

COVID-19 Death Number Modeling and Forecasting of German-2020V

kobayashikorio@gmail.com

2020/4/29

2020/8/12

2021/3/14

2021/3/21

2021/3/24

初期値をデータに近づけた

解析の方針

事象のモデリング

事象のモデリングとは、数学的手法つまり、客観的な表現によって、ある一定の誤差範囲で、事象を式により表現することである。これを数学モデルと呼ぶ。このとき、誤差とは、観測値と式から導かれた数の間の偏差のことである。誤差は事象が環境のランダムネスを反映し、モデルのパラメータが環境のランダムネスを反映しないために、時間と共に拡大する。

両者の偏差が一定の範囲に止まっている間、モデルは、事象を予測できるであろう。

さらに、筆者は以下のように主張する。COVID-19事象については、数学モデルは一貫しており、そのパラメータのみが変化する。誤差が一定であり続ける間、数学モデルは事象をよく説明し、よく説明する故に、このモデルは事象の本質である。

モデルの対象は死亡者数とした。感染者数は、consistency(一貫性)に乏しく、その適切な補正方法を見つけられなかったために、これを対象としなかった。

死亡方程式の導出

死亡者数を積算した時系列が、指数関数的に増加し続けることはないだろう。人類の感染症の歴史からみて、死亡者数の変化傾向は、事象の時間経過と共に必ず一定値に漸近するであろう。この考えの下に、事象を表現する微分方程式を導くことができる。

考え方については、Google Slide (<https://docs.google.com/presentation/d/1M3wCr575y5J8-sb5MJhg97VINIMc1JOps2tLqErQZXKk/edit>)に述べた。

漸近する一定値は0とは限らない。死亡者数が年齢をパラメータとして持つとき、漸近する一定値が0でないことがあり得る。すなわち、ある感染症が死亡原因の一つとなる場合である。

報告値に対するGompertz曲線フィッティング

上記の考え方の下、目的変数 y を死亡者数とした微分方程式 $dy = A y^{\alpha} \exp(-Bt) dt$ の解は、Gompertz曲線である。Gompertz曲線の含意するところは、死亡者数の増加傾向は、死亡者数をパラメータとするゆえに、指数関数的に増大し、減少は、時間 t だけをパラメータとする（時間のみをパラメータとして持つのであれば、減少はウィルス変異の集積を通じて起きると考えられよう（他に原因となる仮説が見つからないゆえに）。すなわち集団免疫成立の否認である）。

Gompertz曲線は、日本以外の殆どの国についてフィッティングできるのであるが、事象の初期において、日本のケースだけは適切なフィッティングが出来なかった。

日本のケースにフィッティング出来ない理由を仮説推定してみた。設定した仮説は、日本の死亡者数の時系列は、複数の独立事象の和である、とした。この仮説の採用で、現在までの時系列が表現できた（事象が複数の独立事象の和で表現できることは、目的変数の現象が時間のみの関数であることを含意する）。

計算のポリシー

事象がただ一つの曲線では、フィッティング出来ないとの気づきを得て、以下のポリシーにより事象をモデル化する。

1. モデルはGompertz曲線により与えられる
2. 一定の誤差に偏差を収めるために複数のGompertz曲線を用いる

計算の手順

事象が収束するまで、すなわち、観測値とモデルの偏差が一定の誤差以下になるまで、以下を続ける。

1. 観測値を与える
2. Fittingされた（Fitting関数がオーバーフロー、アンダーフローが起こさない）モデルで将来予測する
3. ヒューリスティックに初期値を与えた後、Fitting関数によって曲線のパラメータを求める
4. 得られたGompert曲線を元の観測値から差し引く
5. 誤差が一定範囲内から外れるなら、新規の事象が発生したと考え、新規事象の始まりを定義し、最初に戻る
6. 最初に戻る

計算途中の気づきなど

(2020/7/12)死亡原因の主たるウィルス株は交代すると考えたなら、報告死亡者数をモデルがよく表現できた。これは日本の例に明らかであるが、他の国の場合にも当てはまる（米国の事象を表現できる）。

