

A satellite image showing a complex river network flowing through a lush green landscape. The rivers are depicted in dark blue, contrasting with the vibrant green of the surrounding terrain. The network is dense and branching, with many smaller tributaries feeding into larger channels. The overall scene is captured from an aerial perspective, highlighting the intricate patterns of the waterways.

**流量未観測地域における可視光衛星を用いた  
流量推計とデータ同化**

**University of Massachusetts, Amherst  
Ph.D Candidate  
石塚 悠太**

# 自己紹介

東京大学工学部社会基盤学科 芳村研究室

- ・ 鬼怒川洪水のアンサンブル予測について

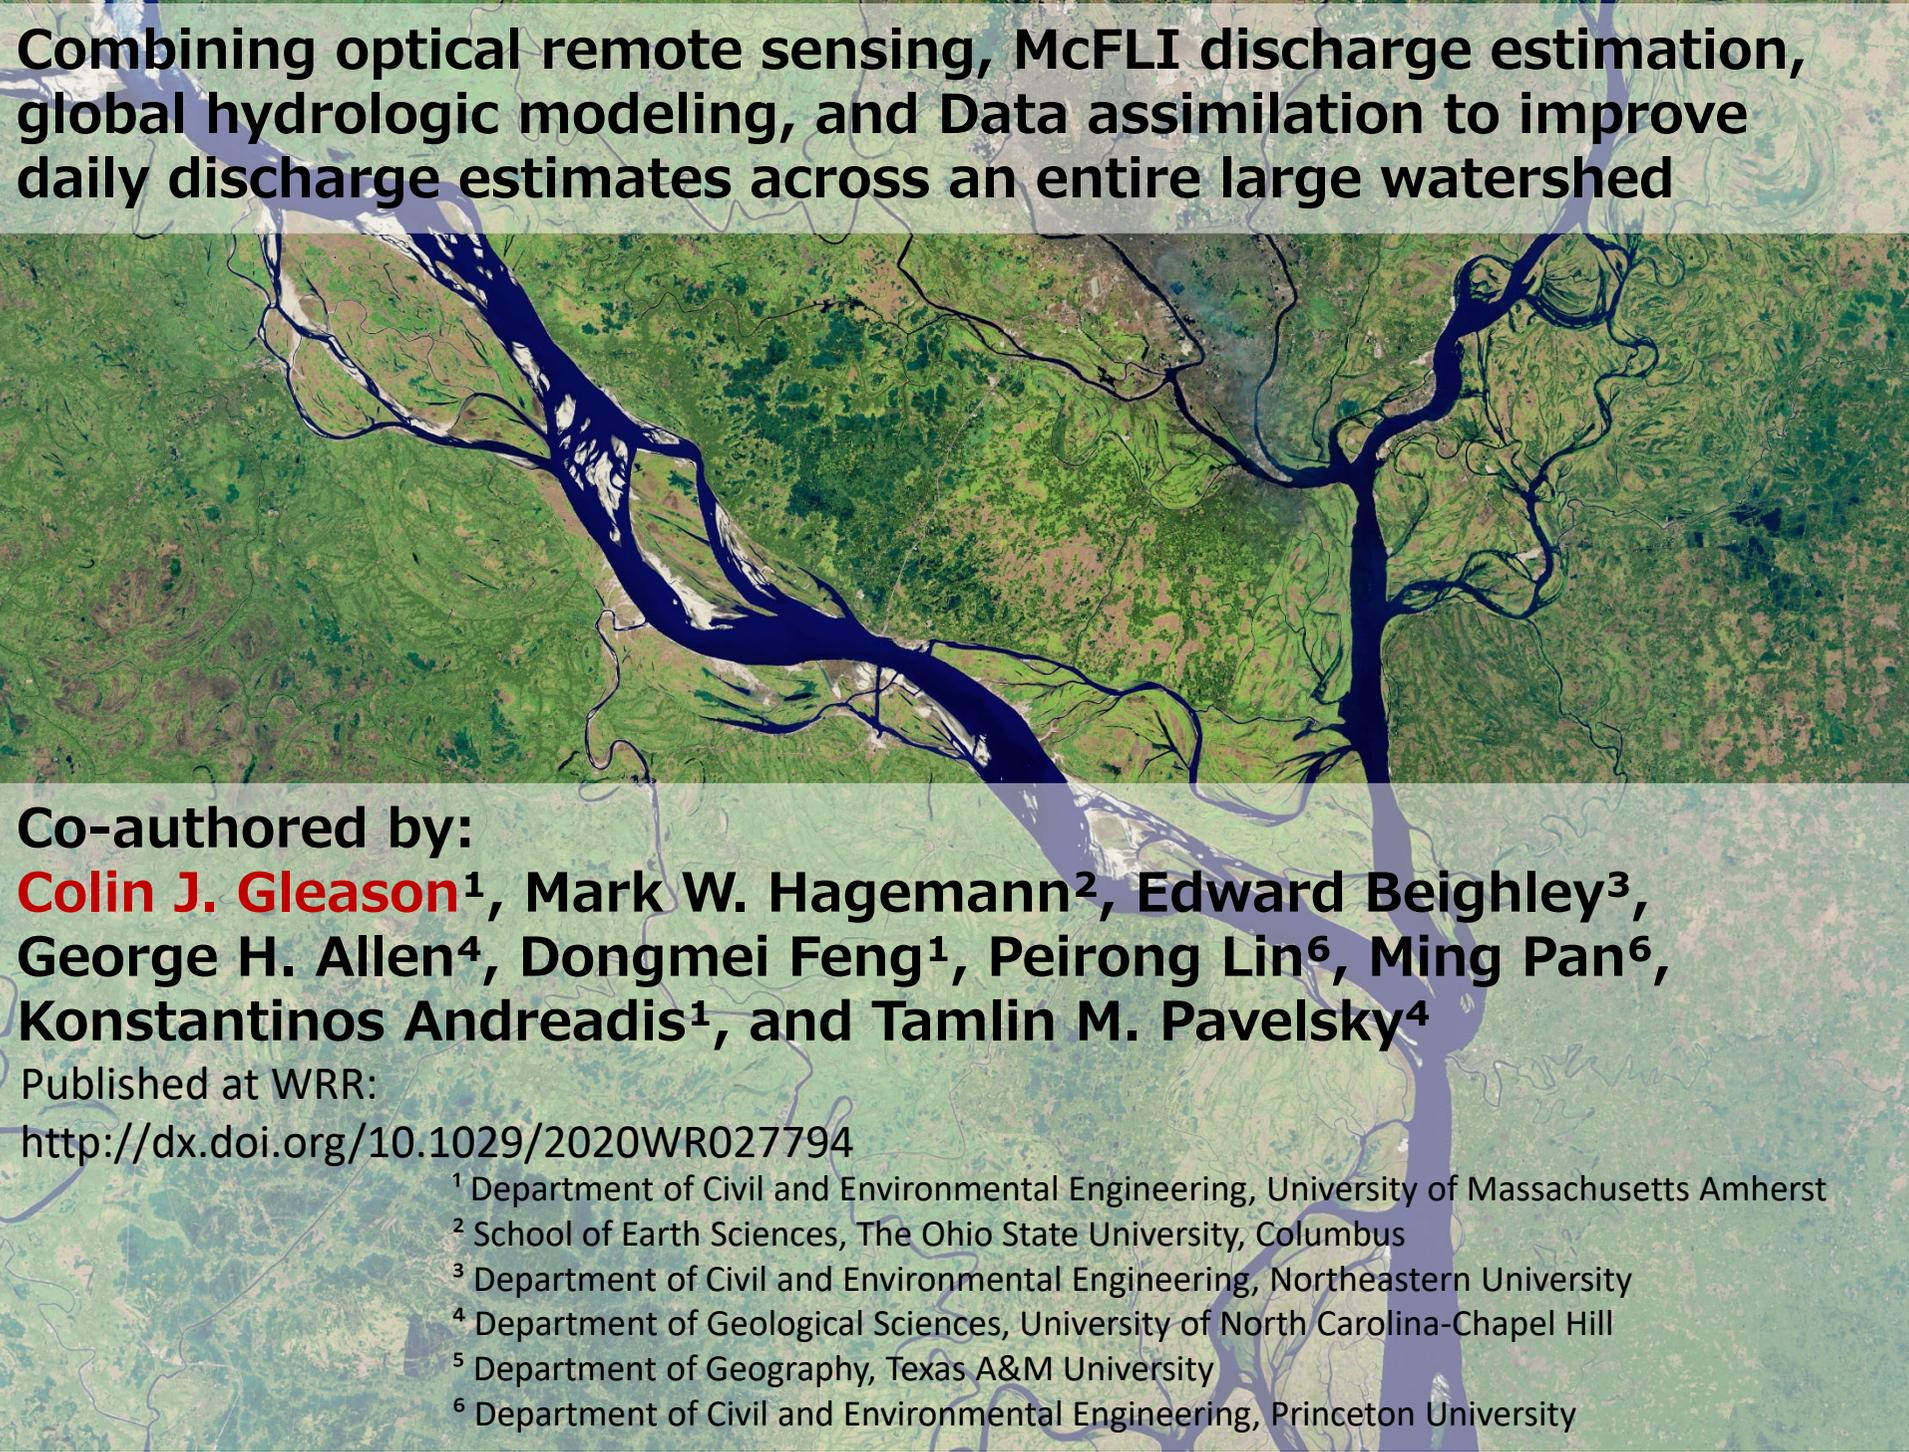
東京大学工学系研究科社会基盤学専攻 芳村研究室

- ・ 全球・日本域洪水予測システムの構築

University of Massachusetts, Amherst; Gleason lab.

- ・ 衛星画像と数値モデルのデータ同化
- ・ 衛星画像からの流量推定アルゴリズムの構築
- ・ 現地観測データの収集

2015年鬼怒川洪水  
発表者撮影



**Combining optical remote sensing, McFLI discharge estimation, global hydrologic modeling, and Data assimilation to improve daily discharge estimates across an entire large watershed**

**Co-authored by:**

**Colin J. Gleason<sup>1</sup>, Mark W. Hagemann<sup>2</sup>, Edward Beighley<sup>3</sup>, George H. Allen<sup>4</sup>, Dongmei Feng<sup>1</sup>, Peirong Lin<sup>6</sup>, Ming Pan<sup>6</sup>, Konstantinos Andreadis<sup>1</sup>, and Tamlin M. Pavelsky<sup>4</sup>**

Published at WRR:

<http://dx.doi.org/10.1029/2020WR027794>

<sup>1</sup> Department of Civil and Environmental Engineering, University of Massachusetts Amherst

<sup>2</sup> School of Earth Sciences, The Ohio State University, Columbus

<sup>3</sup> Department of Civil and Environmental Engineering, Northeastern University

<sup>4</sup> Department of Geological Sciences, University of North Carolina-Chapel Hill

<sup>5</sup> Department of Geography, Texas A&M University

<sup>6</sup> Department of Civil and Environmental Engineering, Princeton University

# Introduction

An aerial photograph of a river network in a lush green landscape. The main river is a thick, dark blue line that winds through the terrain, branching into smaller, thinner channels. The surrounding land is a mix of vibrant green and brownish-green, indicating different vegetation and soil types. The overall scene is a complex, branching pattern of waterways.

河川流量は水資源・水防災の上で重要な水文量の一つ  
流量の推定・予測は水文学における主要課題の一つとして扱われてきた

[Brown et al., 2015 p.6619]

# Introduction

An aerial photograph of a river network in a lush green landscape. The main river is dark blue and flows from the top left towards the bottom right. It branches into many smaller, winding tributaries that create a complex web across the terrain. The surrounding land is a mix of vibrant green and some brownish patches, suggesting a natural, possibly forested or agricultural, environment.

河川流量は水資源・水防災の上で重要な水文量の一つ  
流量の推定・予測は水文学における主要課題の一つとして扱われてきた

[Brown et al., 2015 p.6619]

河川流量を最も正確・高頻度に得る方法はGaugeによる地点観測  
ただし維持費用が高く、世界的なデータ量は年々減少  
国際河川データは政治的な影響も受ける

[Gleason and Hamdan, 2015]

# Introduction

An aerial photograph of a river network in a lush green landscape. The main river is dark blue and flows from the top left towards the bottom right. Numerous smaller tributaries branch off from the main river, creating a complex web of waterways. The surrounding land is covered in dense green vegetation, with some brownish patches indicating different types of terrain or land use.

河川流量は水資源・水防災の上で重要な水文量の一つ  
流量の推定・予測は水文学における主要課題の一つとして扱われてきた

[Brown et al., 2015 p.6619]

河川流量を最も正確・高頻度に得る方法はGaugeによる地点観測  
ただし維持費用が高く、世界的なデータ量は年々減少  
国際河川データは政治的な影響も受ける

[Gleason and Hamdan, 2015]

水文モデルは流量の将来予測やモニタリングに用いられる  
現地観測データはこうした数値モデルの検証・補正にも必要  
その意味でも地点観測データの減少は問題

[Gleason and Durand, 2020]

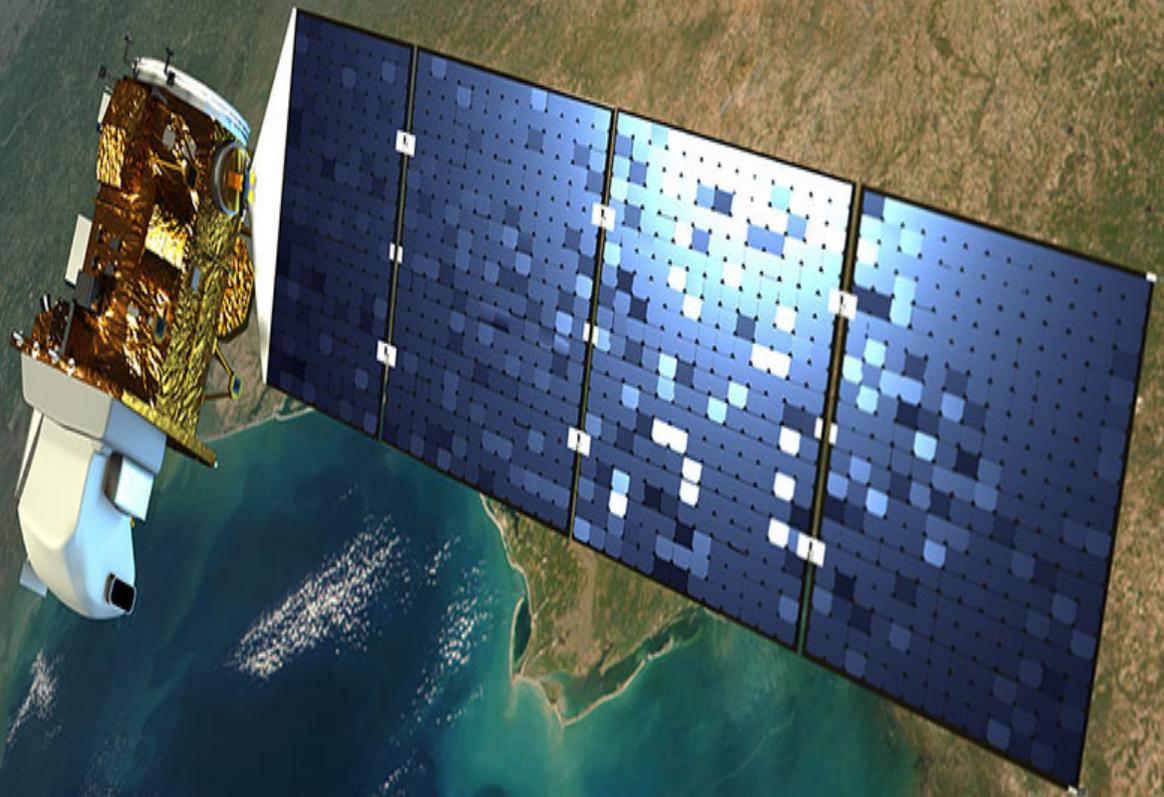
## 衛星観測

- ✓ 全球/広域をカバー
- ✓ 高い空間分解能
- 時間解像度が低い（Public satelliteでは～数日）
  - 可視光の場合は天候の影響も受ける

既に様々な衛星が観測を継続中

- Landsat series, Sentinel series, GRACE, etc.

新規衛星ミッションも進行中

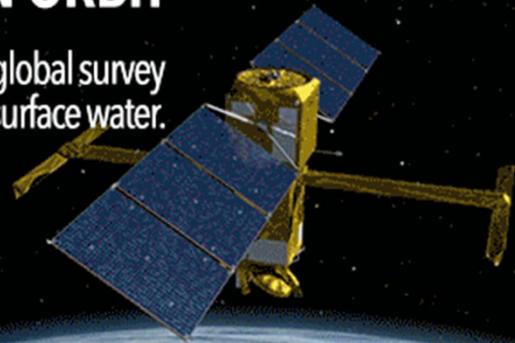


## SWOT Mission

- ✓ 全球をカバー
- ✓ 21日周期で1~7回観測
- ✓ 川幅・水面標高・水面傾斜を観測

### SWOT IN ORBIT

Will provide NASA's first global survey  
of Earth's surface water.



