

Estimasi Kejadian Covid-19 Secara Real Time menggunakan R Programming

Adnan Sauddin

Universitas Islam Negeri Alauddin Makassar, adnan.sauddin@uin-alauddin.ac.id

Try Azisah Nurman

Universitas Islam Negeri Alauddin Makassar, wahidah.alwi@uin-alauddin.ac.id

Khalilah Nur Fadilah

Universitas Islam Negeri Alauddin Makassar

ABSTRAK, Pada artikel ini menguraikan Langkah-langkah estimasi kejadian covid-19 di Indonesia khusus wilayah Sulawesi selatan secara real time menggunakan Bahasa R.

Kata Kunci: *R programming, Covid-19, distribusi poisson, estimasi parameter, likelihood*

1. PENDAHULUAN

Pada artikel ini penulis akan menguraikan penggunaan program R tahap demi tahap dalam melakukan estimasi terhadap kejadian Covid-19 secara real time. Bahwa pandemic covid-19 merupakan kejadian luar biasa yang meliputi seluruh dunia. Tidak satupun negara kecuali terpapar virus ini. peningkatan kejadian terpapar covid-19 dari hari ke hari terus yang terus meningkat membuat setiap negara berusaha secara maksimal untuk menekan kejadian terpapar.

Peningkatan kejadian terpapar virus corona berbeda pada setiap negara, hal tersebut bergantung pada pendekatan penanganan yang dilakukan oleh setiap otoritas negara. Jika kita melihat pada konsep islam dalam penanganan suatu wabah pandemic, bahwa disebut dalam salah satu hadits Rasulullah Sholallahu 'alai wasallam, secara makna-ketika suatu negeri menyebar wabah, maka orang-orang yang berada diluar daerah tersebut dilarang untuk masuk, searah dengan hal tersebut, orang-orang yang berada di dalam suatu daerah tersebut (daerah pandemic) dilarang untuk keluar dari daerah tersebut. Beberapa negara ada yang menerapkan konsep tersebut, dalam cukup berhasil dalam menekan tingkat penyebaran dari virus tersebut.

Ketika wabah tersebut telah menyebar dalam suatu negeri, hal yang mungkin bisa

dilakukan adalah menekan jumlah penyebaran dari waktu ke waktu. Memahami factor-faktor penyebab terus bertambahnya kejadian terpapar virus covid-19 merupakan hal tindakan yang harus dilakukan agar Tindakan preventif dapat segera dilakukan. Salah satu factor yang dapat mempengaruhi Jumlah kejadian covid-19 sangat berkaitan terkait dengan teknik pengukuran atau alat ukur yang digunakan, tingkat validitas alat ukur akan menentukan validnya data yang berkaitan dengan jumlah terpapar. Untuk dapat mengambil Tindakan preventif, mengetahui kemungkinan pertambahan jumlah kejadian terpapar dengan kluster atau segmentasi berdasarkan daerah akan mudah bagi pengambil kebijakan untuk menerapkan kebijakan protocol Kesehatan yang dapat membantu penanganan perluasan dan/atau penurunan jumlah kejadian terpapar.

estimasi peluang peningkatan dan/atau penurunan jumlah kejadian, secara statistic dalam dilakukan dengan menggunakan beberapa model berdasarkan pada distribusi kejadian. Distribusi poisson untuk mendeteksi jumlah kejadian terpapar – model kedatangan – dengan estimasi likelihood. Memanfaat informasi prior akan meningkatkan tingkat keakuratan hasil estimasi – aturan bayes.

2. TINJAUAN PUSTAKA

Jumlah orang menjadi terpapar per orang yang terinfeksi berdasarkan waktu t

Model Kedatangan

Model kedatangan proses terpapar mengikuti pola distribusi poisson. Misalkan λ merupakan rata kejadian terpapar perhari dan

peluang yang mungkin k kasus baru perhari, berdistribusi poisson dengan persamaan

$$P(k|\lambda) = \frac{\lambda^k e^{-\lambda}}{k!}$$

Dapat dikonstruksi suatu distribusi peluang dari kasus baru untuk suatu λ .