(2020/8/12)日本の報告値が、時間経過と共に、2つのGompertz曲線の足し合わせでは、表現できなくなった。事象は、3つのGompertz曲線の足し合わせで表現できた。

(2020/10/24)日本の報告値が、時間経過と共に、複数のGompertz曲線の足し合わせでしか、表現できなくなった。この時点の事象は、異なるパラメータを持つ、4つのGompertz曲線の足し合わせで表現されている。事象の全体は、個々の事象の再帰的な表現であるとの考え方が、確からしさを増した。個々の事象の収束がウィルスの変異に依るものであるように、個々の事象の足し合わせである全体の事象についても、ウィルスのアイデンティティが保持されつつ、起きる変異は、有限である筈なので、全体の事象もまた、個々の事象が収束するように、一定の時間経過の後、収束するだろうからである。

(2020/12/2)日本のモデルに5番目の事象を加えた。

データの準備

元データのアーカイブ場所

多くのデータサイトはJohns Hopkins大学からデータを引用している。

2019 Novel Coronavirus COVID-19 (2019-nCoV) Data Repository by Johns Hopkins CSSE

<https://github.com/CSSEGISandData/COVID-19>

J.Hopkins大学のデータがJSONに変換された例がある。

JSON time-series of coronavirus cases (confirmed, deaths and recovered) per country - updated daily

<https://github.com/pomber/covid19>

このサイトのJSONファイルは以下から読み取ることができる。

<https://pomber.github.io/covid19/timeseries.json>

(オプション)JSONファイルの国名は以下で読める。

```
In[*]:= Association[Import[urlCovid19]] // Keys
```

解析の開始

```
In[*]:= entity = "Germany";
population = Normal[Entity["Country", entity] ["Population"]]
```

```
Out[*]:= 82 114 224
```

データを取得する。

```

In[1]:= country = "Germany";
population = 83 517 046;
urlCovid19 = "https://pomber.github.io/covid19/timeseries.json";
data = Map[Association, Association[Import[urlCovid19]][country], {1}];
ddata = {DateObject[#[[1]]], #[[2]]} & /@ data;
firstday = ddata[[1, 1]];
Last[ddata]

```

```

Out[6]= { Fri 15 Oct 2021 , 94 605 }


```

初回報告日からの経過日数と報告のなかった日のデータからの削除

```

In[7]:= i4 = Map[{QuantityMagnitude[#[[1]] - firstday], #[[2]]} &, ddata];
raw = Map[First, Gather[i4, #1[[2]] == #2[[2]] &]];
rawModified[1] = raw;
ListPlot[raw]

```




```

In[8]:= delta = Apply[Subtract, Map[Reverse,
BlockMap[Transpose, Select[raw, 30 < #[[1]] ≤ 550 &], 2, 1], {2}], {2}];

```

```
In[*]:= ListLinePlot[Map[Last, delta], PlotRange -> {0, 1600}]
```



Iteration計算


1回目

時系列の分割

報告開始日から、ある期日までの結果は、最初のウィルス株によるもの、それ以降の結果は、次のウィルス株によるものと考えて、報告データを切り分ける。この切りわけ日の設定は、報告数の時系列が作る曲線の変曲点からヒューリスティックに決める。

第一回は60日で切り分ける。


```
In[11]:= rawModified[1] = raw;
targetPeriod = Select[rawModified[1], #[[1]] ≤ 120 &];
ListPlot[targetPeriod]
```



時系列へのマッチングの初期値設定

分割した時系列のうち、最初の時系列をGompertz曲線にマッチングさせるために、ヒューリスティックに初期値を与える。すなわち、試行錯誤を繰り返して、Gompertz曲線が、報告された時系列に近くなるようにする。

```
In[14]:= start = 70;
model[1] = n b^Exp[-c (t - start)];
initialguess = {n → 10 000, c → 0.05, b → 0.04};
Show[
  Plot[model[1] /. initialguess, {t, 0, 200}, PlotRange → {{0, 150}, {0, 10 000}}],
  ListPlot[targetPeriod]
]
```