## SWOT Mission

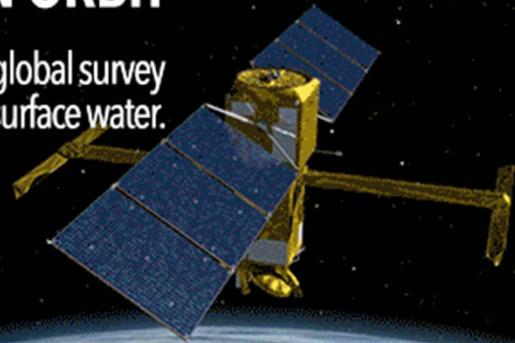
- ✓ 全球をカバー
- ✓ 21日周期で1~7回観測
- ✓ 川幅・水面標高・水面傾斜を観測

## Mass Conserved Flow Low Inversion Algorithms (McFLI)

- 川幅や水面標高が分かれば、衛星観測から流量を求められるのでは？
- 必要な未知パラメータはベイズ的に推定
- 既に多くのアルゴリズムが提唱され合成データで検証済 [Durand et al., 2016]

## SWOT IN ORBIT

Will provide NASA's first global survey  
of Earth's surface water.



## SWOT Mission

- ✓ 全球をカバー
- ✓ 21日周期で1~7回観測
- ✓ 川幅・水面標高・水面傾斜を観測

## Mass Conserved Flow Low Inversion Algorithms (McFLI)

- 川幅や水面標高が分かれば、衛星観測から流量を求められるのでは？
- 必要な未知パラメータはベイズ的に推定
- 既に多くのアルゴリズムが提唱され合成データで検証済 [Durand et al., 2016]

一方で、McFLIアルゴリズム群の有用性は合成データでしか検証されていない

- 多くのアルゴリズムは水面標高を必要とする
- SWOT打ち上げまではデータが存在しない
- 例：
  - 各アルゴリズムのレビューと河口での精度比較 [Durand et al., 2016]
  - SWOT観測のデータ同化と河川パラメータ推定 [Andreadis et al., 2020]

## SWOT Mission

- ✓ 全球をカバー
- ✓ 21日周期で1~7回観測
- ✓ 川幅・水面標高・水面傾斜を観測

## Mass Conserved Flow Low Inversion Algorithms (McFLI)

- 川幅や水面標高が分かれば、衛星観測から流量を求められるのでは？
- 必要な未知パラメータはベイズ的に推定
- 既に多くのアルゴリズムが提唱され合成データで検証済 [Durand et al., 2016]

一方で、McFLIアルゴリズム群の有用性は合成データでしか検証されていない

- 多くのアルゴリズムは水面標高を必要とする
- SWOT打ち上げまではデータが存在しない
- 例：
  - 各アルゴリズムのレビューと河口での精度比較 [Durand et al., 2016]
  - SWOT観測のデータ同化と河川パラメータ推定 [Andreadis et al., 2020]

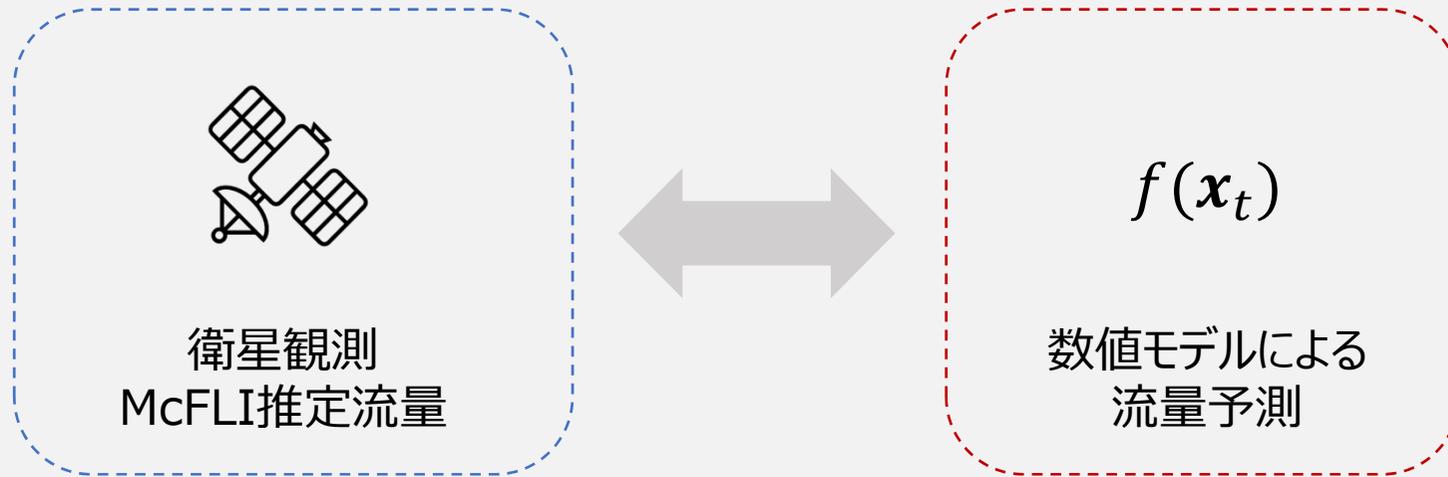
実観測を用いても有用性を証明できるだろうか？

- 川幅だけで動作するアルゴリズムが存在
  - 既存の可視光衛星を利用可能
- 推定流量の精度検証による有用性は一定証明済 [Feng et al., 2019]

# 本研究の目的

本研究の目的は大きく2つ：

- 数値モデルと衛星観測をマージすることで両者の強みを活かす
  - これ自体は多くの既往研究有 [e.g., Andreadis and Lettenmaier 2006; Durand et al., 2008; Beighley et al., 2011; Emery et al., 2019;2020; Oubanas et al., 2018]
- 上記によるMcFLIデータの有用性検証



## メリット

- 観測ベース

## デメリット

- 時間解像度が低い

## メリット

- 未観測地域にも適用可能
- 高時間解像度

## デメリット

- 精度向上にはキャリブレーションが必要

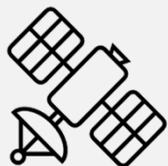
# 本研究の流れ

## メリット

- 観測ベース

## デメリット

- 時間解像度が低い



人工衛星からの画像取得  
プレプロセス



衛星観測された川幅から  
流量を推定



全球Runoffデータ  
[Lin et al., 2019]

$$f(x_t)$$

数値モデルによる  
流量予測

## メリット

- 未観測地域にも適用可能
- 高時間解像度

## デメリット

- 精度向上にはキャリブレーションが必要



モデル流量とマージ  
(データ同化)

**両者のメリットを活用**

# 本研究の流れ

## メリット

- 観測ベース

## デメリット

- 時間解像度が低い



人工衛星からの画像取得  
プレプロセス



衛星観測された川幅から  
流量を推定



全球Runoffデータ  
[Lin et al., 2019]

$$f(x_t)$$

数値モデルによる  
流量予測

## メリット

- 未観測地域にも適用可能
- 高時間解像度

## デメリット

- 精度向上にはキャリブレーションが必要



モデル流量とマージ  
(データ同化)

両者のメリットを活用

# Google Earth Engine (GEE)

Google Earth Engine Search places and datasets...

Scripts Docs Assets

Filter scripts... NEW

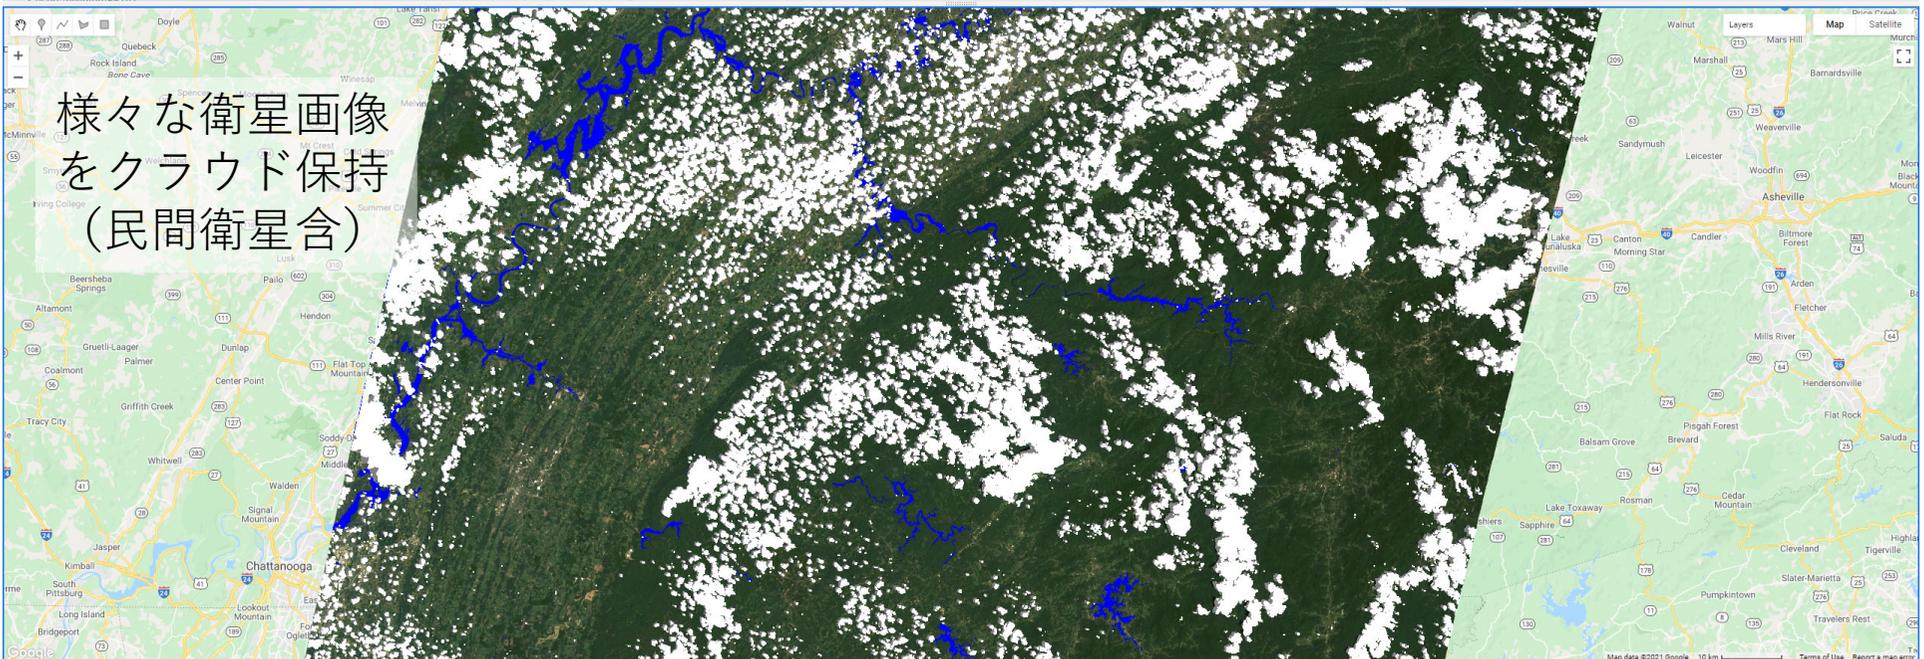
- Owner (2)
  - users/winz718/default
    - EE\_intro\_2nd
    - Missouri\_Yellowstone
    - NWDL\_FMASK
    - UntitledFile
    - myFirstee
    - tan\_beta
  - users/winz718/levee\_detection
    - fetch\_image
    - hydrosheds
    - playground
- Writer
  - No accessible repositories. Click Refresh to check again.
- Reader (1)
  - users/winz718/EE01

```
1 var geometry = ee.Geometry.Rectangle([-104.028110, -47.994577, -103.919481, -47.930000]);
2 var dataset = ee.ImageCollection('LANDSAT/LC08/C01/T1_SR')
3   .filterDate('2017-07-17', '2017-07-18')
4   .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 100))
5   .mosaic()
6   .clip(geometry);
7 print(dataset);
8 var mndwiThreshold = 0.1;
9 var mndwi = dataset.normalizedDifference(['B3', 'B6']).rename('MNDWI');
10 var mndwi = mndwi.updateMask(mndwi.gt(mndwiThreshold), 1);
11
12 var cloudShadowBitMask = (1 << 3);
13 var cloudShadow = dataset
14   .select('pixel_qa')
15   .bitwiseAnd(cloudShadowBitMask)
16   .eq(0)
17   var cloudShadow = cloudShadow
18     .updateMask(cloudShadow.eq(0))
19
20 var cloudsBitMask = (1 << 1);
21 var clouds = dataset
22   .select('pixel_qa')
```

Inspector Console Tasks

Use print(...) to write to this console.

\* Image (12 bands) 350W

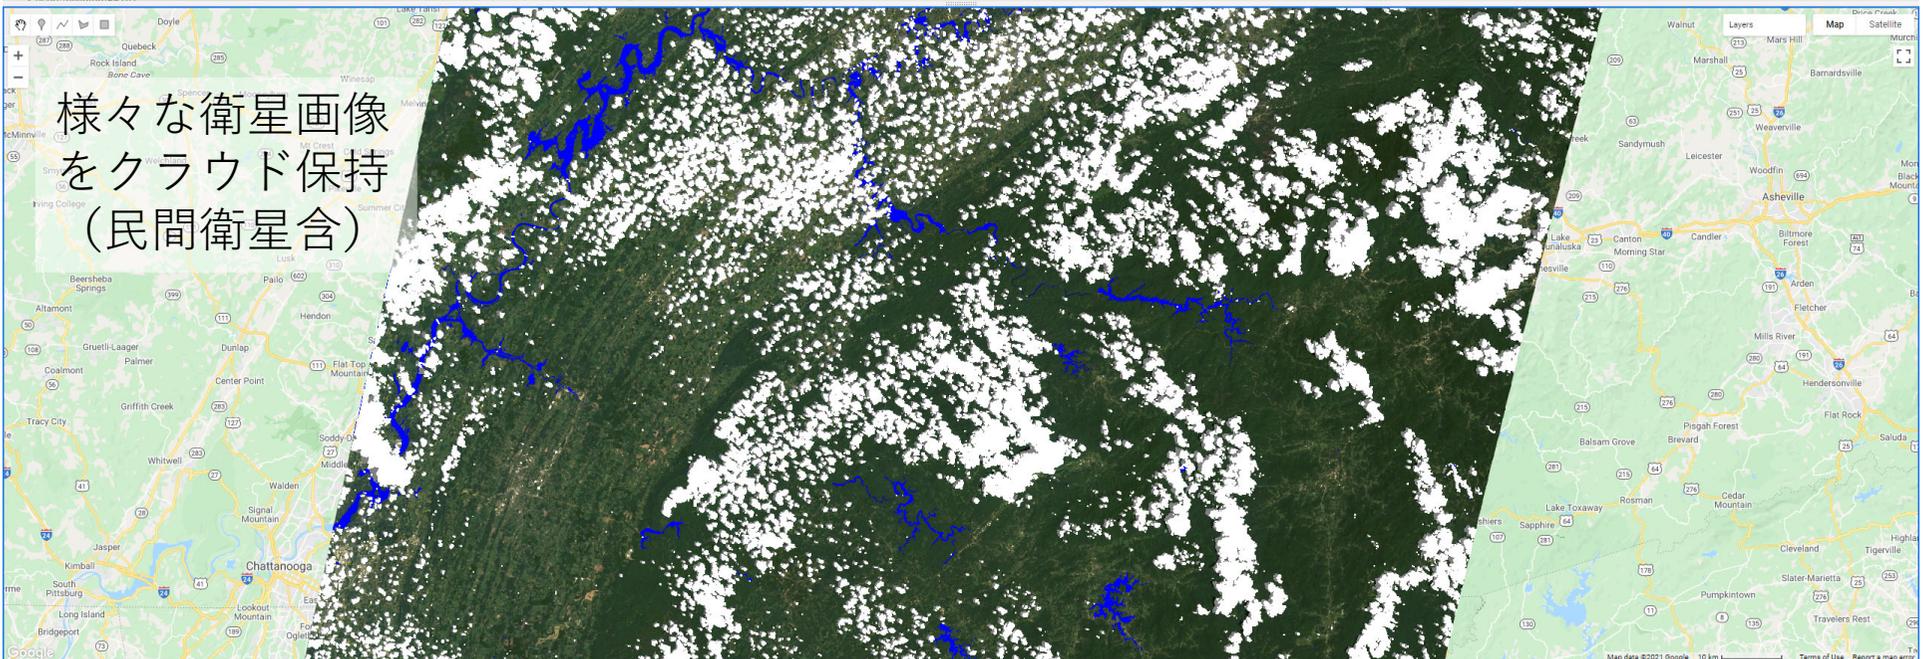


# Google Earth Engine (GEE)

過去のコードはクラウドに保存  
オリジナルデータのアップロードも可能



The screenshot shows the Google Earth Engine web interface. On the left, there is a sidebar with a search bar and a list of scripts under the 'Owner' section. The main area is a script editor titled 'NWDL\_FMASK \*' containing JavaScript code for processing satellite data. The code includes steps for defining geometry, loading a dataset, filtering by date and cloud percentage, and calculating cloud shadow and bit masks. On the right, there is an 'Inspector' and 'Console' panel showing the output of the script, which is an image with 12 bands.



