

โมเดลเส้นโค้งพัฒนาการแบบซับซ้อน (Complex Growth Curve Model)

โมเดลพหุระดับ (Multilevel Modeling)

สันทัด พรประเสริฐมานิต

โครงร่างการนำเสนอ

- รูปแบบการเปลี่ยนแปลง
- โครงสร้างความสัมพันธ์ค่าคงเหลือ (Residual Correlation)
- สมบัติการทำนาย

รูปแบบการเปลี่ยนแปลง

โมเดลการเปลี่ยนแปลงเชิงเส้น


$$Y = b_0 + b_1t$$

$$A: Y = 20 + 5t$$

$$B: Y = 10 + 3t$$

$$C: Y = 40 - 2t$$

t	$Y(A)$	$Y(B)$	$Y(C)$
0	20	10	40
1	25	13	38
2	30	16	36
3	35	19	34
4	40	22	32



รูปแบบการเปลี่ยนแปลง

โมเดลการเปลี่ยนแปลงแบบสมการยกกำลังสอง (Quadratic curve)


$$Y = b_0 + b_1t + b_2t^2$$

$$A: Y = 20 + 5t - 2t^2$$

$$B: Y = 10 + 3t + 1.5t^2$$

$$C: Y = 40 - 2t - 0.5t^2$$

t	$Y(A)$	$Y(B)$	$Y(C)$
0	20	10	40
1	23	14.5	38.5
2	22	22	38
3	17	32.5	38.5
4	8	46	40



รูปแบบการเปลี่ยนแปลง

โมเดลการเปลี่ยนแปลงแบบสมการยกกำลังสาม (Cubic curve)


$$Y = b_0 + b_1t + b_2t^2 + b_3t^3$$

$$A: Y = 20 + 5t - 2t^2 + 0.5t^3$$

$$B: Y = 10 + 3t^2 - 0.5t^3$$

$$C: Y = 30 + 2t + 3t^2 - t^3$$

t	$Y(A)$	$Y(B)$	$Y(C)$
0	20	10	30
1	23.5	12.5	34
2	26	18	38
3	30.5	23.5	36
4	40	26	22



รูปแบบการเปลี่ยนแปลง

โมเดลการเปลี่ยนแปลงแบ่งช่วงย่อย (Spline Model)