Fitting関数を用い、与えた初期値でパラメータを推定し、最初の時系列をGompertz曲線にFittingさせる。

```
In[18]:= ans[1] = FindFit[targetPeriod, model[1],
  initialguess /. Rule → List, t, MaxIterations → 200]
```

Out[18]= {n → 8728.04, c → 0.0714435, b → 0.104764}

```
In[19]:= Show[
  Plot[model[1] /. ans[1], {t, 0, 150}, PlotRange -> {{0, 150}, {0, 10 000}}],
  ListPlot[targetPeriod]
]
```




報告時系列のモディファイ

報告開始日から60日目までを最初のウィルス株による結果、それ以降を次のウィルス株による結果と考える。この切りわけ日の設定は、報告数の時系列が作る曲線の変曲点からヒューリスティックに決めてある。

時系列にfittingさせたGompertz曲線を用いて、報告時系列から、分割された時系列から推定した、推定死亡数時系列を差し引く。つまり、ウィルス株の影響を差し引く。Fittingが成功しているなら、報告時系列の当該部分は0となるであろう。差し引いた時系列をモディファイド時系列と呼ぶ。

```
In[20]:= {pdays, death} = Transpose[rawModified[1]];
ListPlot[
  rawModified[2] = Transpose[{pdays, death - (model[1] /. ans[1] /. t -> pdays)}]]
```




日以前のデータの時系列が0にされた、rawModified[2]が生成された。

```
In[22]:=
```

2回目


第2回はx日で切り分けて、着目するのがtargetPeriod である。

```
In[23]:= targetPeriod = Select[rawModified[2], #[[1]] ≤ 180 &];
ListPlot[targetPeriod]
```



二番目の時系列をGompertz曲線にFittingさせるために、ヒューリスティックに初期値を与える。

```
In[25]:= start = 120;
model[2] = n b^Exp[-c (t - start)];
initialguess = {n → 450, c → 0.04, b → 0.08};
Show[
  Plot[model[2] /. initialguess, {t, 0, 1000}, PlotRange → {{0, 170}, {0, 800}}],
  ListPlot[targetPeriod]
]
```



初期値を与えて、ターゲットとなる時系列をGompertz曲線にFittingさせる。

```
In[29]:= ans[2] = FindFit[targetPeriod, model[2],
  initialguess /. Rule → List, t, MaxIterations → 200]
```

Out[29]= {n → 410.996, c → 0.0588294, b → 0.0332348}

In[30]:= upto = 200;


Show[

Plot[model[2] /. ans[2], {t, 0, upto}, PlotRange → {{0, 200}, {0, 800}},

ListPlot[targetPeriod]

]

General: 0.0332348^{1163.62}は正規化された機械数として表すには小さすぎます。精度が失われる可能性があります。



報告時系列のモディファイ


時系列にfittingさせたGompertz曲線を用いて、報告時系列から、分割された時系列から推定した、推定死亡数時系列を差し引く。つまり、ウィルス株の影響を差し引く。Fittingが成功しているなら、報告時系列の当該部分は0となるであろう。rawModified[3] が生成される。

In[32]:= {pdays, death} = Transpose[rawModified[2]];

ListPlot[

rawModified[3] = Transpose@{pdays, death - (model[2] /. ans[2] /. t → pdays)},

PlotRange → {{0, 380}, {-30, 1200}}]




In[34]:=

3回目

残った時系列は、これまでに推定した時系列を差し引いた、ターゲット時系列である。ヒューリスティックに初期値を与えて、Fittingする。


第3回はx日で切り分けて、着目するのがtargetPeriod である。

```
In[35]:= targetPeriod = Select[rawModified[3], #[[1]] ≤ 430 &];
ListPlot[targetPeriod]
```



```
In[37]:= start = 260;
model[3] = n / (1 + c Exp[-a n (t - start)]);
initialguess = {n → 75 000, c → 100, a → 0.0000006}
Show[
  Plot[model[3] /. initialguess,
    {t, 0, 1000}, PlotRange → {{200, 450}, {0, 75 000}}],
  ListPlot[targetPeriod]]
```