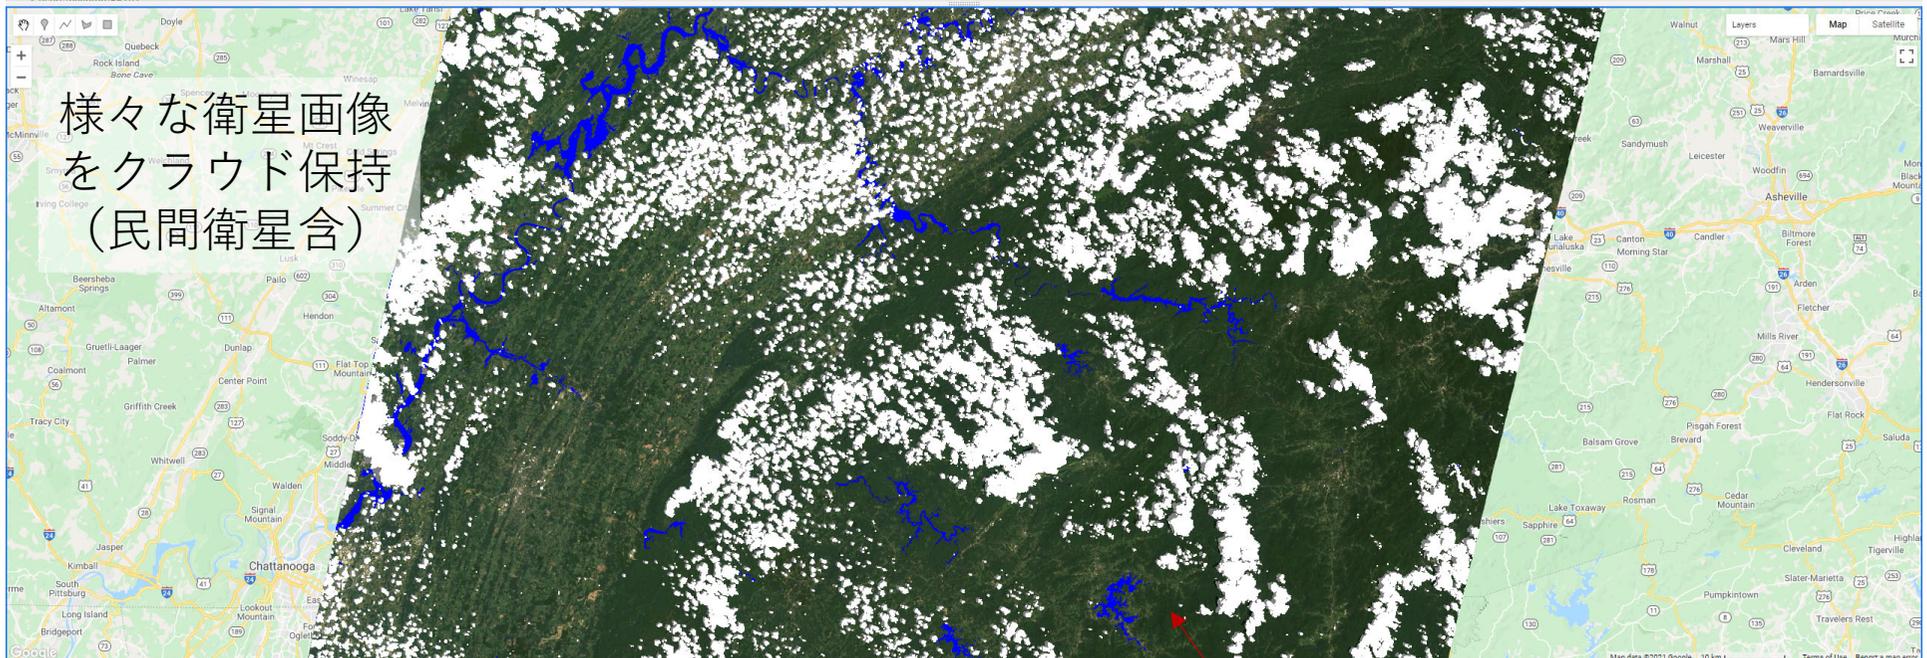
The image shows a satellite view of a forested area with a blue river network overlaid. The text '様々な衛星画像をクラウド保持 (民間衛星含)' is overlaid on the left side of the image. The background is a map showing the location of the satellite image, with various cities and roads visible. The text 'Map data ©2021 Google' is visible at the bottom right of the map.



# Google Earth Engine (GEE)

過去のコードはクラウドに保存  
オリジナルデータのアップロードも可能

Javascriptで処理を記載  
Python APIもあり



処理はGoogleのサーバー上で自動で逐次並列化  
されて実行されるため非常に高速

Interactiveに処理結果を確認

# 本研究の流れ

## メリット

- 観測ベース

## デメリット

- 時間解像度が低い



人工衛星からの画像取得  
プレプロセス



衛星観測された川幅から  
流量を推定



全球Runoffデータ  
[Lin et al., 2019]

$$f(x_t)$$

数値モデルによる  
流量予測

## メリット

- 未観測地域にも適用可能
- 高時間解像度

## デメリット

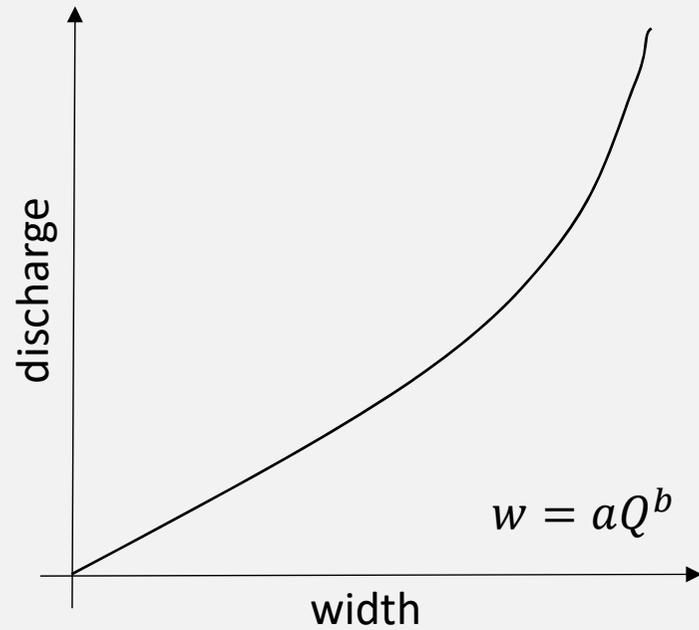
- 精度向上にはキャリブレーションが必要



モデル流量とマージ  
(データ同化)

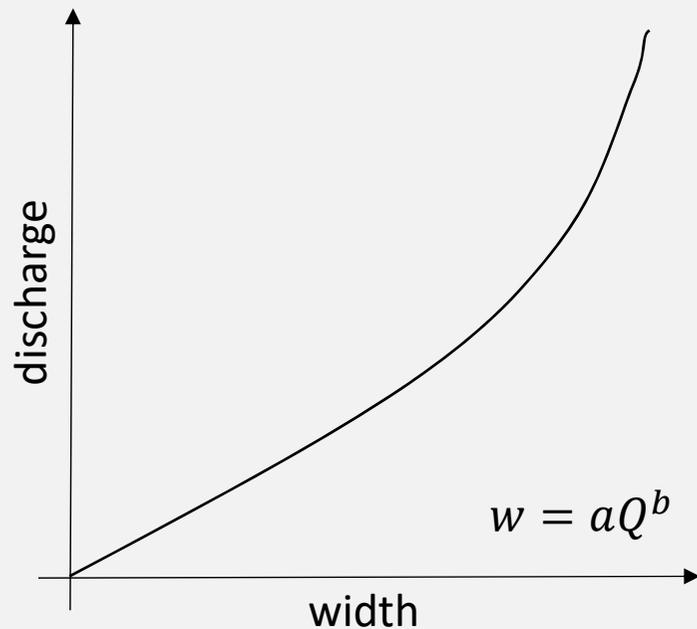
両者のメリットを活用

# 人工衛星からの流量推定



- a-priori*に川幅-流量関係が分かれば：  
所与の川幅に対して流量が計算できる
- (a,b)の推定には過去観測が必要

# 人工衛星からの流量推定



*a-priori*に川幅-流量関係が分かれば：  
所与の川幅に対して流量が計算できる

- (a,b)の推定には過去観測が必要

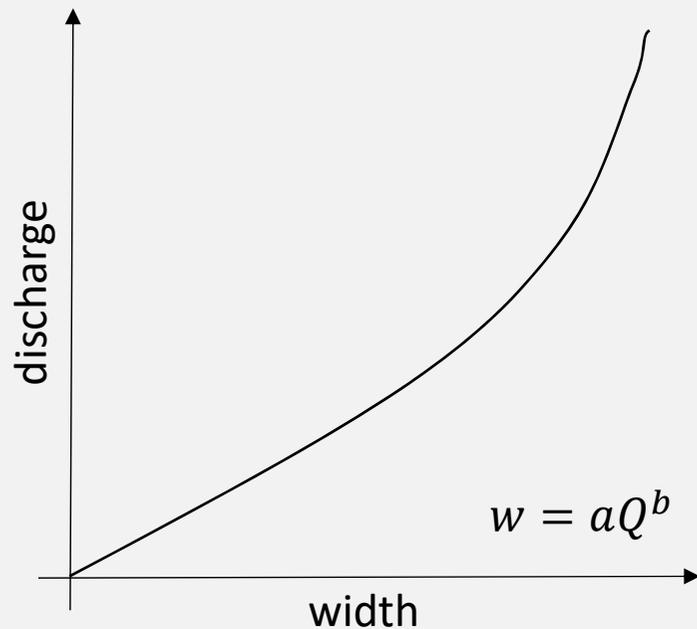
Gleason et al., (2014)は流域内で成り立つ  
このaとbの関係を発見 (a.k.a., AMHG).



Brinkerhoff et al., (2019) はこの関係  
がDingmanの河道パラメタライゼーションから  
数学的に導出できることを示した。

[Brinkerhoff et al., 2019]

# 人工衛星からの流量推定



*a-priori*に川幅-流量関係が分かれば：  
所与の川幅に対して流量が計算できる

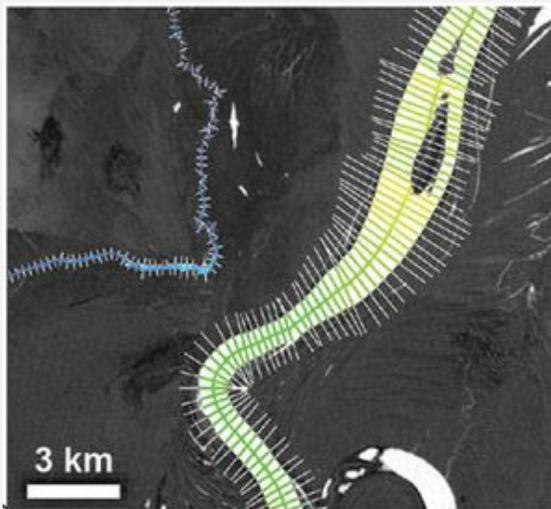
- (a,b)の推定には過去観測が必要

Gleason et al., (2014)は流域内で成り立つこのaとbの関係を発見 (a.k.a., AMHG).



Brinkerhoff et al., (2019)はこの関係がDingmanの河道パラメタライゼーションから数学的に導出できることを示した。

[Brinkerhoff et al., 2019]

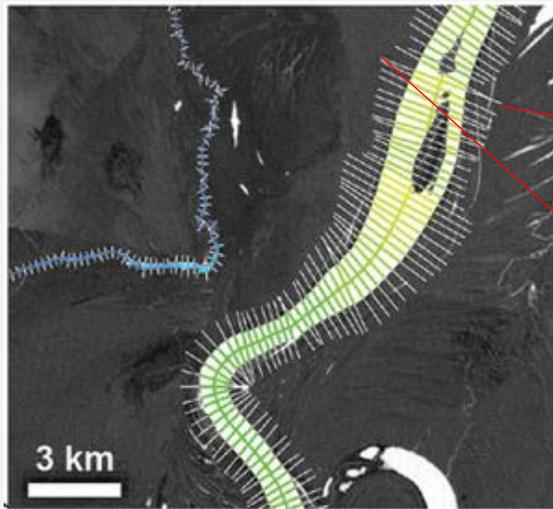


## Ill-posed problem

流量 $Q$ をAMHGと衛星画像を用いて推定するには：

- 必要なパラメータ
  - $w$ ,  $b$ , and AMHG parameters
- 衛星から観測できるパラメータ
  - $w$ のみ

# AMHGのベイズ的再構築 [BAM] [Hageman et al., 2017]

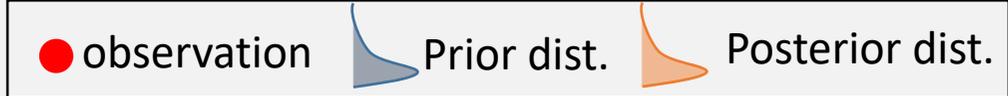
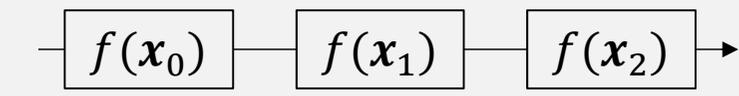
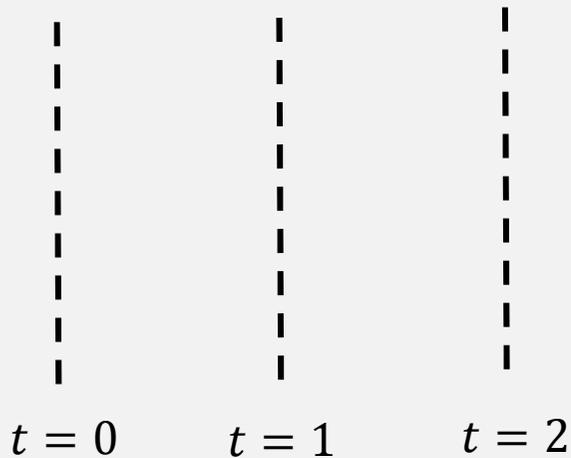


Known  
[ $w$ ]

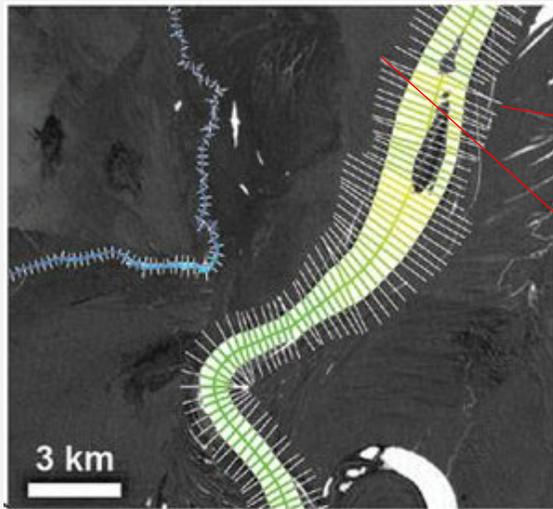
Unknown  
[ $Q, b, \text{etc.}$ ]

ベイズ更新を用いて既知の $w$ から未知のパラメタ/流量を推定

1. 未知パラメタの事前分布と $Q$ の初期分布を設定



# AMHGのベイズ的再構築 [BAM] [Hageman et al., 2017]



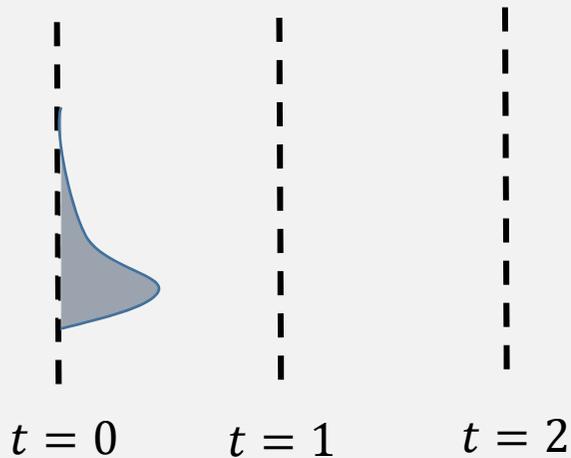
Known  
[ $w$ ]

Unknown  
[ $Q, b, \text{etc.}$ ]

ベイズ更新を用いて既知の $w$ から未知のパラメタ/流量を推定

1. 未知パラメタの事前分布と $Q$ の初期分布を設定
2.  $w$ の分布（尤度分布）を上から計算

$$w = aQ^b$$



$t = 0$        $t = 1$        $t = 2$

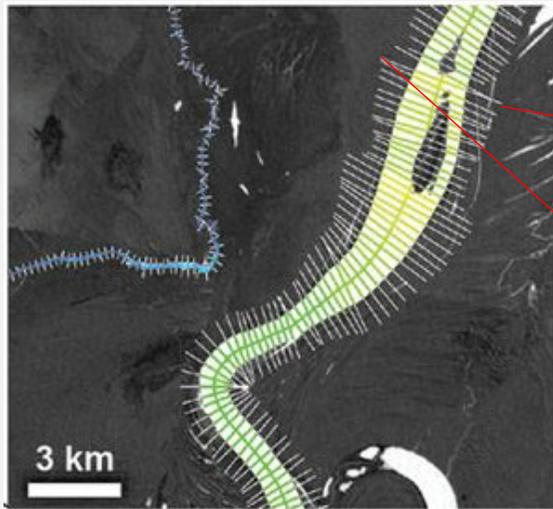
$f(x_0)$     $f(x_1)$     $f(x_2)$  →

● observation

▲ Prior dist.