Estimasi Likelihood Distribusi Poisson

Pemodelan proses kedatangan distribusi poisson memungkinkan bagi kita untuk melakukan prediksi terhadap distribusi kasus kejadian baru dalam suatu hari sebagai suatu fungsi rata-rata kedatangan (λ). Namun demikian, pada data real, kita hanya dapat mengamati jumlah kedatangan. Untuk mendapatkan keadaan yang dimaksud, maka kita perlu melakukan estimasi terhadap kejadian baru yang akan datang, salah satu metode yang populer adalah likelihood.

Distribusi dari λ untuk sembarang k disebut fungsi likelihood, yakni:

$$L(\lambda|k) = \frac{\lambda^k e^{-\lambda}}{k!}$$

Menghubungkan λ dan R_t

Hubungan antara λ dan R_t secara matematis

$$\lambda = k_{t-1} \gamma^{(R_{t-1})}$$

Gunakana persamaan terakhir dan substitusi ke persamaan sebelumnya

$$L(\lambda|k) = \frac{\lambda^k e^{-\lambda}}{k!}$$

Hasilnya

$$L(R_t|k) = \frac{\lambda^k e^{-\lambda}}{k!}$$

Estimasi R_t

Untuk mengestimasi kejadian secara time series kita dapat menggunakan aturan bayes,

$$L(\lambda|k) = \frac{\lambda^k e^{-\lambda}}{k!}$$

$$L(R_t|k_t) = \frac{P(R_t)L(k_t|R_t)}{P(k_t)}$$

Jika menggunakan $L(R_t|k_t)$ sebagai prior dari $P(R_t)$ untuk suatu periode tertentu, maka persamaan sebelumnya dapat dituliskan

$$L(R_t|k_t) \propto P(R_{t-1}|k_{t-1}) \cdot L\left(\frac{P(R_t)L(k_t|R_t)}{P(k_t|R_t)}\right)$$

Iterasi silang semua periode, $t=0$, diperoleh

$$L(R_t|k_t) \propto P(R_0) \cdot \prod_{t=0}^T L(k_t|R_t)$$

Dengan prior yang seragam, $P(R_0)$, direduksi ke

$$P(R_t|k_t) \propto \prod_{t=0}^T L(k_t|R_t)$$

Paket R yang digunakan

Pada program r, terdapat banyak paket yang telah dikembangkan oleh banyak pengembang. Dalam menganalisis kejadian Covid-19 secara real time, berikut paket-paket yang digunakan:

1. tidyverse
2. ggplot2
3. HDinterval
4. smooter

serta beberapa paket lain yang dapat dilihat pada script Bahasa r pada bagian hasil.

3. HASIL

Pengaturan Tampilan Ourput R

```
# Load packages
library(tidyverse)

# Plot options
## Dimensi Plot to 12 x 6.
options(repr.plot.width = 12,
        repr.plot.height = 6)

## Menggunakan ggplot2 untuk semua
plot.
theme_custom <- function(base_size,
  ...) {
  ggplot2::theme_gray(base_size =
    base_size, ...) +
  ggplot2::theme(
    plot.title = element_text(face =
      'bold'),
    plot.subtitle = element_text(color
      = '#333333'),
    panel.background =
      element_rect(fill = "#EBF4F7"),
    strip.background =
      element_rect(fill = "#33AACC"),
    legend.position = "bottom"
  )
}
```

```
ggplot2::theme_set(theme_custom(base_size = 20))
ggplot2::update_geom_defaults("line", list(size = 1.5))
```

```
# Utility functions
```

```
## Pengaturan tampilan head dari dataframe.
## paket yang digunakan adalah `repr` package.
```

```
display_df <- function(x){
  d <- as.character(
    knitr::kable(x, format = 'html',
table.attr = "class='dataframe'")
  )
  IRdisplay::display_html(d)
}
```

```
display_head <- function(x, n = 6){
  display_df(head(x, n))
}
```

```
display_random <- function(x, n = 6){
  display_df(dplyr::sample_n(x, n))
}
```

