |F_1^-| F_1' F_1''$$

$$\lambda_2 |F_2^+| |F_2^-| F_2' F_2''$$

(cas 1 seul type de diffuseur anomal)

# Les principaux programmes en bio-cristallographie

- Des programmes de plus en plus performants et automatisés
  - Quelques exemples : CCP4, PHENIX, HKL3000,CNS

Quelques références actuelles :

- Collecte de données
  - HKL2000, MOSFLM, XDS
- Phasage MIR,MAD,SAD
  - SHARP, SOLVE,SHELX, CRANK,
- Remplacement Moléculaire
  - Phaser, MOLREP, AMoRe, BALBES, MR-ROSETTA
- Modification de densité (avec parfois constructions automatiques)
  - RESOLVE, SOLOMON, ARP/WARP, DM, SHELX
- Construction des structures
  - Automatique
    - Buccaneer, Resolve, Arp/wArp
  - Manuelle
    - Coot, O
- Affinement
  - REFMAC, PHENIX, SHELX, BUSTER, CNS





## CCP4 Tutorials

### ccp4i2 tutorials

- + [ccp4i2 video tutorials](#)
- + [Data processing and SAD phasing](#)
- + [Molecular replacement](#)
- + [Model building and refinement](#)

### ccp4i tutorials

- + [Basic phasing tutorials](#)
- + [Integration and data processing](#)
- + [Multi-crystal processing](#)
- + [Refinement with ligands and covalent links](#)

### External tutorials

- + [More MX tutorials](#)

PHENIX home

Quit Preferences Help Citations Reload last job Other tools Ask for help

Actions Job history

**Projects**

Show group: All groups Manage...  
Select Delete New project Settings

ID	Last modified	# of jobs	R-free
p9-sad	Mar 13 2014 03:0...	34	0.3035

**Data analysis**

Experimental phasing  
Molecular replacement  
Model building  
Refinement  
Validation  
Ligands  
Reflection tools  
Maps  
Model tools  
Other utilities

Current directory: /Users/nat/Documents/tutorials/p9-sad Browse...

PHENIX version dev-1549 Project: p9-sad

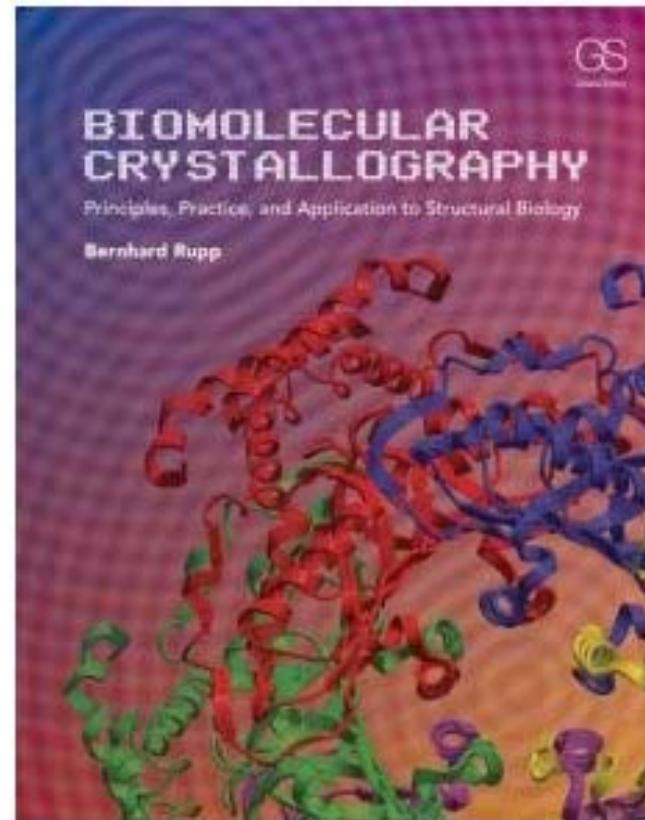
The screenshot shows the main interface of the PHENIX software. At the top is a menu bar with standard Mac OS X icons (Quit, Preferences, Help) and specific PHENIX tools (Citations, Reload last job, Other tools, Ask for help). Below the menu is a toolbar with buttons for Actions (selected), Job history, Projects, Show group (set to All groups), Manage..., and buttons for Select, Delete, New project, and Settings. The main area is divided into two sections: 'Projects' on the left and 'Data analysis' on the right. The 'Projects' section lists a single project named 'p9-sad' with details: Last modified Mar 13 2014 03:0..., # of jobs 34, and R-free 0.3035. It includes buttons for Select, Delete, New project, and Settings. The 'Data analysis' section is a vertical list of tools: Experimental phasing, Molecular replacement, Model building, Refinement, Validation, Ligands, Reflection tools, Maps, Model tools, and Other utilities. At the bottom, there's a 'Current directory' field containing '/Users/nat/Documents/tutorials/p9-sad' with a 'Browse...' button and a search icon, and a status bar indicating 'PHENIX version dev-1549' and 'Project: p9-sad'.

## Bio - Cristallographie

Déterminations des structures 3D des macromolécules biologiques par diffraction des rayons X

<https://www.renafobis.fr/>

JEAN CAVARELLI  
Université de Strasbourg,  
Centre de Biologie Structurale Intégrative,  
Institut de Génétique et de Biologie Moléculaire et Cellulaire  
1, rue Laurent Fries, - 67404 Illkirch-Graffenstaden Cedex  
Tél : 03 69 48 52 74 - Fax : 03 88 65 32 76 - e-mail : [jean.cavarelli@unistra.fr](mailto:jean.cavarelli@unistra.fr)



[http://jean.cavarelli.free.fr/igbmc/lab\\_services/xray\\_progs.html](http://jean.cavarelli.free.fr/igbmc/lab_services/xray_progs.html)

[http://jean.cavarelli.free.fr/unistra/Public/biblio/biblio\\_cristallographie.html](http://jean.cavarelli.free.fr/unistra/Public/biblio/biblio_cristallographie.html)