▲ Posterior dist.

# AMHGのベイズ的再構築 [BAM] [Hageman et al., 2017]

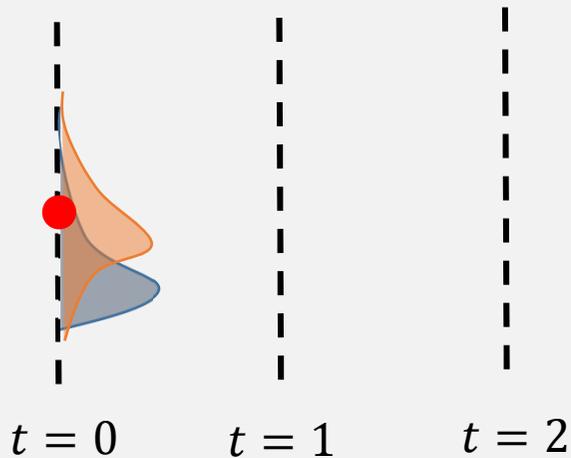


Known  
[w]

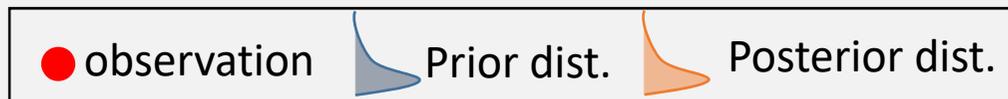
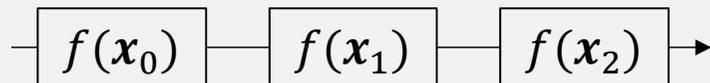
Unknown  
[Q, b, etc.]

ベイズ更新を用いて既知のwから未知のパラメタ/流量を推定

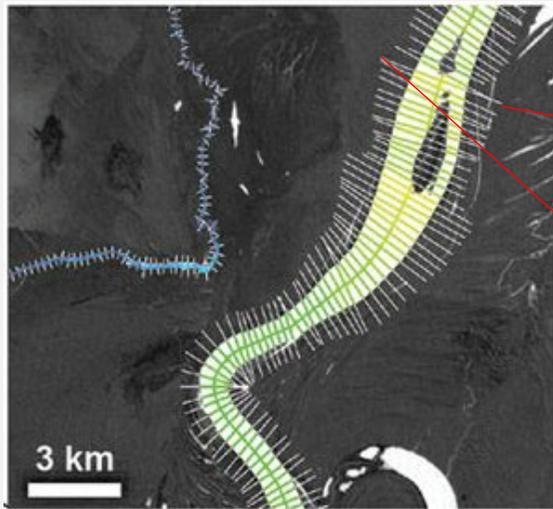
1. 未知パラメタの事前分布とQの初期分布を設定
2. wの分布（尤度分布）を上から計算
3. ベイズの定理を用いてパラメタ事前分布とQの分布を更新



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



# AMHGのベイズ的再構築 [BAM] [Hageman et al., 2017]

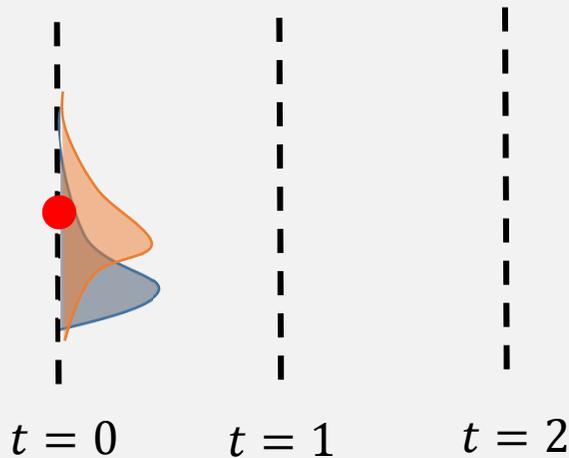


Known  
[ $w$ ]

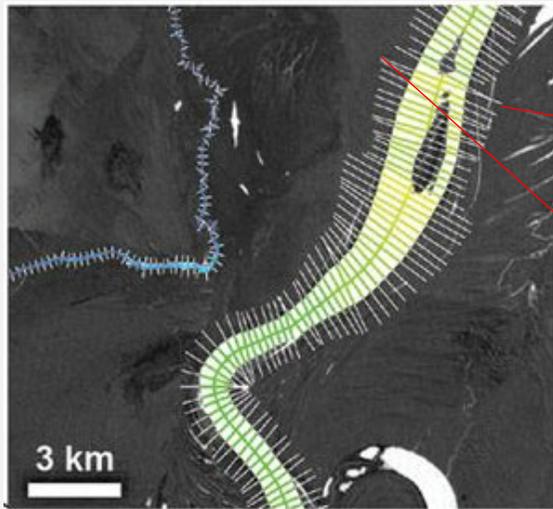
Unknown  
[ $Q, b, \text{etc.}$ ]

ベイズ更新を用いて既知の $w$ から未知のパラメタ/流量を推定

1. 未知パラメタの事前分布と $Q$ の初期分布を設定
2.  $w$ の分布（尤度分布）を上から計算
3. ベイズの定理を用いてパラメタ事前分布と $Q$ の分布を更新
4. 時刻0における $Q$ を得る



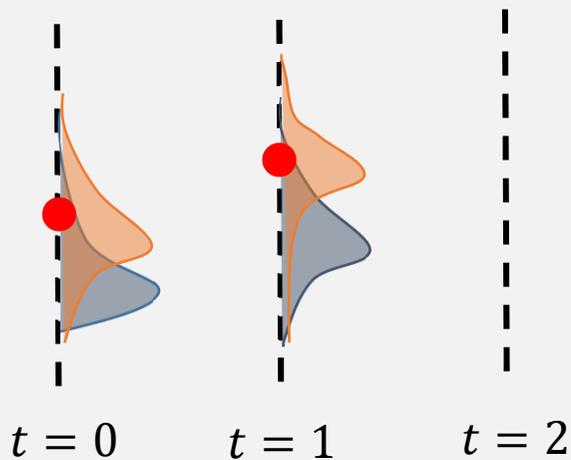
# AMHGのベイズ的再構築 [BAM] [Hageman et al., 2017]



Known  
[ $w$ ]

Unknown  
[ $Q, b, \text{etc.}$ ]

ベイズ更新を用いて既知の $w$ から未知のパラメタ/流量を推定



1. 未知パラメタの事前分布と $Q$ の初期分布を設定
2.  $w$ の分布（尤度分布）を上から計算
3. ベイズの定理を用いてパラメタ事前分布と $Q$ の分布を更新
4. 時刻0における $Q$ を得る
5. 更新された分布を事前分布として上記を観測が得られる度に繰り返す

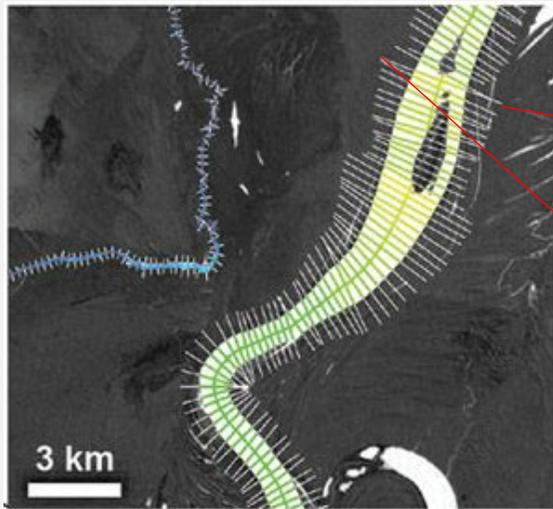
$f(x_0)$  —  $f(x_1)$  —  $f(x_2)$  →

● observation

▲ Prior dist.

▲ Posterior dist.

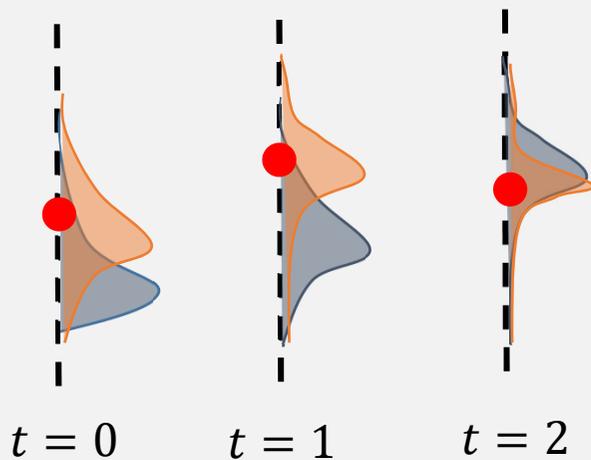
# AMHGのベイズ的再構築 [BAM] [Hageman et al., 2017]



Known  
[ $w$ ]

Unknown  
[ $Q, b, \text{etc.}$ ]

ベイズ更新を用いて既知の $w$ から未知のパラメタ/流量を推定



1. 未知パラメタの事前分布と $Q$ の初期分布を設定
2.  $w$ の分布（尤度分布）を上から計算
3. ベイズの定理を用いてパラメタ事前分布と $Q$ の分布を更新
4. 時刻0における $Q$ を得る
5. 更新された分布を事前分布として上記を観測が得られる度に繰り返す

$f(x_0)$  —  $f(x_1)$  —  $f(x_2)$  →

● observation

▲ Prior dist.

▲ Posterior dist.

# 本研究の流れ

## メリット

- 観測ベース

## デメリット

- 時間解像度が低い



人工衛星からの画像取得  
プレプロセス



衛星観測された川幅から  
流量を推定



全球Runoffデータ  
[Lin et al., 2019]

$$f(x_t)$$

数値モデルによる  
流量予測

## メリット

- 未観測地域にも適用可能
- 高時間解像度

## デメリット

- 精度向上にはキャリブレーションが必要



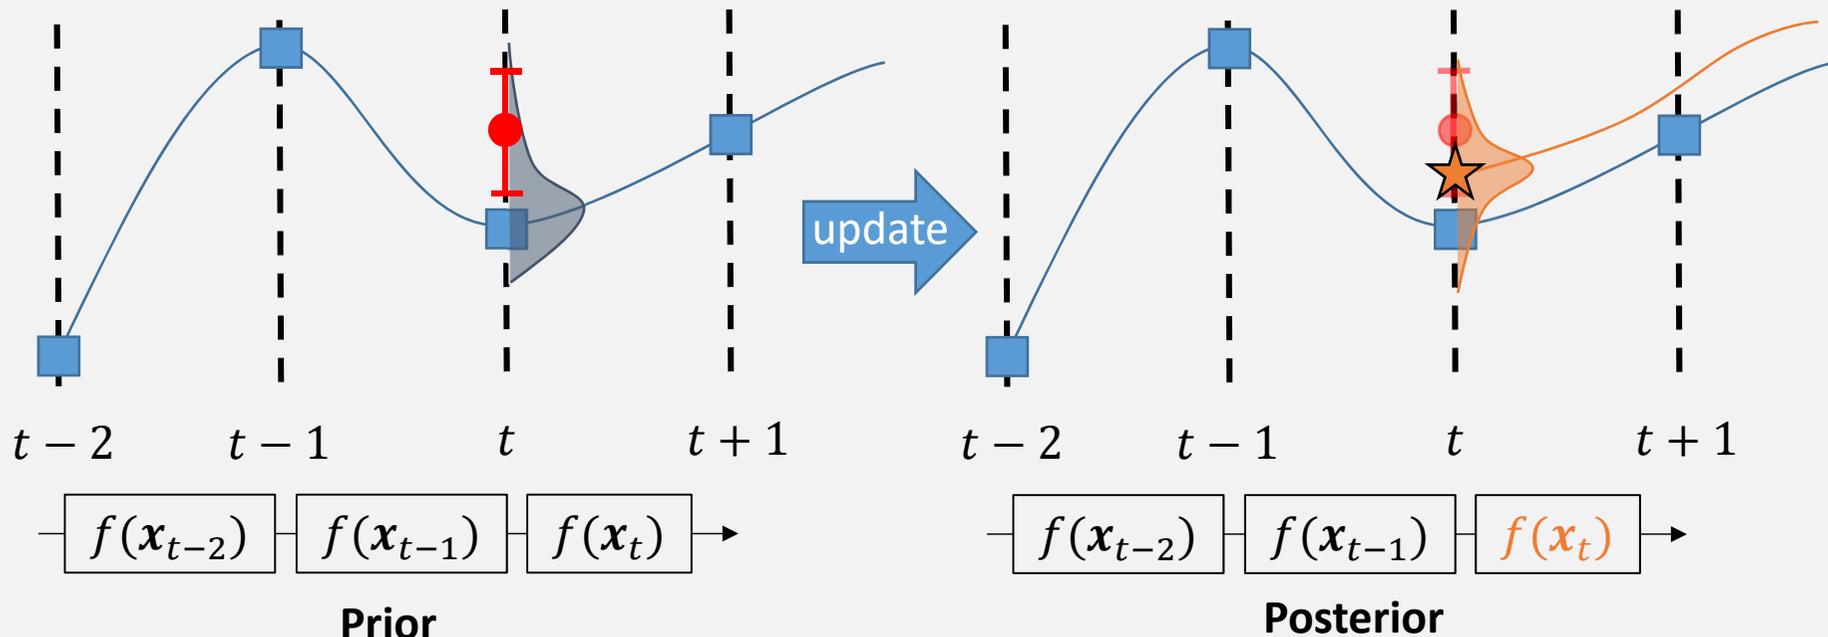
モデル流量とマージ  
(データ同化)

両者のメリットを活用

# データ同化概要

データ同化は観測を数値モデルに確率的にマージする手法

- Observation error
- Background error



- モデルからの事前推定 (分布)
- 観測誤差
- $x_t$  時刻  $t$  における状態
- $f(x_t)$  モデル
- ★ 解析 (i.e., 同化後の値)

分布をどう表現する？

1. 正規分布を仮定
2. アンサンブルで表現

# 本研究の流れ

## メリット

- 観測ベース

## デメリット

- 時間解像度が低い



人工衛星からの画像取得  
プレプロセス



衛星観測された川幅から  
流量を推定



全球Runoffデータ  
[Lin et al., 2019]

$$f(x_t)$$

数値モデルによる  
流量予測

## メリット

- 未観測地域にも適用可能
- 高時間解像度

## デメリット

- 精度向上にはキャリブレーションが必要



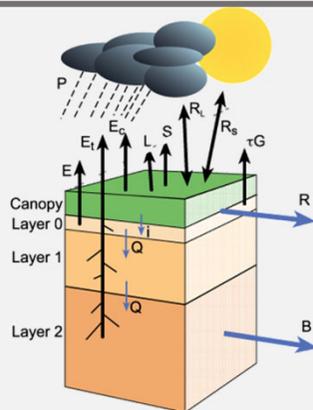
モデル流量とマージ  
(データ同化)