แบ่งเวลาออกเป็น 2 ช่วง โดยให้ $t = t_1 + t_2$

แบ่งเวลาออกเป็น 3 ช่วง โดยให้ $t = t_1 + t_2 + t_3$

จากสมการดังกล่าว สามารถแบ่งการเปลี่ยนแปลง
เชิงเส้นเป็นดังนี้

$$Y = b_0 + b_1 t = b_0 + b_1 t_1 + b_1 t_2$$

สมการนี้สามารถให้สัมประสิทธิ์ถดถอยของ t_1 และ t_2 แตกต่างกันได้



$$Y = b_0 + b_1 t_1 + b_2 t_2$$

t	t_1	t_2
0	0	0
1	1	0
2	2	0
3	2	1
4	2	2

รูปแบบการเปลี่ยนแปลง

$$Y = b_0 + b_1 t_1 + b_2 t_2$$

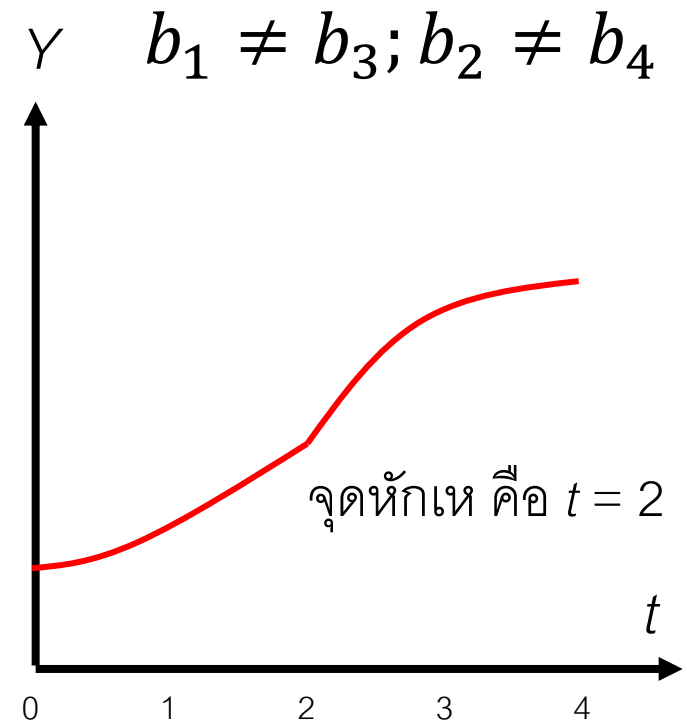

t	t_1	t_2
0	0	0
1	1	0
2	2	0
3	2	1
4	2	2



รูปแบบการเปลี่ยนแปลง

$$Y = b_0 + b_1 t_1 + b_2 t_1^2 + b_3 t_2 + b_4 t_2^2$$

t	t_1	t_2
0	0	0
1	1	0
2	2	0
3	2	1
4	2	2



รูปแบบการเปลี่ยนแปลง

โมเดลการเปลี่ยนแปลงแบ่งช่วงย่อยเชิงเส้น (Linear Spline Model)


$$Y = b_0 + b_1 t_1 + b_2 t_2$$

$$A: Y = 20 + 5t_1 - 2t_2$$

$$B: Y = 10 + 3t_1 + 2t_2$$

$$C: Y = 40 - 2t_1 - 2t_2$$

t	t_1	t_2	$Y(A)$	$Y(B)$	$Y(C)$
0	0	0	20	10	40
1	1	0	25	13	38
2	2	0	30	16	36
3	2	1	28	18	34
4	2	2	26	20	32



รูปแบบการเปลี่ยนแปลง

โมเดลการเปลี่ยนแปลงแบ่งช่วงย่อยกำลังสอง (Quadratic Spline Model)


$$Y = b_0 + b_1t + b_2t_1^2 + b_3t_2 + b_4t_2^2$$

$$A: Y = 20 + 5t_1 - 2t_1^2 - 3t_2 - 4t_2^2$$

$$B: Y = 10 + 3t_1 + 1.5t_1^2 + 7t_2 - 2t_2^2$$

$$C: Y = 40 - 4t_1 - 0.5t_1^2 - 2t_2^2$$

t	t_1	t_2	$Y(A)$	$Y(B)$	$Y(C)$
0	0	0	20	10	40
1	1	0	23	14.5	36.5
2	2	0	22	22	34
3	2	1	15	27	34.5
4	2	2	0	28	36



โมเดลการเปลี่ยนแปลงแบ่งช่วงย่อยกำลังสอง (Quadratic Spline Model)


$$Y = b_0 + b_1t + b_2t_1^2 + b_3t_2 + b_4t_2^2 + b_5t_3 + b_6t_3^2 \quad \text{แบ่งสามช่วง}$$

$$A: Y = 20 + 5t_1 - 2t_1^2 - 3t_2 + 1.5t_2^2 + 4t_3 + 2t_3^2$$

$$B: Y = 10 + 3t_1 + 1.5t_1^2 + 7t_2 - 2t_2^2 - 3t_3 + 0.5t_3^2$$

$$C: Y = 40 - 4t_1 - 0.5t_1^2 - 2t_2^2 - 0.5t_3$$

t	t_1	t_2	t_3	$Y(A)$	$Y(B)$	$Y(C)$
0	0	0	0	20	10	40
1	1	0	0	23	14.5	36.5
2	2	0	0	22	22	34
3	3	0	0	17	32.5	32.5
4	3	1	0	15.5	37.5	33
5	3	2	0	17	38.5	34.5
6	3	3	0	21.5	35.5	37
7	3	3	1	27.5	33	36.5
8	3	3	2	37.5	31.5	36




รูปแบบการเปลี่ยนแปลง

นักวิจัยต้องการตรวจสอบผลการบำบัด
ความเครียดจากสถาบันแห่งหนึ่ง



นักวิจัยเก็บข้อมูลจากคนไข้ 1000 คน โดยแบ่ง
คนไข้เป็น 2 กลุ่ม คือ กลุ่มบำบัดปกติ และกลุ่ม
ควบคุม โดยเก็บข้อมูลต่อเนื่อง 14 วัน

ระยะที่ 1 : วัดข้อมูลพื้นฐาน (วันที่ 1-5)
ระยะที่ 2 : บำบัดคนไข้ (วันที่ 6-11)
ระยะที่ 3 : ติดตามผล (วันที่ 12-14)