Simulasi “Kedatangan” Terpapar Baru per Hari

```
# Jumlah Kasus Baru dalam se-hari
k = 0:69
```

```
# Rata-Rata “Kedatangan terpapar baru per hari
lambda = c(10, 20, 30, 40)
poisson_densities = crossing(lambda = lambda, k = k) %>%
  mutate(p = dpois(k, lambda))
```

```
display head(poisson_densities)
```

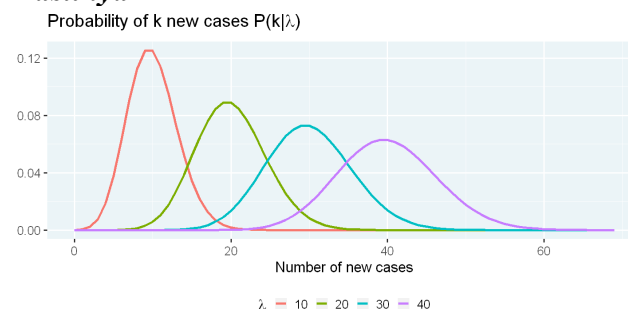
lambda	k	p
10	0	0.0000454
10	1	0.0004540
10	2	0.0022700
10	3	0.0075667
10	4	0.0189166
10	5	0.0378333

Grafik Distribusi Poisson

```
poisson_densities %>%
# Konver lambda ke fakto sehingga setiap baris berupa menghasil warna yang berbeda (sebagai diskrit)
mutate(lambda = factor(lambda)) %>%
ggplot(aes(x = k, y = p, color = lambda)) + geom_line() + labs(title = expression(paste("Probability of k new cases P(k|", lambda, ")")),
```

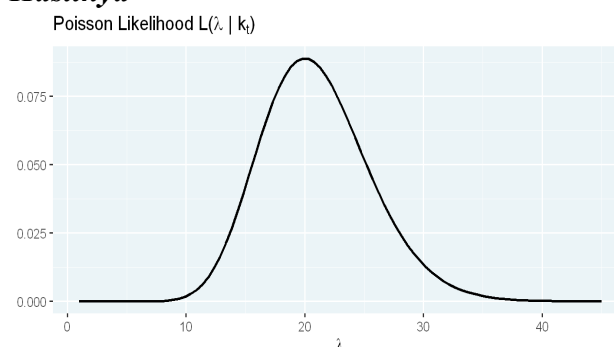
```
x = 'Number of new cases',
y = NULL,
color = expression(lambda)
)
```

Hasilnya



```
# Jumlah Kasus Baru Teramati per Hari
k = 20
# Rata-rata Kedatangan terpapar baru per hari
lambdas = seq(1, 45, length = 90)
# Menghitung likelihood and gambar Likelihood
tibble(lambda = lambdas, p = dpois(k, lambdas)) %>%
  ggplot(aes(x = lambda, y = p)) +
  geom_line(color = 'black') +
  labs(
    title = expression(paste("Poisson Likelihood L(", lambda, " | k"[t], ")")),
    x = expression(lambda),
    y = NULL
  )
)
```