**両者のメリットを活用**

# Methods – 概要



**MERIT-HYDRO**  
[Yamazaki et al., 2019]

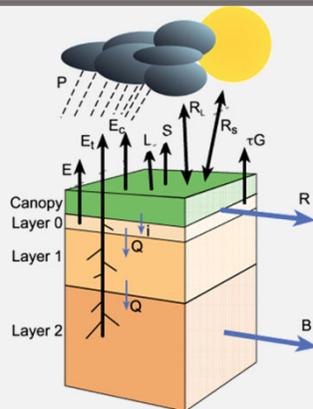


**Global Hydrological  
Reconstruction (Runoff)**  
[Lin et al., 2019]

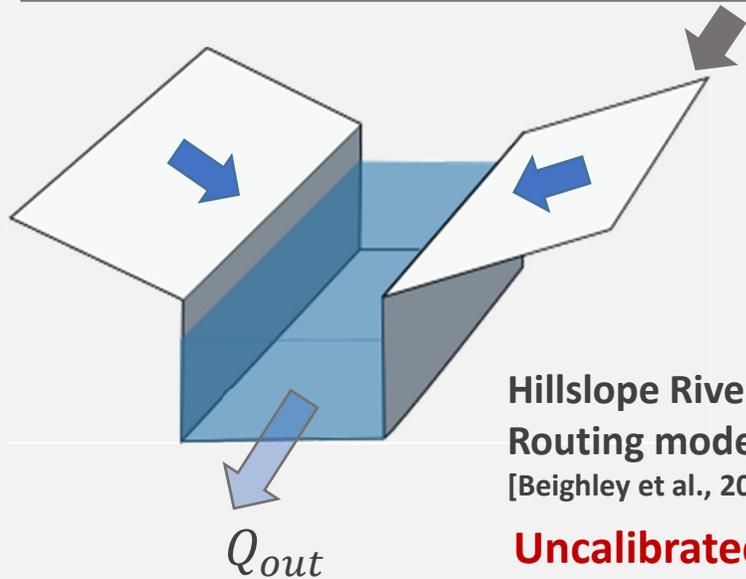
# Methods – 概要



MERIT-HYDRO  
[Yamazaki et al., 2019]



Global Hydrological  
Reconstruction (Runoff)  
[Lin et al., 2019]



Hillslope River  
Routing model  
[Beighley et al., 2009]

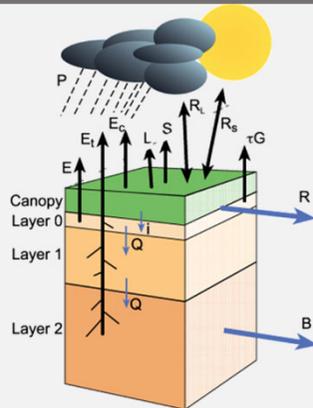
**Uncalibrated**

“baseline”

# Methods – 概要

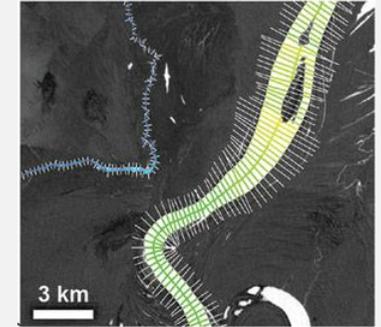


MERIT-HYDRO  
[Yamazaki et al., 2019]

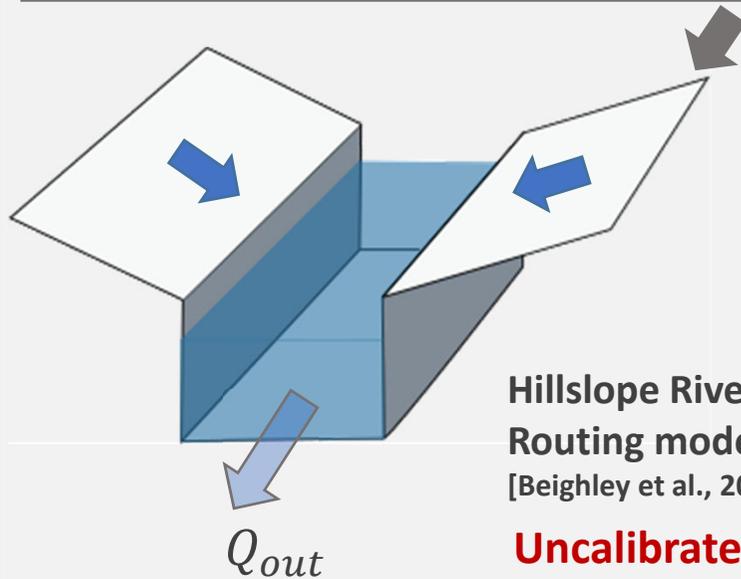


Global Hydrological  
Reconstruction (Runoff)  
[Lin et al., 2019]

River width  
extraction from Landsat  
[Allen and Pavelsky, 2018;  
Yang et al., 2019]



Discharge estimation  
via BAM algorithm  
[Hageman et al., 2017]



Hillslope River  
Routing model  
[Beighley et al., 2009]

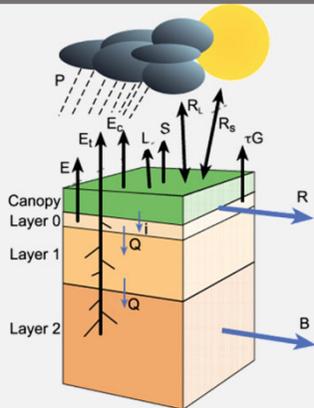
**Uncalibrated**

“baseline”

# Methods – 概要

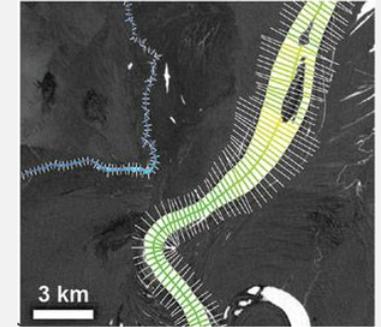


**MERIT-HYDRO**  
[Yamazaki et al., 2019]



**Global Hydrological Reconstruction (Runoff)**  
[Lin et al., 2019]

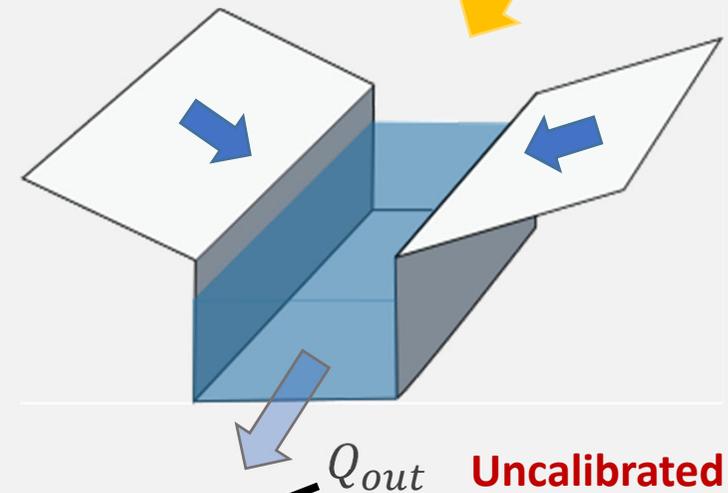
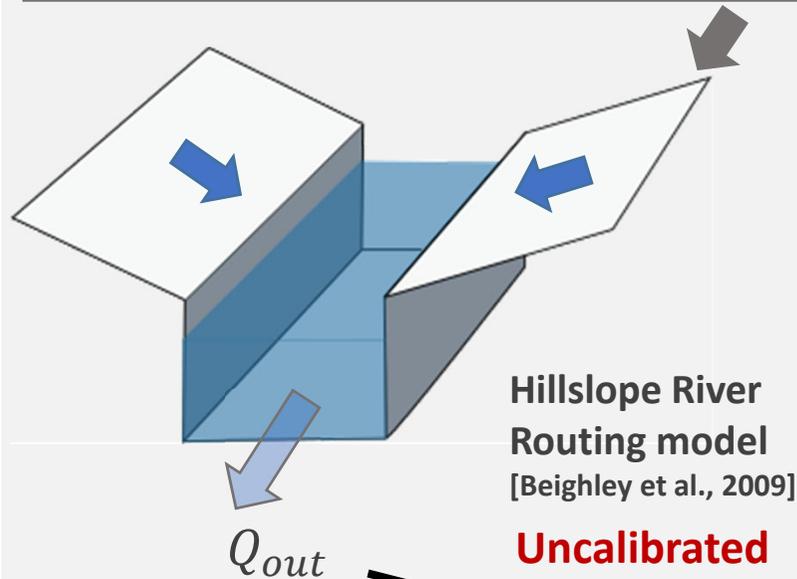
River width extraction from Landsat  
[Allen and Pavelsky, 2018; Yang et al., 2019]



Discharge estimation via BAM algorithm  
[Hageman et al., 2017]



Data Assimilation ( $Q_{flw}$ )

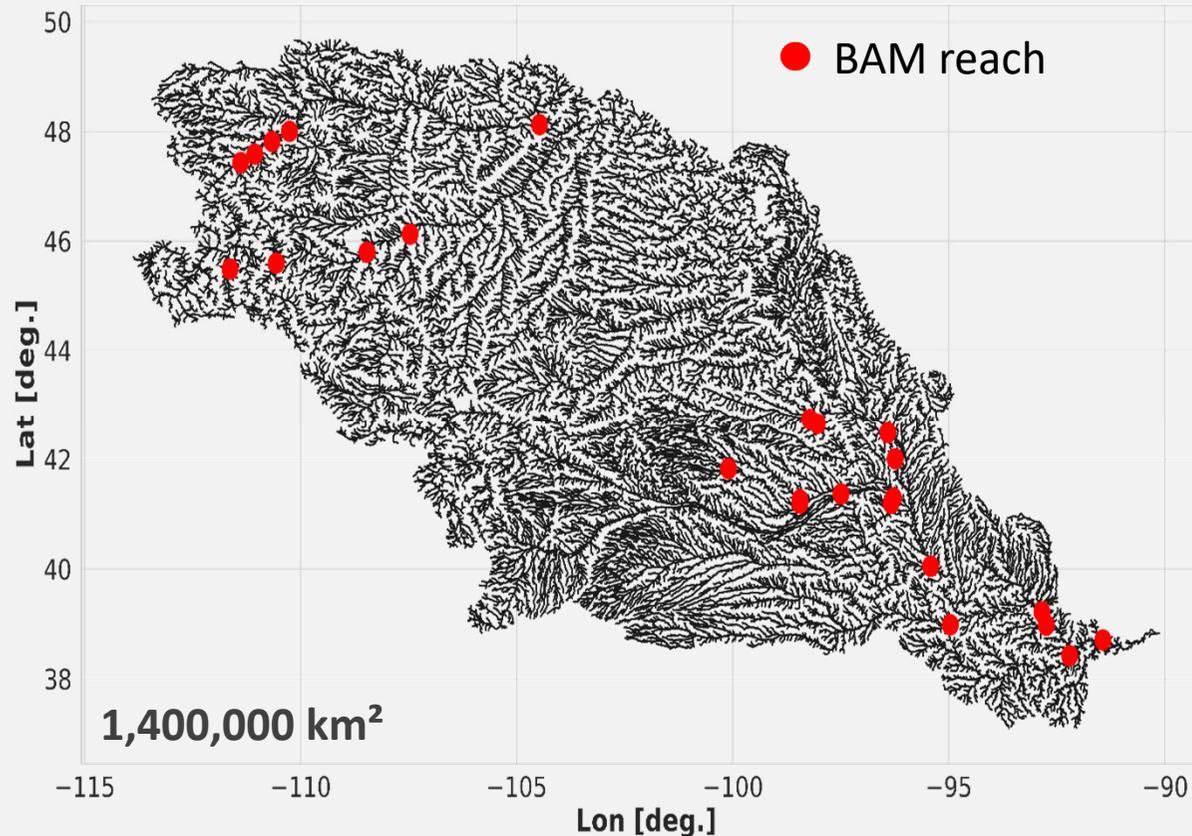


**“baseline”**

gauge discharge observation

**“this study”**

# Methods – 実験設定



Missouri Basin and BAM reaches



観測河川は43だけ？

Random errorを除去するため  
複数の川幅観測を平均

Test流域:

Missouri basin  
(30,000 reaches)

計算期間:

2002 – 2011 (10 years)

Daily

モデル解像度:

10-5km (ベクター)

BAM観測:

43 reaches

同化アルゴリズム:

LETKF [Hunt et al., 2008]

20 ensembles

# Validation metrics

## NSE

Nash-Sutcliffe Efficiency

- 年平均観測流量とどちらが予測精度が良いかを示す
- $> 0$  でモデルの方が精度良

## NRMSE

Normalized Root Mean Square Error

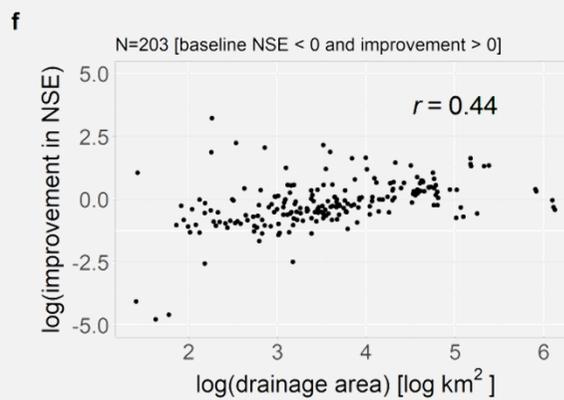
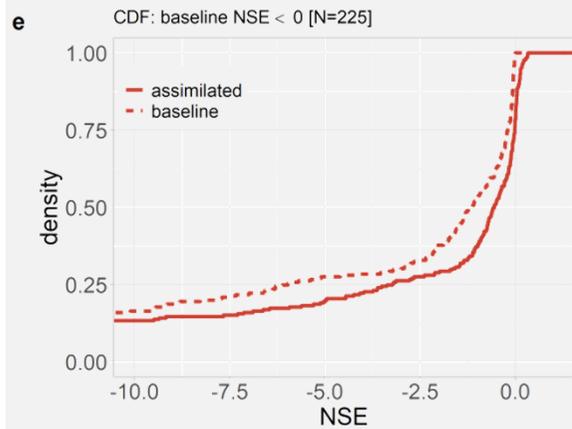
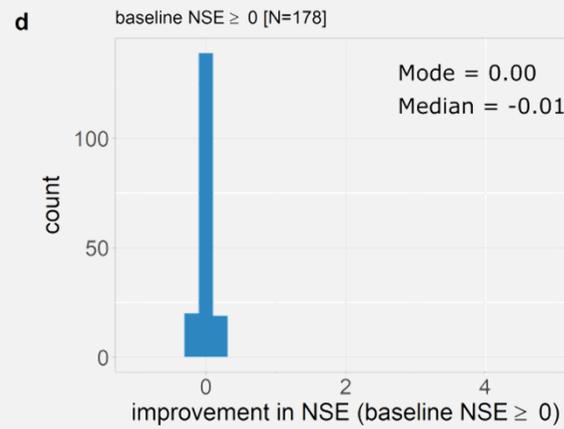
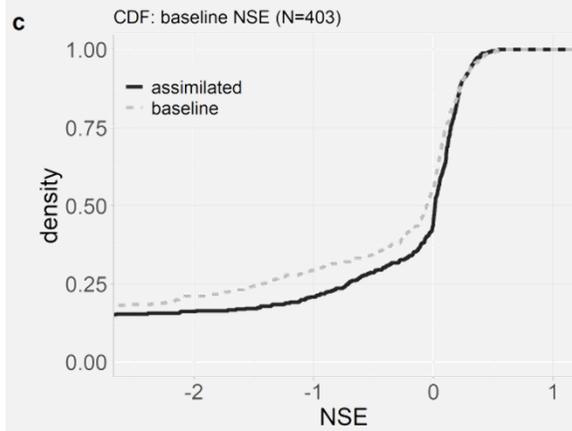
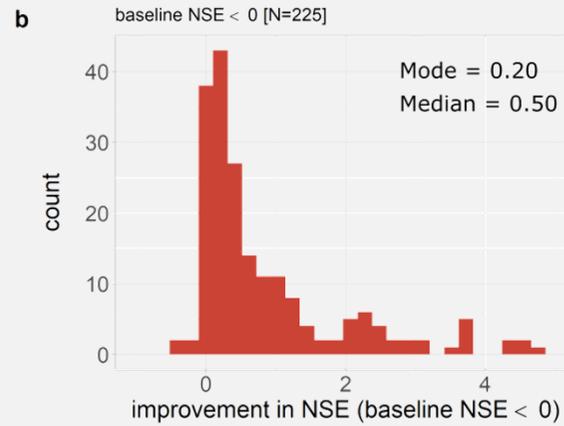
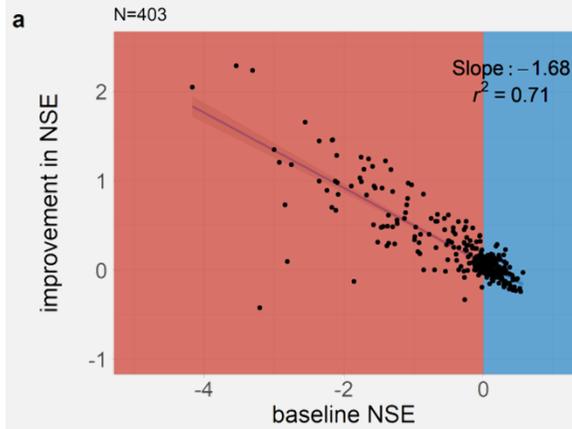
- 平均観測流量で正規化した誤差率