เวลาที่มีทั้งหมด 14 วัน จะใส่ค่าตั้งแต่ 0 – 13 โดยค่า 0 คือค่าความเครียดก่อนเข้ารับบำบัด

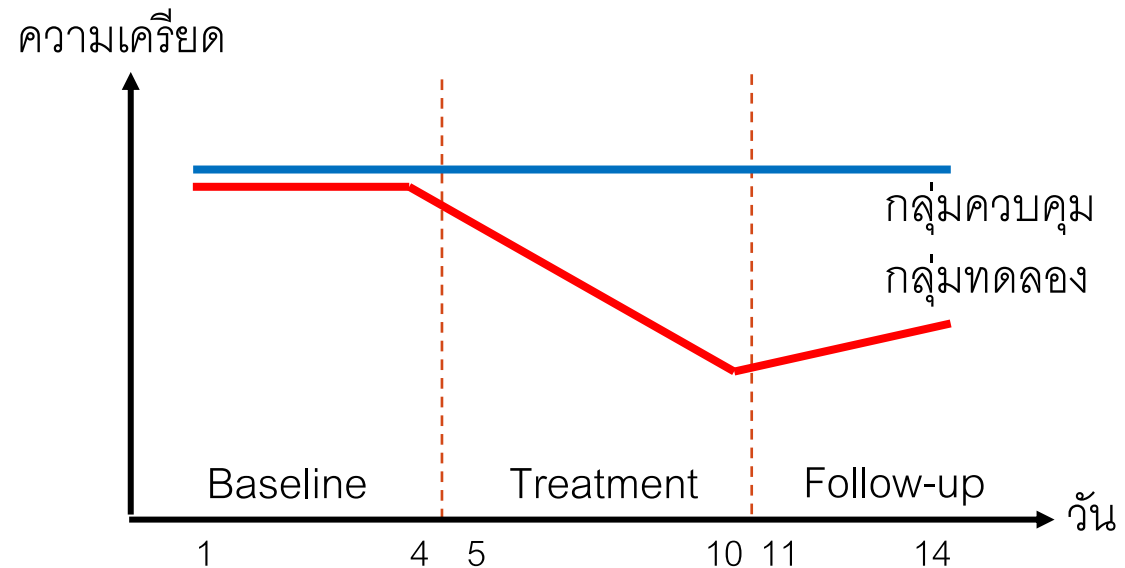
t	t_c	t_1	t_2	t_3
1	0	0	0	0
2	1	1	0	0
3	2	2	0	0
4	3	3	0	0
5	4	4	0	0
6	5	4	1	0
7	6	4	2	0
8	7	4	3	0
9	8	4	4	0
10	9	4	5	0
11	10	4	6	0
12	11	4	6	1
13	12	4	6	2
14	13	4	6	3