Out[39]= $\{n \rightarrow 75\,000, c \rightarrow 100, a \rightarrow 6. \times 10^{-7}\}$



```
In[41]:= ans[3] = FindFit[targetPeriod, model[3],
  initialguess /. Rule → List, t, MaxIterations → 200]
```

Out[41]= $\{n \rightarrow 67\,921., c \rightarrow 100.836, a \rightarrow 7.07315 \times 10^{-7}\}$


```
In[42]:= upto = 430;
Show[
  ListPlot[rawModified[3]],
  Plot[model[3] /. ans[3], {t, 0, upto}],
  PlotRange -> {{0, upto}, {0, 75 000}}
```



報告時系列のモディファイ

rawModified[4] が生成される。

```
In[44]:= {pdays, death} = Transpose[rawModified[3]];
ListPlot[
  rawModified[4] = Transpose@{pdays, death - (model[3] /. ans[3] /. t -> pdays)},
  PlotRange -> {{0, 550}, {-30, 12 000}}
```




```
In[ ]:=
```

4回目

start地点から前のデータをノイズとみなす。


Logistic curve

```
In[46]:= targetPeriod = Select[rawModified[4], #[[1]] <= (560) &];
ListPlot[targetPeriod]
```



```
In[48]:= start = 420;
model[4] = n / (1 + c Exp[-a n (t - start)]);
initialguess = {n → 4000, c → 100, a → 0.000006}
Show[
  Plot[model[4] /. initialguess,
    {t, 0, 1000}, PlotRange → {{400, 450}, {0, 5000}}],
  ListPlot[targetPeriod]]
```

Out[50]= {n → 4000, c → 100, a → 0.000006}



```
In[52]:= ans[4] = FindFit[targetPeriod, model[4],
  initialguess /. Rule → List, t, MaxIterations → 200]
```

Out[52]= {n → 14 329.6, c → 22.9594, a → 4.42136 × 10⁻⁶}


報告時系列のモディファイ

rawModified[5] が生成される。

```

In[53]:= {pdays, death} = Transpose[rawModified[4]];
ListPlot[
  rawModified[5] = Transpose@{pdays, death - (model[4] /. ans[4] /. t → pdays)},
  PlotRange → {{520, 650}, {-30, 4000}}]

```



5回目


start地点から前のデータをノイズとみなす。

Logistic curve

```


In[55]:= targetPeriod = Select[rawModified[5], #[[1]] ≥ (520) &];
ListPlot[targetPeriod]

```



```
In[57]:= start = 520;
model[5] = n / (1 + c Exp[-a n (t - start)]);
initialguess = {n → 4000, c → 40, a → 0.00001}
Show[
  Plot[model[5] /. initialguess,
    {t, 0, 1000}, PlotRange → {{520, 650}, {0, 5000}}],
  ListPlot[targetPeriod]]
```

```
Out[59]= {n → 4000, c → 40, a → 0.00001}
```



```
In[61]:= ans[5] = FindFit[targetPeriod, model[5],
  initialguess /. Rule → List, t, MaxIterations → 200]
```

```
Out[61]= {n → 6313.28, c → 96.7156, a → 6.51272 × 10-6}
```

計算結果と評価

人口に対する死亡率の推定

```
In[62]:= percent =
  100 Divide[(model[1] /. ans[1]) + (model[2] /. ans[2]) + (model[3] /. ans[3]) +
    (model[4] /. ans[4]) + (model[5] /. ans[5]) /. t → Infinity, population]
```

```
Out[62]= 0.116986
```

```
In[63]:= population * percent / 100
```

```
Out[63]= 97 703.
```

全ての時系列へのフィッティング

得られた4つのGompertz曲線の和と報告時系列を表示する。

```
In[64]:= fdate = First[ddata][[1]];
         ldate = Last[ddata][[1]];