Hasilnya



Nilai Peluang untuk rentang R_t

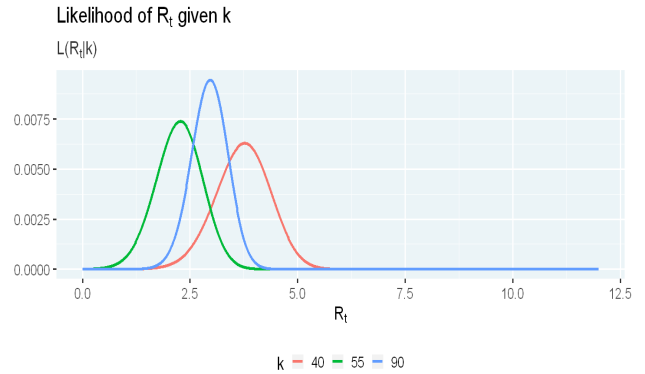
```
# r_t_range is a vector of possible values for  $R_t$ 
R_T_MAX = 12
r_t_range = seq(0, R_T_MAX, length = R_T_MAX*100 + 1)

# Gamma is 1/serial interval
GAMMA = 1/4
```

```
# Kasus Baru Perhari
k = c(20, 40, 55, 90)
likelihoods <- tibble(day =
  seq_along(k) - 1, k = k) %>%
# Menghitung vector likelihoods
  mutate(
    r_t = list(r_t_range),
    lambda = map(lag(k, 1), ~ .x
  * exp(GAMMA * (r_t_range - 1))),
    likelihood_r_t = map2(k,
lambda, ~ dpois(.x,
.y)/sum(dpois(.x, .y))
) %>%
# Mengabaikan Hari ke-0
filter(day > 0) %>%
# Unnest the data to flatten it.
select(-lambda) %>%
unnest(c(r_t,
likelihood_r_t))
display_random(likelihoods)
```

day	k	r_t	likelihood_r_t
1	40	10.55	0
3	90	7.73	0
2	55	7.35	0
2	55	1.27	0.0014977
1	40	1.37	0.0000162
3	90	7.66	0

```
likelihoods %>%
  ggplot(aes(x = r_t, y
=likelihood_r_t, color =
factor(k))) +
  geom_line() +
  labs(
    title =
expression(paste("Likelihood of
R"[t], " given k")),
    subtitle =
expression(paste("L(R"[t], "|k)")),
x = expression("R"[t]),
y = NULL, color = 'k'
)
)
```

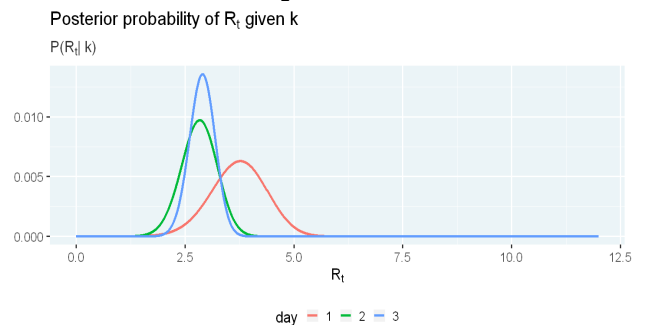


```
posteriors <- likelihoods %>%
  group_by(r_t) %>%
  arrange(day) %>%
  mutate(posterior =
cumprod(likelihood_r_t)) %>%
  group_by(k) %>%
  mutate(posterior = posterior /
sum(posterior)) %>%
  ungroup()
```

display_random(posteriors)

day	k	r_t	likelihood_r_t	posterior
2	55	1.91	0.0059229	0.0009075
3	90	4.21	0.0000771	0.0000002
1	40	4.21	0.0049115	0.0049115
2	55	2.04	0.0067356	0.0016521
2	55	8.59	0.0000000	0.0000000
2	55	8.09	0.0000000	0.0000000

```
posteriors %>%
  ggplot(aes(x = r_t, y = posterior,
color = factor(day))) +
  geom_line() +
  labs(
    title =
expression(paste("Posterior
probability of R"[t], " given k")),
    subtitle =
expression(paste("P(R"[t], "| k)")),
x = expression("R"[t]), y =
NULL, color = 'day')
)
```



Install and load HDInterval package
library(HDInterval)