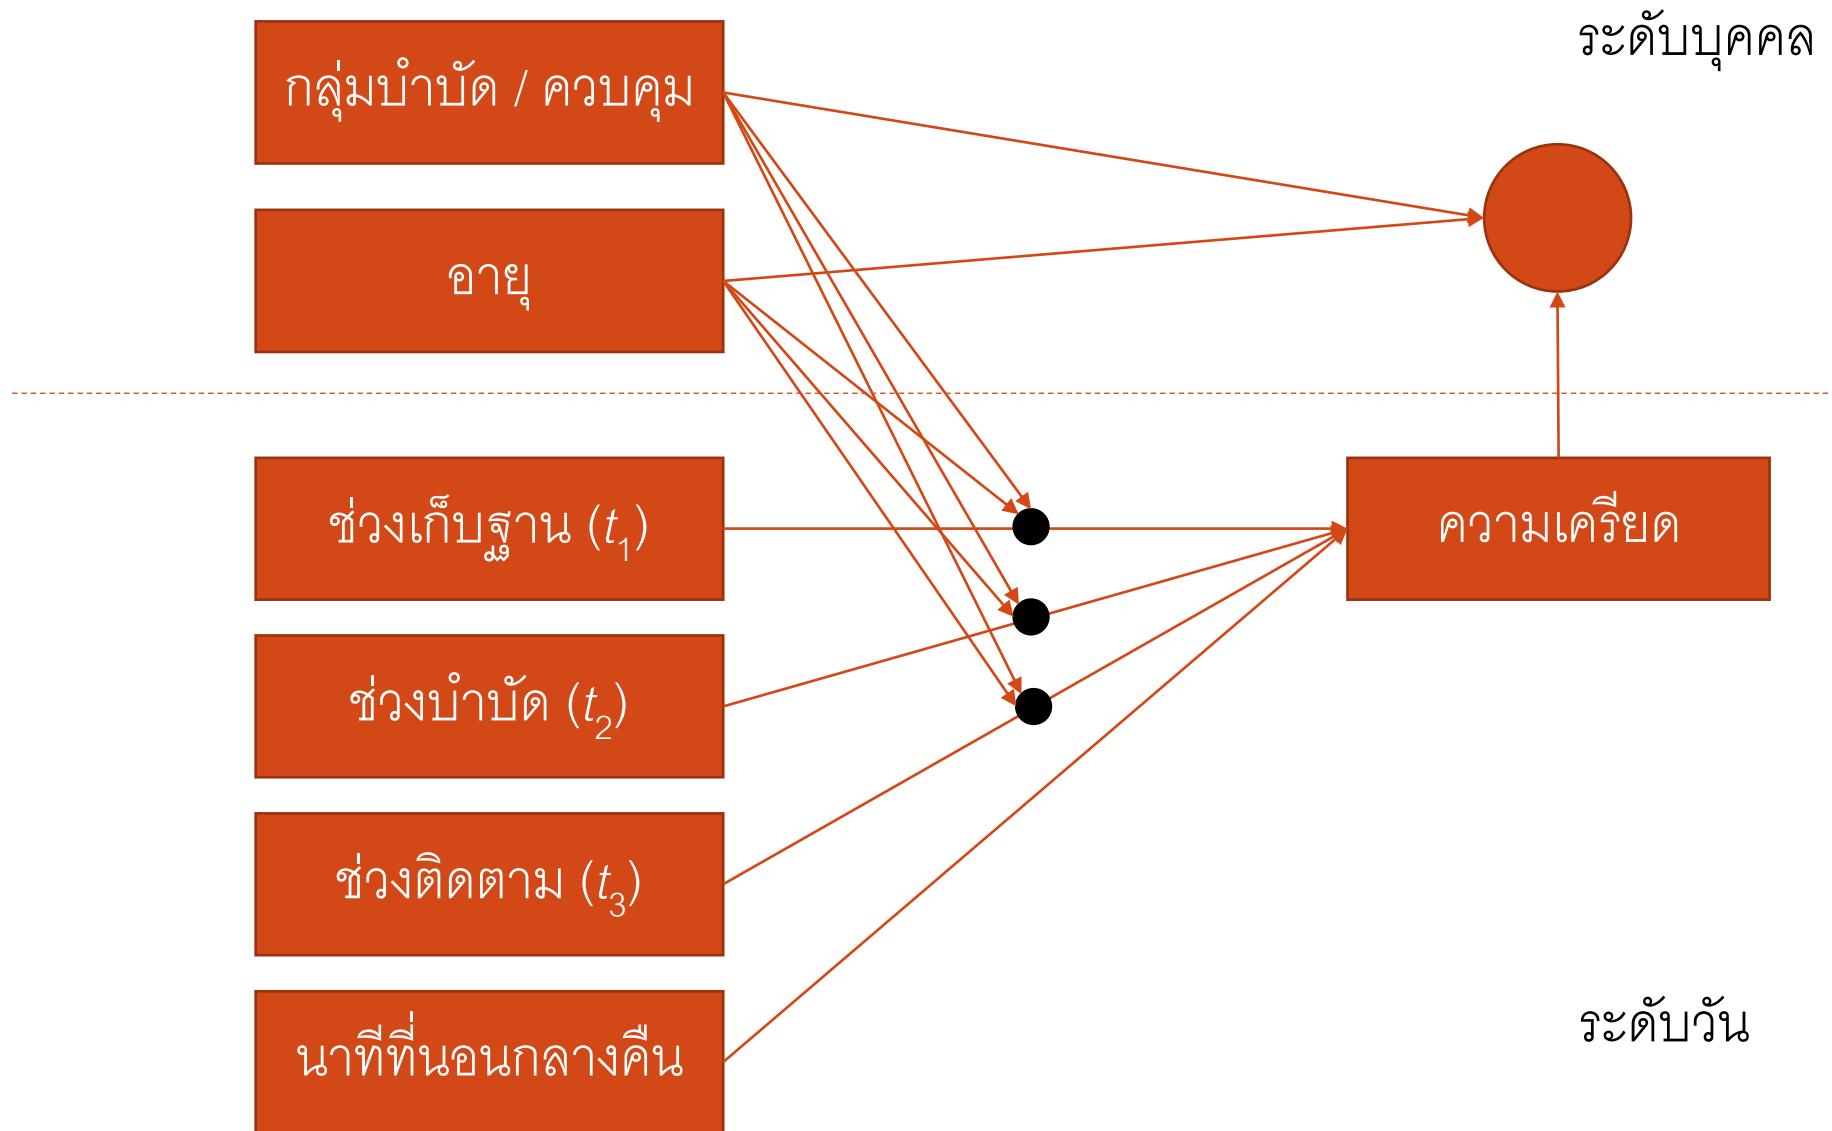
$$t_c = t_1 + t_2 + t_3$$

t_1 = การเปลี่ยนแปลงเชิงเส้นช่วง Baseline

t_2 = การเปลี่ยนแปลงเชิงเส้นช่วง Treatment

t_3 = การเปลี่ยนแปลงเชิงเส้นช่วง Follow-up





รูปแบบการเปลี่ยนแปลง

```
> dat1 <-read.table("lecture9ex1.csv", sep="," , header=TRUE)
```

```
> psych::describe(dat1)
```

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
rowid	1	14000	7000.50	4041.60	7000.5	7000.50	5189.10	1	14000	13999	0.00	-1.20	34.16
pid	2	14000	500.50	288.69	500.5	500.50	370.65	1	1000	999	0.00	-1.20	2.44
time	3	14000	7.50	4.03	7.5	7.50	5.19	1	14	13	0.00	-1.21	0.03
stress	4	14000	50.21	9.85	51.0	50.39	10.38	11	83	72	-0.20	0.10	0.08
treat	5	14000	0.50	0.50	0.5	0.50	0.74	0	1	1	0.00	-2.00	0.00
sleep	6	14000	423.58	58.69	423.0	423.53	60.79	226	635	409	0.01	-0.13	0.50
age	7	14000	36.64	6.20	36.0	36.58	5.93	18	60	42	0.11	0.00	0.05

- ตัวแปรเวลา (time) ที่แสดงถึงวันที่วัด
- แบ่งการเปลี่ยนแปลงเชิงเส้นออกเป็น 3 ส่วน คือ ช่วงวัดข้อมูลพื้นฐาน, ช่วงบำบัด, และช่วงติดตามผล

```
> dat1$timec <- dat1$time - 1
```

```
> dat1$timebase <- dat1$timec
```

```
> dat1[dat1$timebase > 4, "timebase"] <- 4