```

```
upto = 700;


```

```
Show[
  Plot[(model[1] /. ans[1]) + (model[2] /. ans[2]) + (model[3] /. ans[3]) +
        (model[4] /. ans[4]) + (model[5] /. ans[5]), {t, 0, upto}, PlotTheme → "Grid",
        PlotRange → {{0, upto}, {0, 100 000}}, PlotStyle → {Purple, Thickness[0.005]}],
  ListPlot[raw, PlotLegends →
    Placed[Text[Style[country <> "\n" <> "Estimated death ratio: " <>
      ToString[DecimalForm[percent, 3]] <> " %", 13, Bold]], {0.3, 0.75}]],
    ImageMargins → 20,
    Frame → True,
    PlotLabel → DateString[fdate] <> "-" <> DateString[ldate],
    FrameLabel → {Style["Days passed from the first report day", 13],
      Style["Accumulated death", 13]}, LabelStyle → {Black}]

```

General: 0.0332348^{1162.92} は正規化された機械数として表すには小さすぎます。精度が失われる可能性があります。

Out[67]=



モデルと報告値の偏差


```

In[ ]:= Clear[et]

In[ ]:= {pdays, death} = Transpose[raw];
diff =
  Transpose@{pdays, 100 * (death - (et = (model[1] /. ans[1]) + (model[2] /. ans[2]) +
    (model[3] /. ans[3]) + (model[4] /. ans[4]) /. t -> pdays)) / et};

ListLinePlot[diff,
  PlotRange -> {{100, 500}, {-20, 20}},
  PlotLegends -> Placed[Text[Style[country, Bold]], {0.2, 0.8}]]

```




```

In[ ]:= filter = EntropyFilter[Transpose[raw][[2]], 5] // N

In[ ]:= ListLinePlot[filter]

```




まとめ

報告時系列をモディファイ（時系列からモデル推定値を差し引いた残差を新たな時系列とする）する操作の図解（3回までの時）

例えば、報告時系列を、事象の始まりの部分から順に、Gompertz曲線にフィッティングさせ

て、フィッティング結果を報告時系列から差し引く操作を2回実行する。フィッティング操作は3回実行する。

```
In[ ]:= Show[ListPlot[raw], ListPlot[rawModified[2]],  
ListPlot[rawModified[3], PlotRange -> All]]
```



報告時系列にGompertz曲線をフィッティングさせる操作のまとめ

1. 事象を、微分方程式の解を用いてモデル化することと、多項式を用いてフィッティングすることは、全く異なるモデリングの方法である。微分方程式は、事象が物理過程に従うという確信の表現であるが、多項式が事象の表現であるとは言えない。
2. 報告数の時系列をモデル化するためには、時系列を、適切と考えられる曲線（この事象に対しては、微分方程式の解であるGompertz曲線）にフィッティングさせる必要がある。Gompertz曲線は非線形であるので、FindFit関数を適用するためには、初期値を必要とする。
3. イタレーションを繰り返しても、フィッティングできない場合、対象とする事象が、想定した方程式が表現する物理過程と異なる、と考えるべきである（上記の例で言えば、報告時系列を分割しない限り、単一のGompertz曲線で事象に適切なフィッティングを得ることは不可能である）。
4. モデルと報告値の偏差の、報告値に対する割合によって、モデルの精度を推定することができる。
5. 事象の報告値にはノイズが含まれているが、例えば、事象開始後145日目に起きたディップを、有意な信号か否かは判然としない。ただし、モデルと報告値の偏差の時系列が、何らかのインディケーションを示す可能性は残る。

EOF

■配列A, BにおけるEER計算方法

配列A Aの出現確率 = 3 / 10 Bの出現確率 = 3 / 10 Cの出現確率 = 4 / 10

配列B Aの出現確率 = 6 / 10 Bの出現確率 = 4 / 10

配列A AAABBBCCCC

配列B AAAAAABBBB

$$SE(P) = - \sum P(X) \log P(X)$$