Menghitung Nilai R_t Nilai dengan Peluang Tinggi

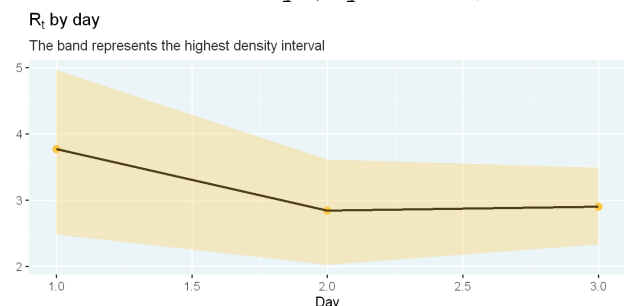
```
# menghitung nilai  $R_t$  yang paling mungkin dan highest-density interval
estimates <- posteriors %>%
  group_by(day) %>%
  summarize(
    r_t_simulated =
list(sample(r_t_range, 10000, replace = TRUE, prob = posterior)),
    r_t_most_likely =
r_t_range[which.max(posterior)] %>%
mutate( r_t_lo =
map_dbl(r_t_simulated, ~ hdi(.x)[1]),
    r_t_hi =
map_dbl(r_t_simulated, ~ hdi(.x)[2])
) %>%
select(-r_t_simulated)
```

```
display head(estimates)
```

day	r t most likely	r t lo	r t hi
1	3.77	2.48	4.96
2	2.84	2.02	3.61
3	2.90	2.33	3.49

Grafik Interval

```
estimates %>%
  ggplot(aes(x = day, y =
r_t_most_likely)) +
  geom_point(color = "#ffc844",
size = 5) +
  geom_line(color = 'black') +
  geom_ribbon(aes(ymin = r_t_lo,
ymax = r_t_hi), fill = "#ffc844",
alpha = 0.3) +
labs( title =
expression(paste('R'[t], ' by day')),
subtitle = "The band represents the
highest density interval",
x = 'Day', y = NULL)
```



Kasus Covid-19 Indonesia

Upload Data Covid-19 Indonesia

```
covid_cases <-
readr::read_csv("d:/Statistik_Harian_p
```

```
er_Provinsi_COVID19_Indonesia_Rev
(6).csv")
```

Variabel

```
display_head(covid_cases)
Parsed with column specification:
cols(
  Object_ID = col_double(),
  Provinsi = col_character(),
  Tanggal = col_date(format = ""),
Kasus_Terkonfirmasi_Akumulatif = col_double
()),
Penambahan_Harian_Kasus_Terkonf = col_doubl
e()),
Kasus_Sembuh_Akumulatif = col_double(),
Penambahan_Harian_Kasus_Sembuh = col_double
()),
Kasus_Meninggal_Akumulatif = col_double(),
Penambahan_Harian_Kasus_Meningg = col_doubl
e()),
Kasus_Aktif_Akumulatif = col_double(),
CFR_Harian = col_character(),
RI_Harian = col_character(),
FID = col_double(),
ObjectId = col_double()
)
```

Menampilkan Data Harian Terkonfirmasi dan Pemulusan

```
# Install the smoother
packagelibrary(smoother)

# Menampilkan kasus harian
terkonfirmasi dan pemulusannya
smooth_new_cases <- function(cases){
  cases %>% arrange(Tanggal) %>%
# mutate(new_cases = c(cases[1],
diff(cases))) %>%
mutate(new_cases_smooth = round(
smoother::smth(Penambahan_Harian_Kasus
_Terkonf, window = 7, tails = TRUE)
)) %>%
select(Provinsi, Tanggal,
Penambahan_Harian_Kasus_Terkonf,
new_cases_smooth) }
```

Filter Propinsi

```
state_selected <- "Sulawesi Selatan"
covid_cases %>%
filter(Provinsi == state_selected) %>%
smooth_new_cases() %>%
display_random()
```

Hasil

Tabel 1. Penambahan Kasus Karian Terkonfirmasi dan Pemulusannya

Provinsi	Tanggal	PHKT*	PHKT smooth
Sulawesi Selatan	2020-05-24	32	40

Provinsi	Tanggal	PHKT*	PHKT smooth
Sulawesi Selatan	2020-03-05	0	0
Sulawesi Selatan	2020-04-03	16	7
Sulawesi Selatan	2020-05-02	30	31
Sulawesi Selatan	2020-04-27	0	9
Sulawesi Selatan	2020-05-06	25	23