## KGE

Kling-Gupta Efficiency

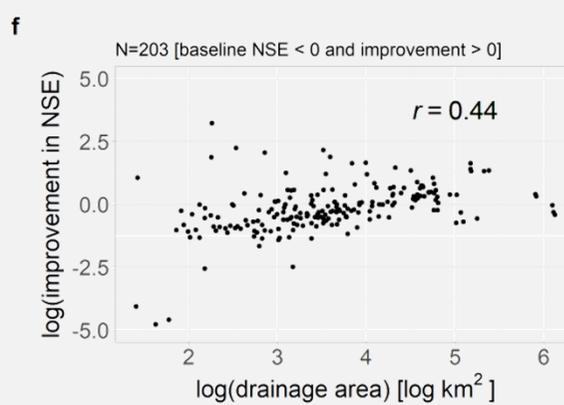
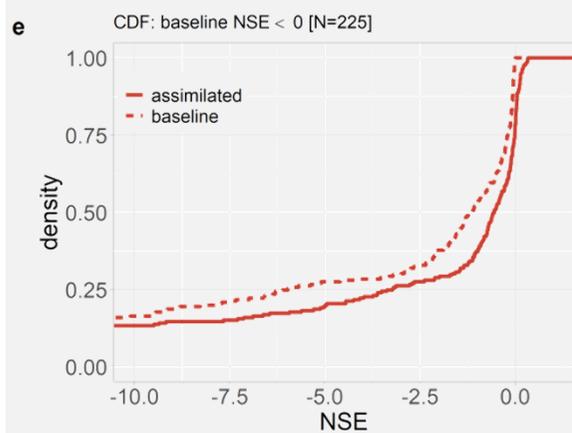
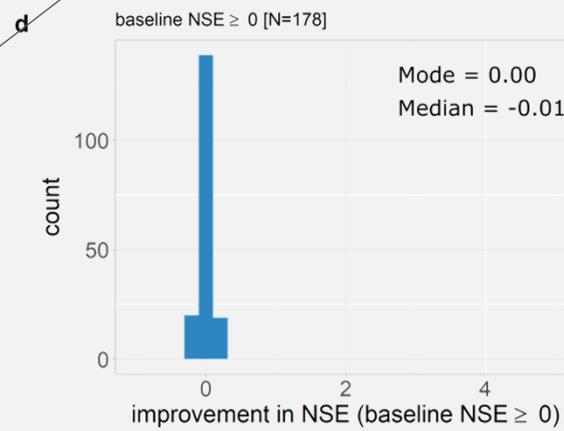
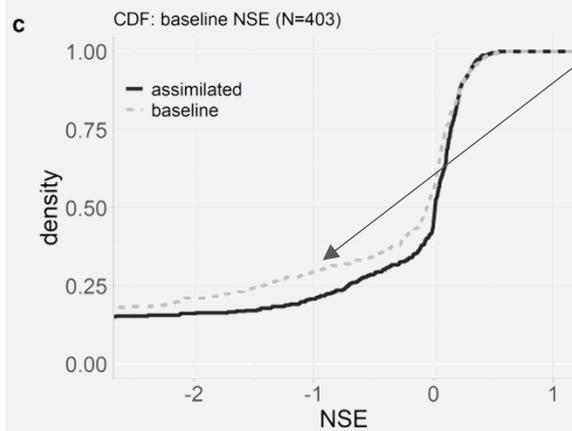
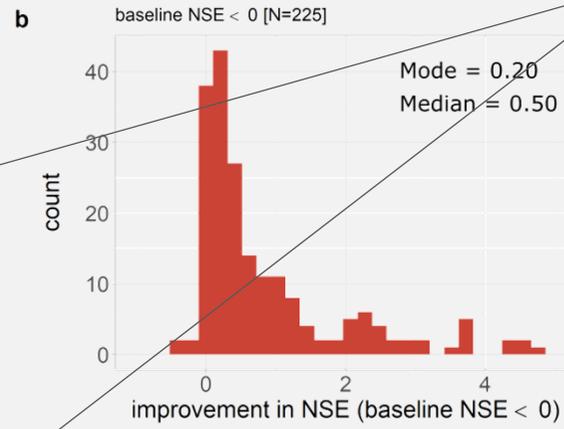
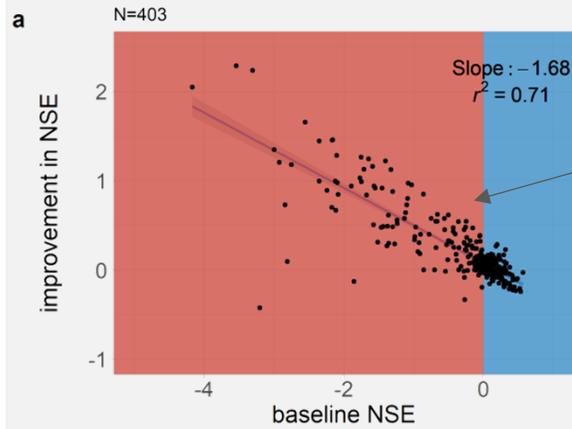
- 相関係数、変動係数、バイアスの混合指標

# Results - NSE



# Results - NSE

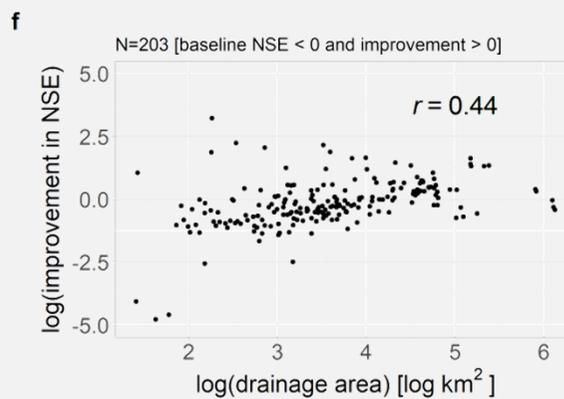
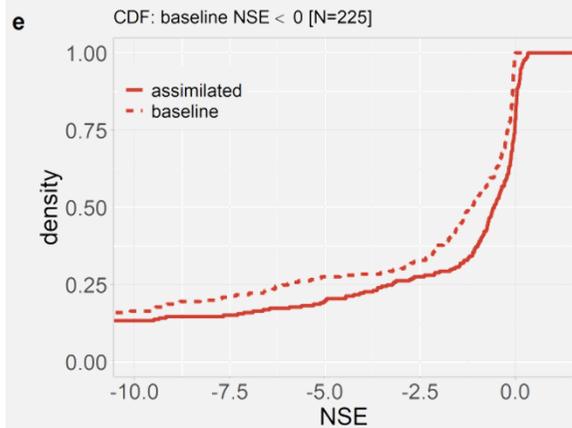
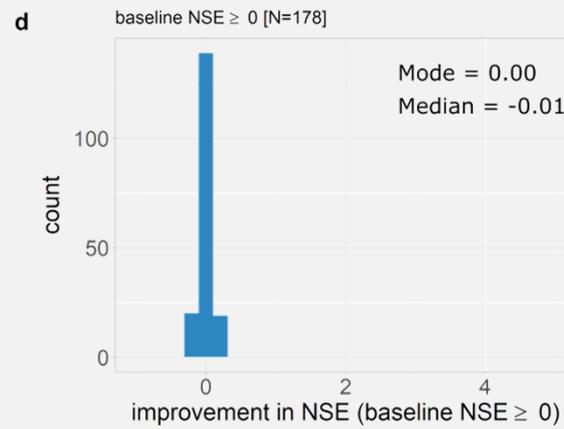
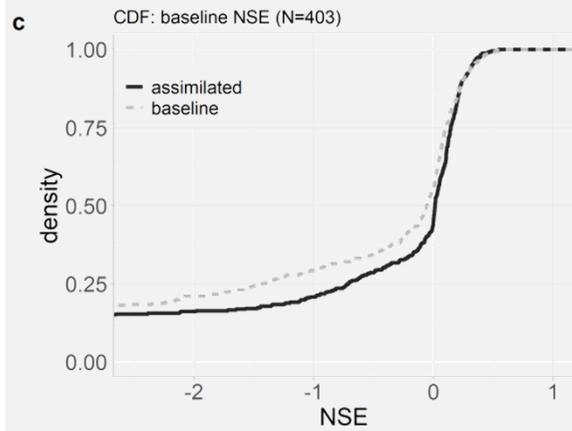
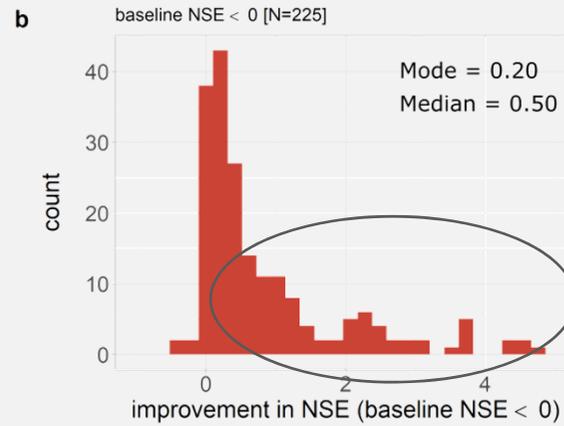
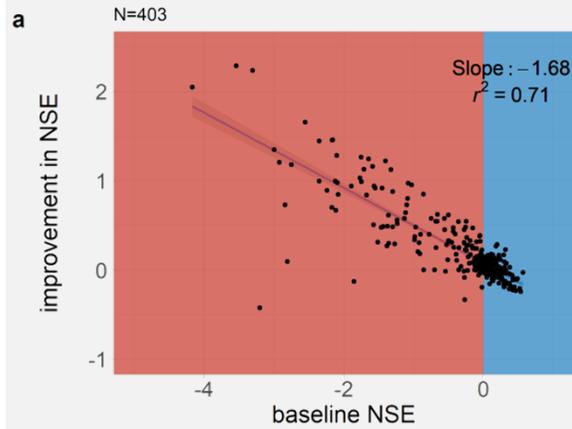
BaselineのNSEが悪いところで改善が大きい



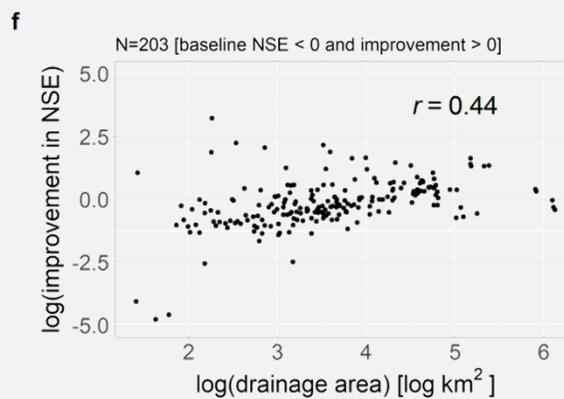
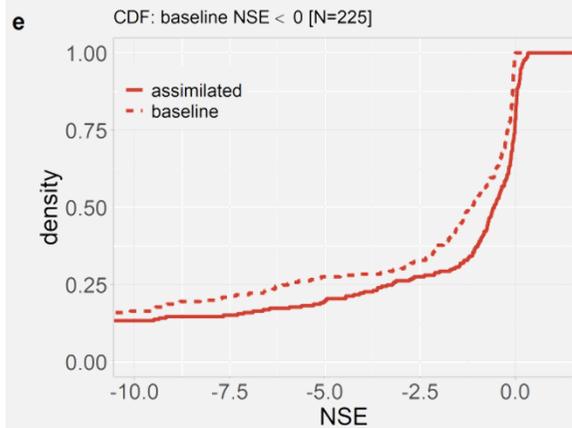
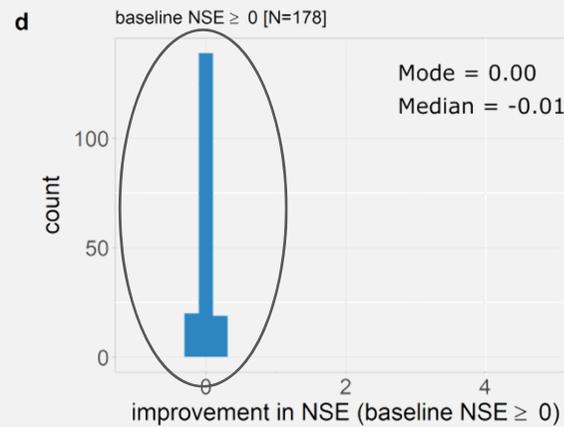
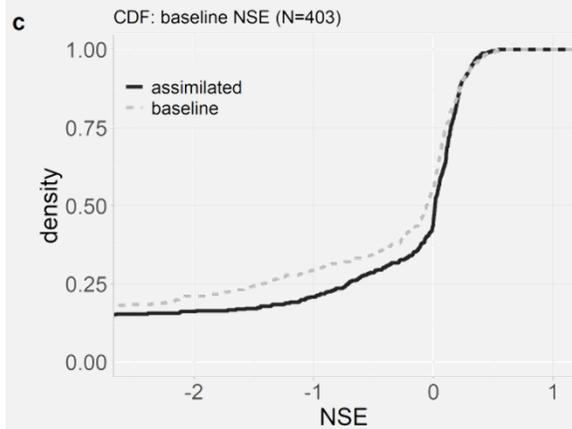
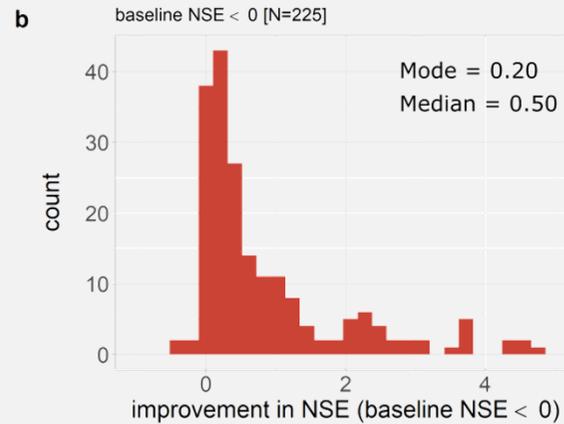
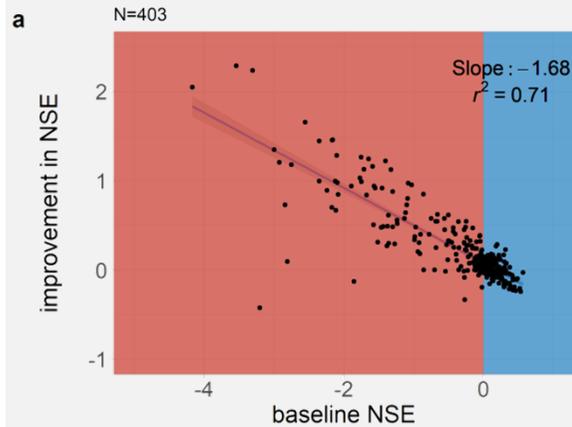
# Results - NSE