* Penambahan Harian Kasus Terkonfirmasi

Grafik Kasus Baru Terkonfirmasi per Hari Propinsi Sulawesi Selatan

```
plot_new_cases <- function(cases){
cases %>% ggplot(aes(x = Tanggal, y =
Penambahan Harian Kasus Terkonf)) +
geom_line(linetype = 'dotted', color =
'gray40') +
geom_line(aes(y = new_cases_smooth),
color = "#14243e") + labs(title =
"Kasus Baru per Hari",
subtitle = unique(cases$Provinsi),
x = NULL, y = NULL
)}
}
```

```
covid_cases %>%
filter(Provinsi == state_selected) %>%
smooth_new_cases() %>%
plot_new_cases()
```

Kasus Baru per Hari
Sulawesi Selatan



```
compute_likelihood <- function(cases){
likelihood <- cases %>%
filter(new_cases_smooth > 0) %>%
mutate(r_t = list(r_t_range), lambda
= map(lag(new_cases_smooth, 1), ~ .x *
exp(GAMMA * (r_t_range - 1))),
likelihood_r_t =
map2(new_cases_smooth, lambda, dpois,
log = TRUE)) %>%
slice(-1) %>% select(-lambda) %>%
unnest(c(likelihood_r_t, r_t))
}
covid_cases %>%filter(Provinsi ==
state_selected) %>% smooth_new_cases()
%>%compute_likelihood() %>%
display_random()
```

Tabel 2. Nilai Estimasi Likelihood

Provinsi	Tanggal	PHKT	PHKT_smoth	r_t	likelihood_r_t
Sulawesi Selatan	2020-04-13	0	16	10.47	-158.273788
Sulawesi Selatan	2020-06-02	89	59	11.74	-528.219541
Sulawesi Selatan	2020-05-10	12	11	8.43	-46.628205
Sulawesi Selatan	2020-04-06	30	13	9.10	-48.391746
Sulawesi Selatan	2020-04-22	13	10	11.78	-99.431836
Sulawesi Selatan	2020-06-02	89	59	2.76	-5.399832

* Penambahan Harian Kasus Terkonfirmasi

Menghitung Posterior

```
compute_posterior <-
function(likelihood){likelihood %>%
arrange(Tanggal) %>%group_by(r_t) %>%
mutate(posterior = exp(
zoo::rollapplyr(likelihood_r_t, 7,
sum, partial = TRUE))) %>%
group_by(Tanggal) %>%mutate(posterior
= posterior / sum(posterior, na.rm =
TRUE)) %>%
# Tidak Menghitung Nilai NA
mutate(posterior =
ifelse(is.nan(posterior), 0,
posterior)) %>% ungroup() %>%
select(-likelihood_r_t)}
covid_cases %>%
filter(Provinsi == state_selected) %>%
smooth_new_cases() %>%
compute_likelihood() %>%
compute_posterior() %>%
display_random()
```

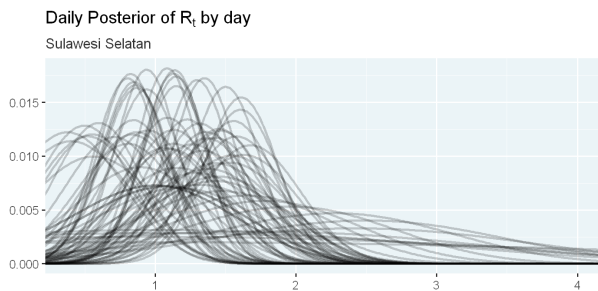
Tabel 3. Posterior dari Nilai R_t

Provinsi	Tanggal	PHKT	PHKTSmooth	r_t	posterior
Sulawesi Selatan	2020-04-09	10	14	5.16	0
Sulawesi Selatan	2020-05-26	33	32	6.98	0
Sulawesi Selatan	2020-03-30	4	7	6.48	0
Sulawesi Selatan	2020-04-04	0	8	4.54	0
Sulawesi Selatan	2020-04-14	9	15	11.92	0
Sulawesi Selatan	2020-04-09	10	14	5.45	0

* Penambahan Harian Kasus Terkonfirmasi

Plot Posterior

```
plot_posteriors <-
function(posterior) {
posterior %>%ggplot(aes(x = r_t, y =
posterior, group = Tanggal))
+geom_line(alpha = 0.2) +labs(
title = expression(paste("Daily
Posterior of R"[t], " by
day")), subtitle =
unique(posterior$Provinsi),
x = '', y = '') +
coord_cartesian(xlim = c(0.4, 4)) +
theme(legend.position = 'none')}
covid_cases %>%
filter(Provinsi == state_selected) %>%
smooth_new_cases() %>%
compute_likelihood() %>%
compute_posterior() %>%
plot_posteriors()
```

Gambar 1. Grafik Posterior Harian dari R_t **Estimasi Real Time (R_t) interval 95%**

```
# Estimate  $R_t$  untuk interval 95%
estimate_rt <- function(posterior) {
posterior %>%group_by(Provinsi,
Tanggal) %>%summarize(r_t_simulated =
list(sample(r_t_range, 10000, replace
= TRUE, prob = posterior)),
r_t_most_likely =
r_t_range[which.max(posterior)]
) %>%mutate(
r_t_lo = map_dbl(r_t_simulated, ~
hdi(.x)[1]),
r_t_hi = map_dbl(r_t_simulated, ~
hdi(.x)[2])
) %>%
select(-r_t_simulated)
}
```

```
covid_cases %>%
filter({Provinsi} == state_selected)
%>%
smooth_new_cases() %>%
compute_likelihood() %>%
compute_posterior() %>%
estimate_rt() %>%
display_head()
```

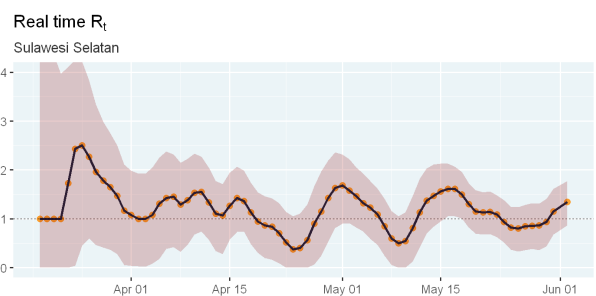
Gambar 2. Nilai Lo dan Hi Bandwidth dari nilai R_t yang paling mungkin

Provinsi	Tanggal	r_t_mo st_likel y	r_t_lo	r_t_hi
Sulawesi Selatan	2020-03-19	1.00	0.00	6.32
Sulawesi Selatan	2020-03-20	1.00	0.00	5.03
Sulawesi Selatan	2020-03-21	1.00	0.00	4.36
Sulawesi Selatan	2020-03-22	1.00	0.00	3.97
Sulawesi Selatan	2020-03-23	1.73	0.00	4.13
Sulawesi Selatan	2020-03-24	2.43	0.15	4.39

Grafik Estimasi Real Time (R_t) Propinsi Sulawesi Selatan

```
plot_estimates <- function(estimate) {
estimate %>%
ggplot(aes(x = Tanggal, y =
r_t_most_likely)) + geom_point(color =
"darkorange", alpha = 0.8, size = 4) +
geom_line(color = "#14243e") +
geom_hline(yintercept = 1, linetype =
'dashed') +geom_ribbon(aes(ymin =
r_t_lo, ymax = r_t_hi), fill =
'darkred', alpha = 0.2) +labs(title =
expression('Real time R'[t]), x = '',
y = '', subtitle =
unique(estimate$Provinsi)
) +coord_cartesian(ylim = c(0, 4))
}
covid_cases %>%
filter(Provinsi == state_selected) %>%
smooth_new_cases() %>%
compute_likelihood() %>%
compute_posterior() %>%
estimate_rt() %>%
plot_estimates()
```