BaselineのNSEが悪いところで改善が大きい

Baseline NSE < 0の河川では改善方向に大きく歪んでいる



# Results - NSE



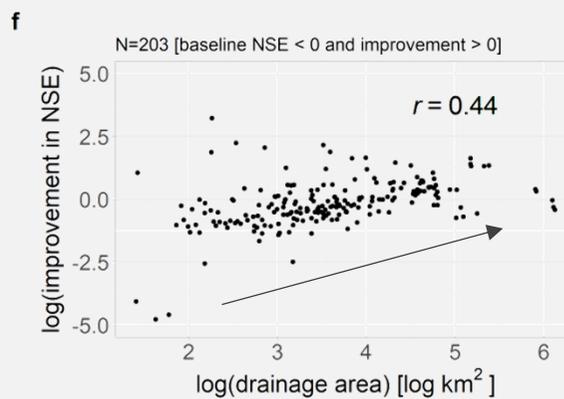
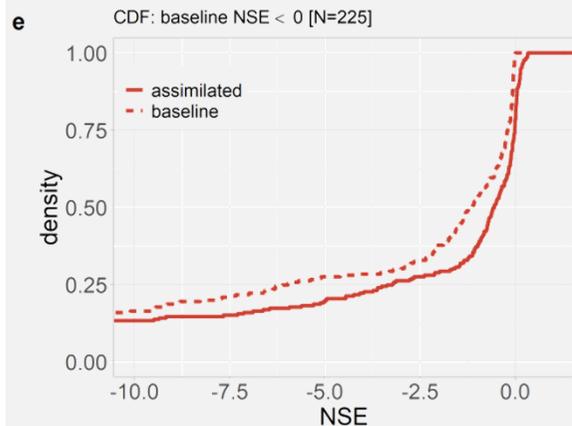
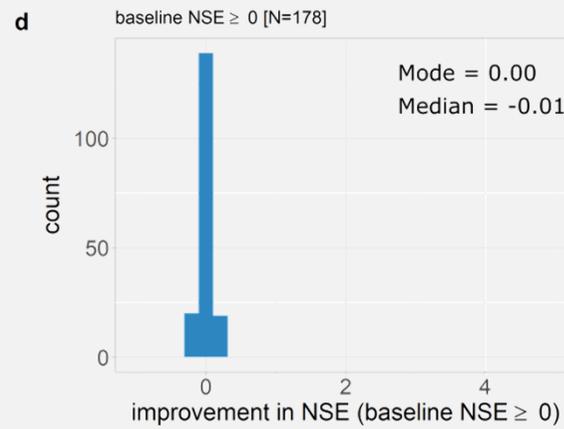
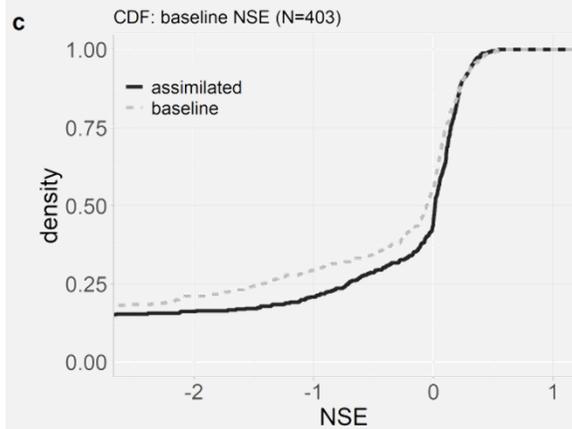
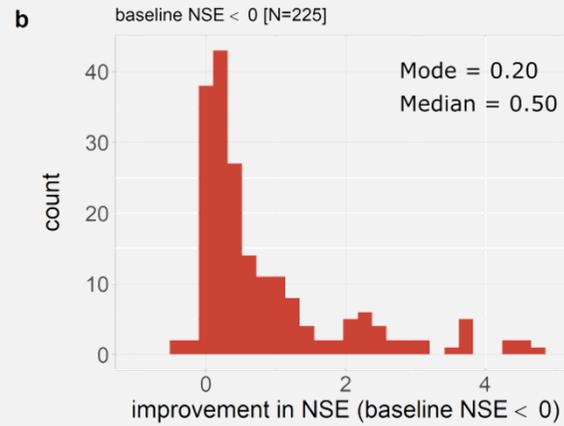
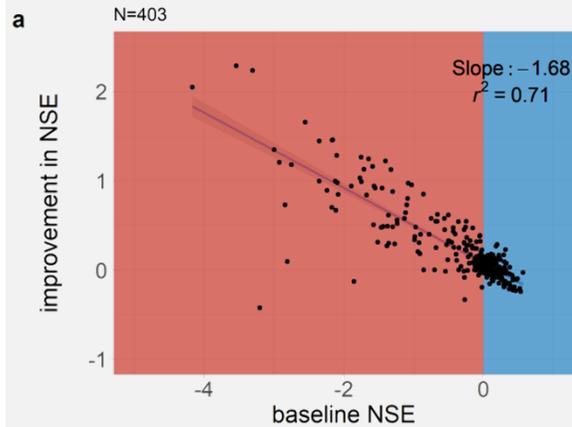
BaselineのNSEが悪いところ  
で改善が大きい

Baseline NSE < 0の河川では  
改善方向に大きく歪んでいる

Baseline NSE > 0の河川では  
改善も悪化もなし

- 流量ベイズ推定の事後分散  
と精度が相関していること  
を示唆

# Results - NSE



BaselineのNSEが悪いところで改善が大きい

Baseline NSE < 0の河川では改善方向に大きく歪んでいる

Baseline NSE > 0の河川では改善も悪化もなし

- 流量ベイズ推定の事後分散と精度が相関していることを示唆

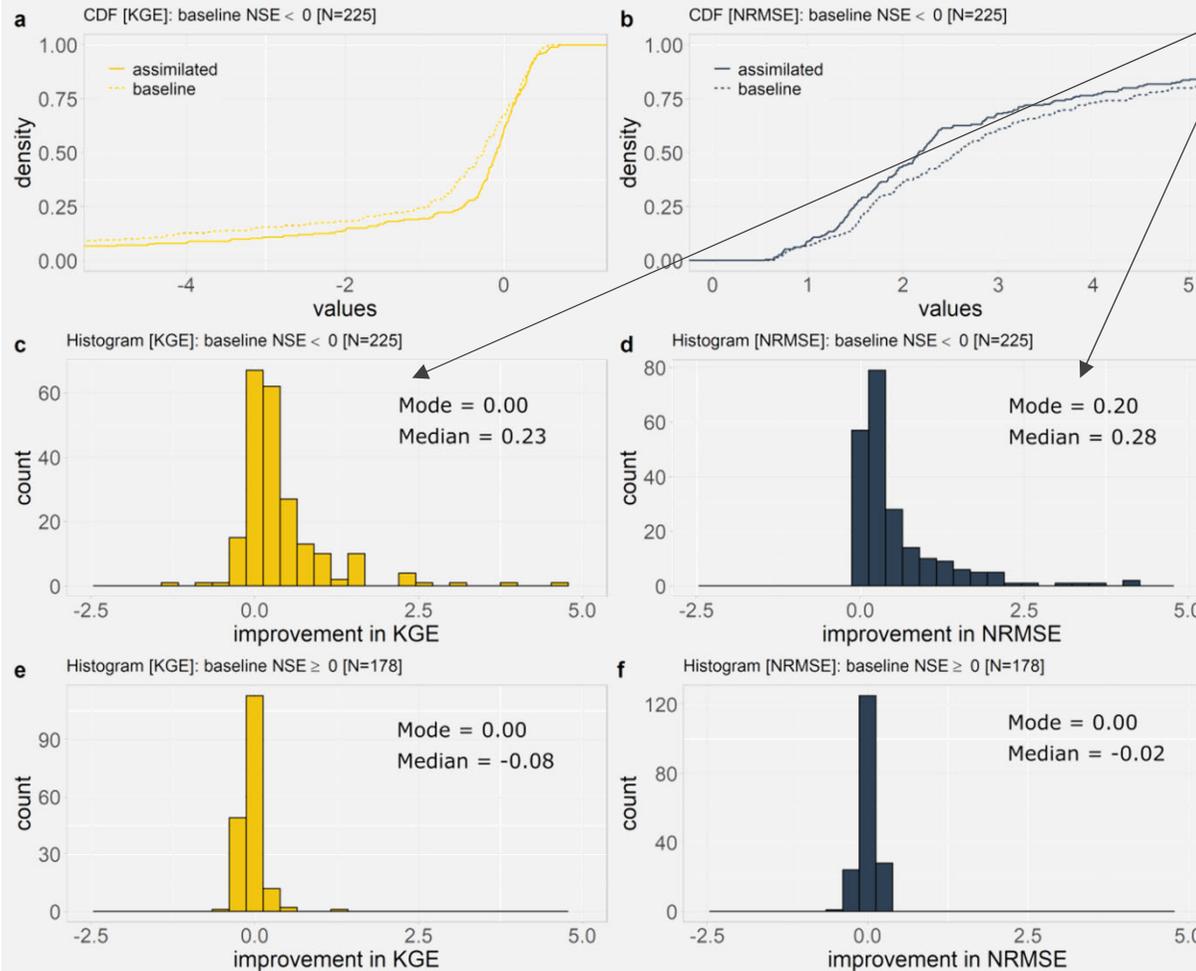
下流ほど改善が大きい傾向

- 補正された流量は下流に向けて累積していく

# Results – NRMSE / KGE

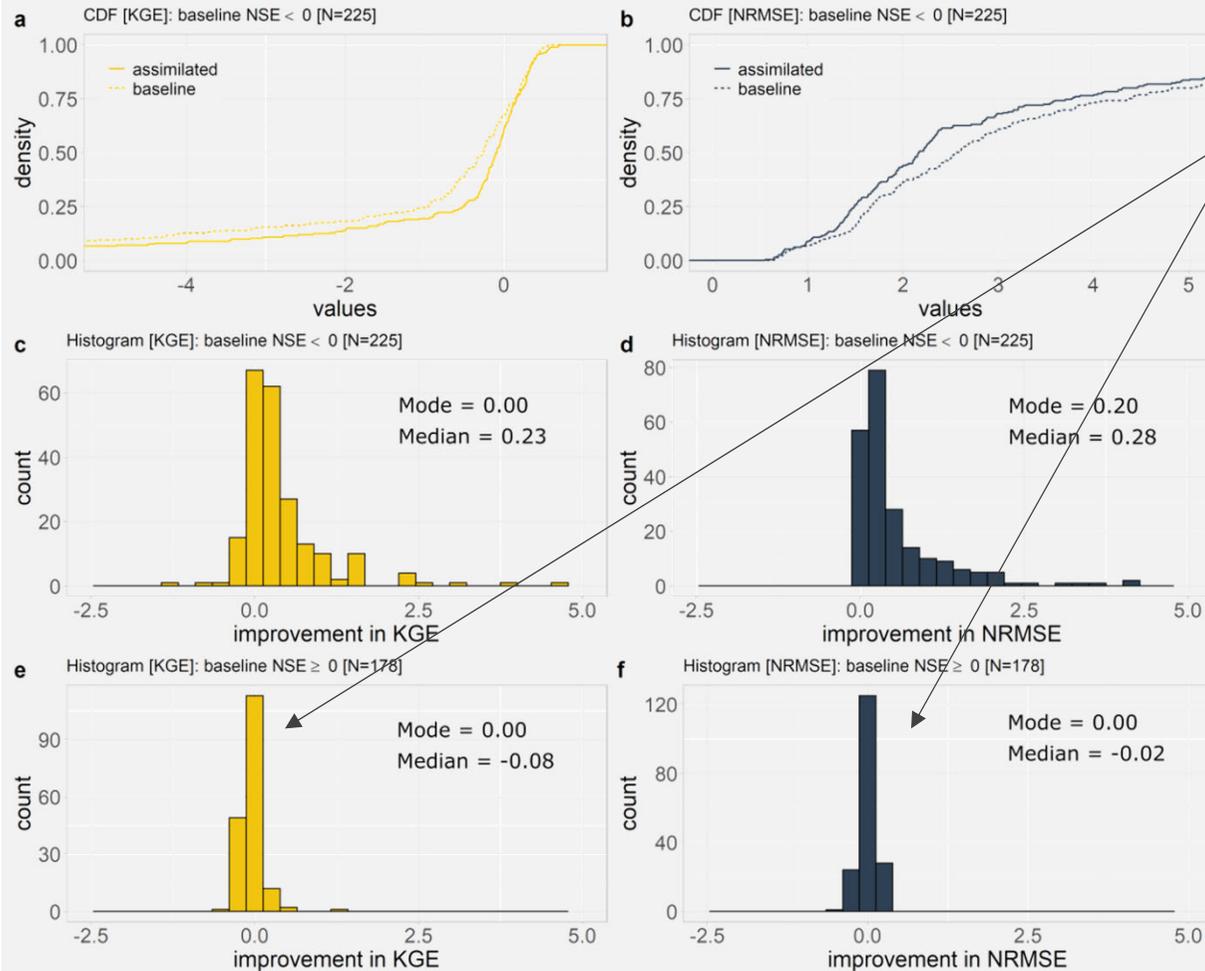
\*Normalized Root Mean Square Error / Kling-Gupta Efficiency

NRMSE / KGEでも同様の傾向  
Baselineの精度が悪いところ  
で改善大



# Results – NRMSE / KGE

\*Normalized Root Mean Square Error / Kling-Gupta Efficiency

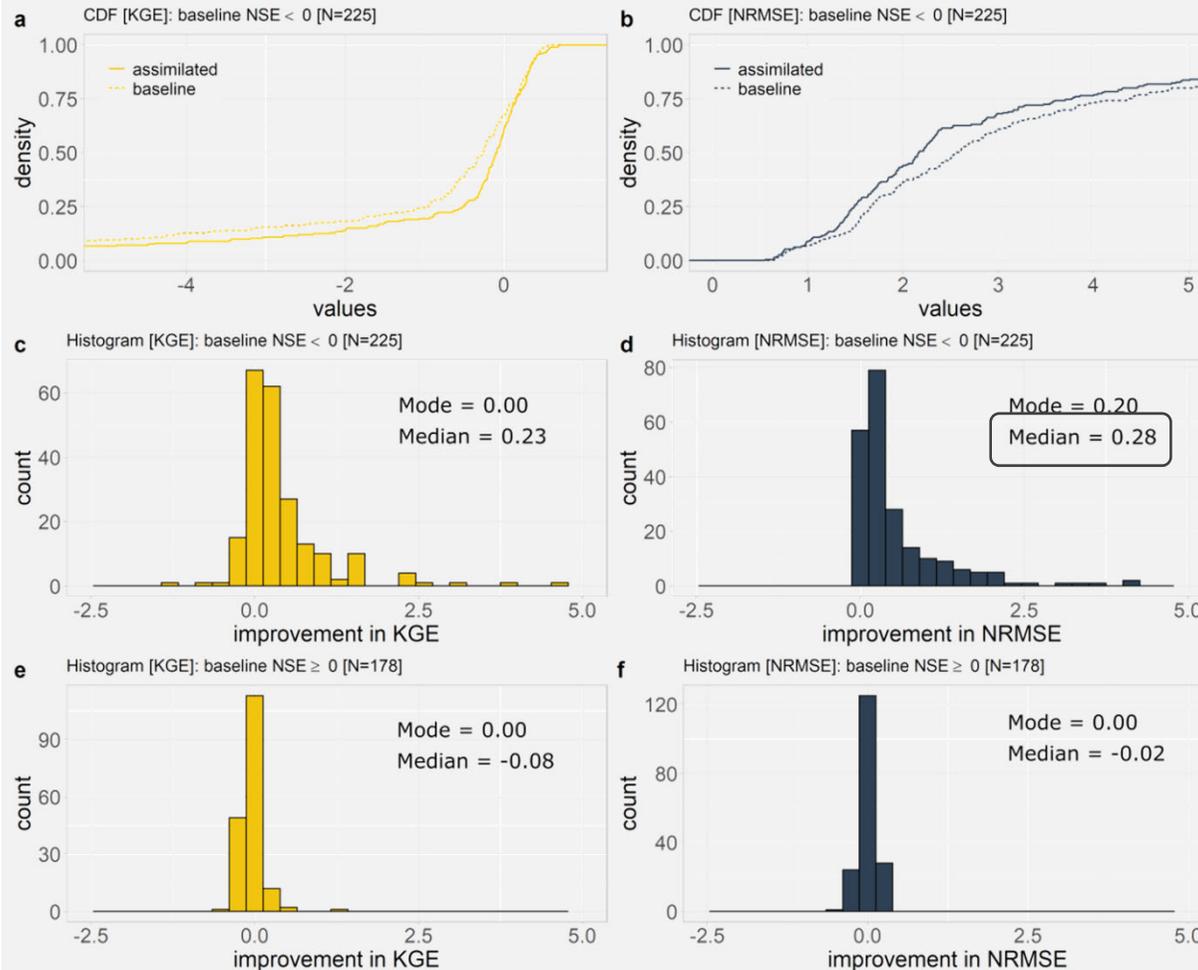


NRMSE / KGEでも同様の傾向

- Baselineの精度が悪いところで改善大
- Baselineの精度が良いところでは改善・悪化小

# Results – NRMSE / KGE

\*Normalized Root Mean Square Error / Kling-Gupta Efficiency



NRMSE / KGEでも同様の傾向

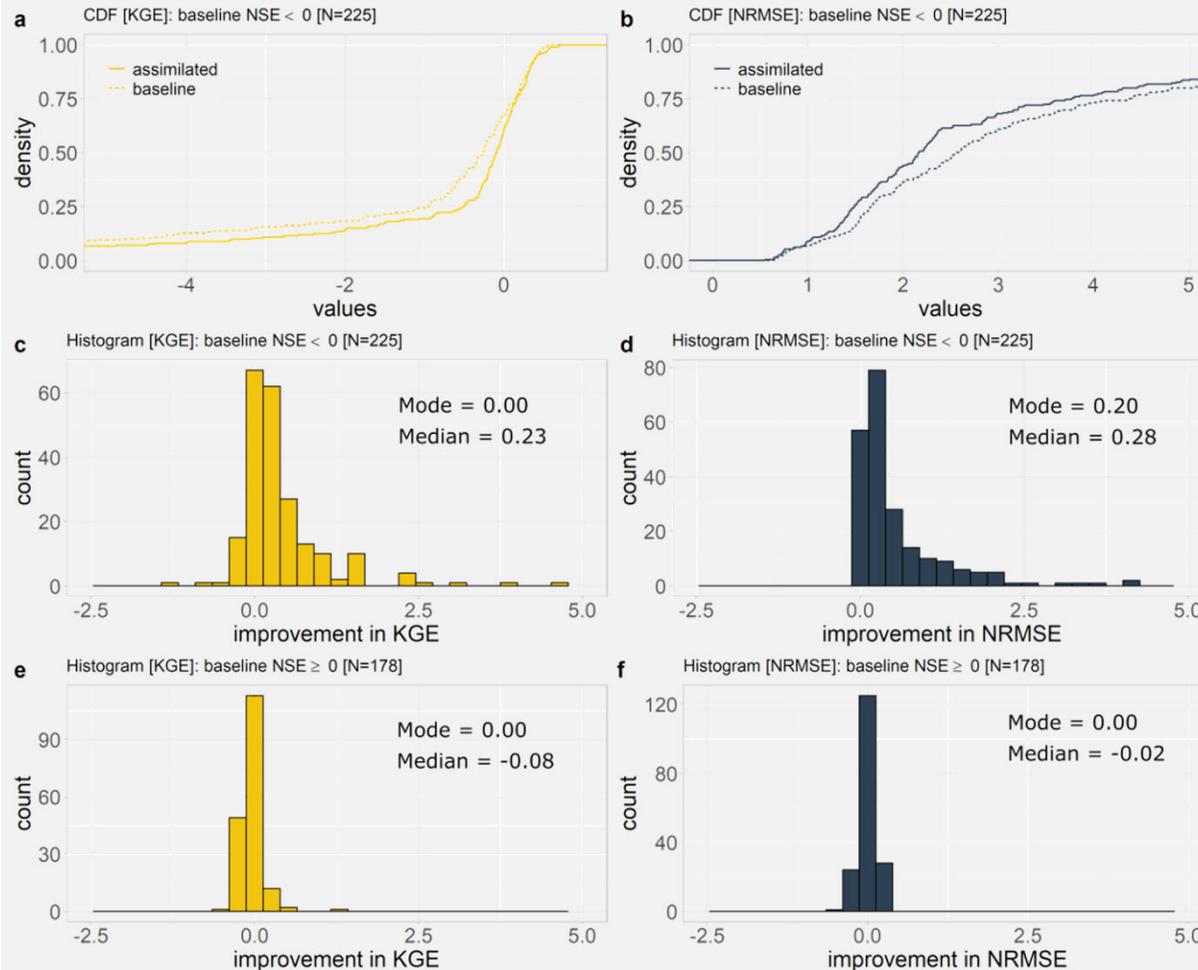
- Baselineの精度が悪いところで改善大
- Baselineの精度が良いところでは改善・悪化小

NRMSE改善の中央値は0.28

- 半数以上が28%以上誤差率改善

# Results – NRMSE / KGE

\*Normalized Root Mean Square Error / Kling-Gupta Efficiency



NRMSE / KGEでも同様の傾向

- Baselineの精度が悪いところで改善大
- Baselineの精度が良いところでは改善・悪化小

NRMSE改善の中央値は0.28

- 半数以上が28%以上誤差率改善

複数の指標で見てもMcFLIのマージによって精度が改善

- Modelはuncalibrated
- 未観測地域でのMcFLIおよび本手法の有用性を示唆

# Discussion

**確かに改善は見られたが、一部では精度が悪化しているのはなぜか？**

- McFLIの問題はill-posedなため、あらゆる可能な解が存在する
- 河川によってはうまく解空間を拘束できなかつたり、誤った空間に収束したりする
- これによってMcFLIが誤った値をconfidentに出力してしまうことがある
- Covariance-inflation (Anderson, 2006) によって解決できないか検討中

# Discussion

## **確かに改善は見られたが、一部では精度が悪化しているのはなぜか？**

- McFLIの問題はill-posedなため、あらゆる可能な解が存在する
- 河川によってはうまく解空間を拘束できなかつたり、誤った空間に収束したりする
- これによってMcFLIが誤った値をconfidentに出力してしまうことがある
- Covariance-inflation (Anderson, 2006) によって解決できないか検討中

## **なぜ川幅をそのまま同化しないのか？**

- 現状のデータ状況だと河道深と断面形状に大きな不確実性
- パラメータが多すぎてうまく収束しない
  - 実際、裏で行ったテストではMcFLIを用いた方が精度が良かった
- SWOT衛星によって観測変数が増えるためIRSTEA・Bristolのチームがデータ同化によって河道深と河道断面のデータセット作成予定

# Discussion

## **確かに改善は見られたが、一部では精度が悪化しているのはなぜか？**

- McFLIの問題はill-posedなため、あらゆる可能な解が存在する
- 河川によってはうまく解空間を拘束できなかったり、誤った空間に収束したりする
- これによってMcFLIが誤った値をconfidentに出力してしまうことがある
- Covariance-inflation (Anderson, 2006) によって解決できないか検討中

## **なぜ川幅をそのまま同化しないのか？**

- 現状のデータ状況だと河道深と断面形状に大きな不確実性
- パラメータが多すぎてうまく収束しない
  - 実際、裏で行ったテストではMcFLIを用いた方が精度が良かった
- SWOT衛星によって観測変数が増えるためIRSTEA・Bristolのチームがデータ同化によって河道深と河道断面のデータセット作成予定

## **モデルのNSEが負のもので改善がみられても意味がないのではないか？**

- 観測のある流域ではこれは正しい
- ただし、未観測流域ではそもそも観測がないので、観測年平均流量も存在しない
  - NSEという値・考え方そのものが未観測流域では成立しない
- よって、あらゆる改善は意味のあるものと少なくとも我々は考えている

# Takeaway

## 衛星観測から流量を得る手法、McFLI

- 衛星観測から得られる情報から連立方程式を立式
- 未知パラメータは観測データから逐次推定

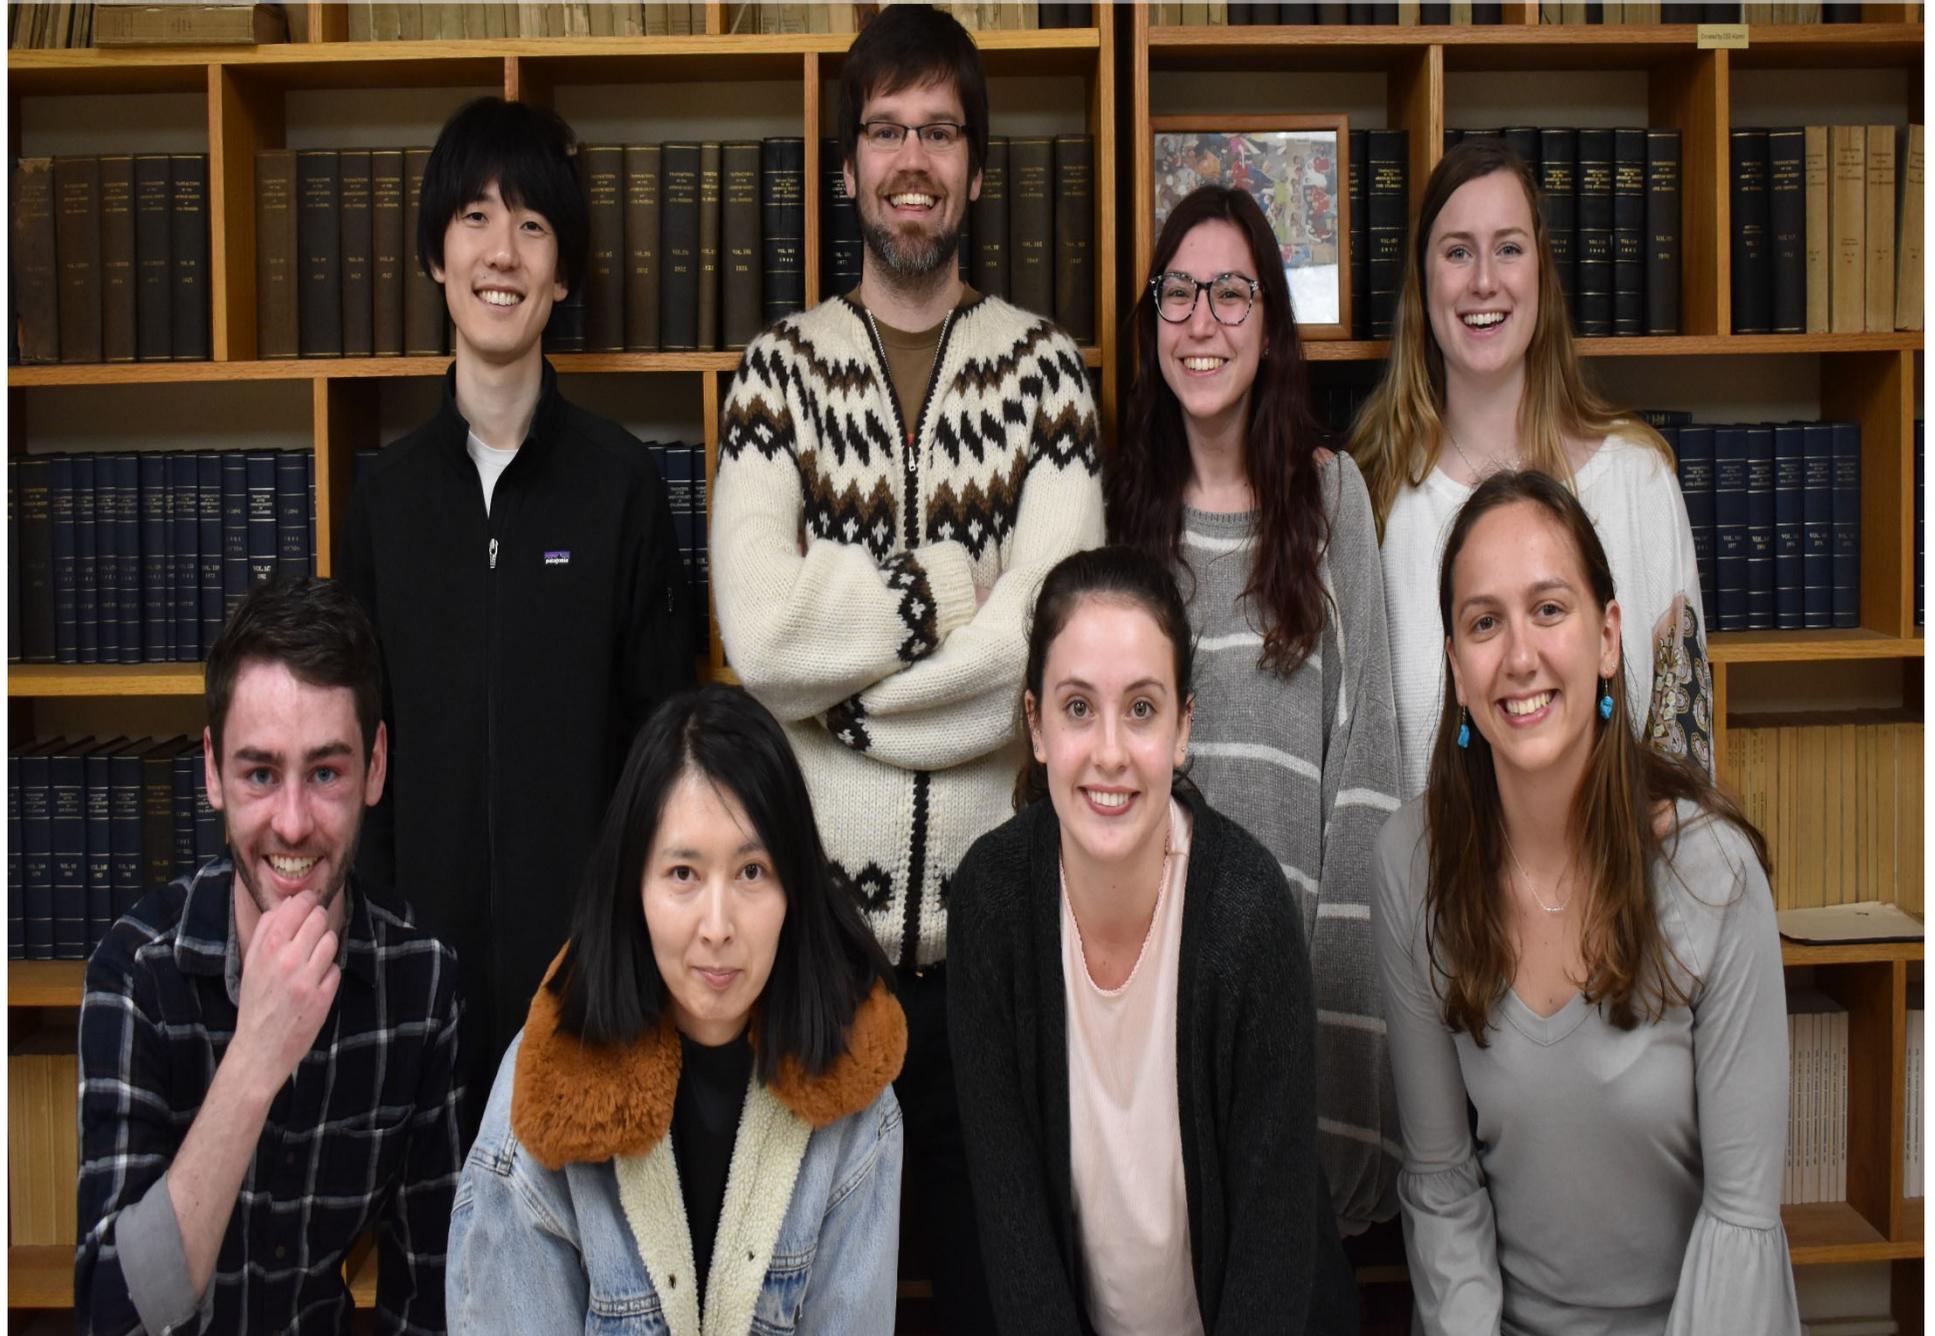
## SWOT Mission

- 11カ月後にローンチ予定
- 世界中の水面標高と川幅が取得できるように

## 可視光衛星とデータ同化を用いたMcFLIの数値モデルへのマージ

- McFLIによる流量のベイズ推定（＝事後確率分布）をデータ同化と組み合わせ
- NSE, NRMSE, KGEで特にbaselineの精度が悪いところで改善が見られた
  - Baseline NSE < 0の観測点における：
    - NSE改善中央値：0.5
    - NRMSE改善中央値：28%
    - KGE改善中央値：0.23
- 実データを通じてMcFLIがモデル精度改善に有用であることを示唆
  - SWOT衛星を用いたMcFLI流量推定のモデル利用のテンプレートを提示
  - SWOTローンチ後はさらなる精度改善が期待される
    - 観測変数の増加→McFLIの精度改善
  - 本手法で提示した可視光衛星の利用とSWOT衛星の組み合わせで観測を増やす

# 博士進学と米国留学について



# 博士進学と米国留学について

周りの話を聞いていても日本での博士進学は年々メジャーに

日本での研究・指導環境は最高だった

ではなぜ米国進学したのか？

- NASAのプロジェクト（SWOT）に関わりたかった
- 留学に憧れがあった
- 観測に行ってみたかった
- 金銭的な理由
  - 博士に行くなら自分で全て賄えと言われていた
  - 欧米では特に学費補助とStipend補助が手厚い

# 米国留学は実際の所どうか？



カナダのマッケンジー流域現地観測  
スレイブ川でのキャンプ

# 米国留学は実際の所どうか？



カナダのマッケンジー流域現地観測  
スレイブ川でのキャンプ

# 米国留学は実際の所どうか？

研究の質という意味では場所に関係はないように思える

- アドバイザーとの相性等はもちろん重要

あくまで自分の分野に限って言えば、コネクション作りには特徴があった

- 多くの著名な研究者の方々と気軽にワークショップ等で会える
  - 欧州圏も比較的行きやすい
- 共著に入ってもらいやすい
- 上記からコネクションが作りやすい (→論文・就活)
- 国際学会 (AGU) が再開の場所になり楽くなる

ただしこれらは副次的なもので、結局は自分次第な所も

- 米国でできることは日本でもできる (特にアフターコロナでは環境は画一的)
- 研究内容を最重視しつつご決断されるべき

## アメリカの良いところ

- 自然 (トレッキングコースの宝庫)
- キッチン (オープン有。広い。戻れない。)
- 週末の集まりが多い (ボードゲームなど)

# Results – Hydrographs