Gambar 3. Grafik Hasil Estimasi Real Time Propinsi Sulawesi Selatan

**Gambaran Umum Estimasi Semua Propinsi di Indonesia**

```
estimates_all <- covid_cases %>%
filter(Tanggal >= "2020-03-19")
%>%group_by(Provinsi) %>%
# Abaikan propinsi dengan terpapar
kurang dari 50
```

```
filter(max(Penambahan_Harian_Kasus_Ter
konf) > 50 ) %>%group_split() %>%
  map_df(~ {.x %>%
    smooth_new_cases() %>%
    compute_likelihood() %>%
    compute_posterior() %>%
    estimate_rt()
  }) %>%
ungroup()
```

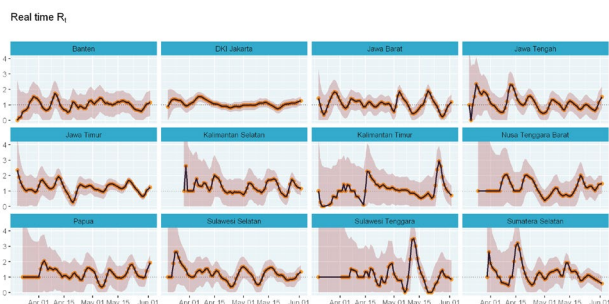
Tabel 4. Nilai Lo dan Ho Real Time untuk Propinsi dengan Kejadia diatas 50 PHKT

Provinsi	Tanggal	r_t_mo st_likel y	r_t_lo	r_t_hi
Nusa Tenggara Barat	2020-04-04	1.00	0.00	3.34
Kalimantan Timur	2020-05-25	2.39	0.97	3.67
DKI Jakarta	2020-04-20	0.91	0.65	1.16
DKI Jakarta	2020-04-23	0.83	0.57	1.10
Sulawesi Tenggara	2020-06-02	0.86	0.00	2.08
Sumatera Selatan	2020-04-07	0.65	0.00	2.57

```
Grafik gambaran Umum Semua Propinsi
# Merubah tinggi dan lebar area
grafik
options(repr.plot.height = 10,
repr.plot.width = 20)
estimates_all %>%plot_estimates() +
  facet_wrap(~ Provinsi, ncol = 4) +
  labs(subtitle = "")

# Pengaturan ulang
options(repr.plot.height = 12,
repr.plot.width = 8)
```

Gambar 4. Grafik Estimasi Real Time Propinsi dengan Kejadian PHKT lebih dari 50 Kejadian



4. DISKUSI

Dari hasil estimasi memperlihatkan kejadian harian yang fluktuatif, namun dari akhir periode dari data yang digunakan nampak kejadian cenderung naik.

Estimasi dengan menggunakan pendekatan lain dimungkinkan untuk digunakan yang hasilnya dapat dibandingkan dari setiap pendekatan tersebut.

5. DAFTAR PUSTAKA

- [1] Bettencourt LMA, Ribeiro RM (2008) Real Time Bayesian Estimation of the Epidemic Potential of Emerging Infectious Diseases. PLoS ONE 3(5): e2185. <https://doi.org/10.1371/journal.pone.0002185>
- [2] Mwangi TW, Fegan G, Williams TN, Kinyanjui SM, Snow RW, Marsh K (2008) Evidence for Over-Dispersion in the Distribution of Clinical Malaria Episodes in Children. PLoS ONE 3(5): e2196. <https://doi.org/10.1371/journal.pone.0002196>
- [3] Haign John, (2002) Probability Models. Springer. London.
- [4] David J. Olive, (2014). Statistical Teory and Inferences. Springer. London.
- [5] Murray Logan,(2010) Biostatistical Design and Analysis Using R, John Wiley & Sons, Inc. New York.
- [6] Gergely Daróczi ,(2015)Mastering Data Analysis with R. Packt Publishing. Birmingham, UK.
- [7] Data Covid-19 Indonesia. https://prod-hub-indexer.s3.amazonaws.com/files/685be21cd0034247b5ceeac996d947fe/0/full/4326/685be21cd0034247b5ceeac996d947fe_0_full_4326.csv