```

```
> dat1$timetreat <- dat1$timec - dat1$timebase
```

```
> dat1[dat1$timetreat > 6, "timetreat"] <- 6
```

```
> dat1$timefollow <- dat1$timec - dat1$timebase - dat1$timetreat
```

รูปแบบการเปลี่ยนแปลง

```
> dat1 <-read.table("lecture9ex1.csv", sep=";", header=TRUE)  
> psych::describe(dat1)
```

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
rowid	1	14000	7000.50	4041.60	7000.5	7000.50	5189.10	1	14000	13999	0.00	-1.20	34.16
pid	2	14000	500.50	288.69	500.5	500.50	370.65	1	1000	999	0.00	-1.20	2.44
time	3	14000	7.50	4.03	7.5	7.50	5.19	1	14	13	0.00	-1.21	0.03
stress	4	14000	50.21	9.85	51.0	50.39	10.38	11	83	72	-0.20	0.10	0.08
treat	5	14000	0.50	0.50	0.5	0.50	0.74	0	1	1	0.00	-2.00	0.00
sleep	6	14000	423.58	58.69	423.0	423.53	60.79	226	635	409	0.01	-0.13	0.50
age	7	14000	36.64	6.20	36.0	36.58	5.93	18	60	42	0.11	0.00	0.05

- ตัวแปรควบคุมที่เปลี่ยนแปลงตามเวลา (Time-varying covariate) คือตัวแปรแทรกซ้อนที่อยู่ในระดับการวัดซ้ำ
- ตัวแปรควบคุมที่ไม่เปลี่ยนแปลงตามเวลา (Time-invariant covariate) คือตัวแปรแทรกซ้อนที่อยู่ในระดับบุคคล

ตัวแปรทั้งสองระดับ อาจมีปฏิสัมพันธ์กับตัวแปรเวลาได้


```
> out1a <- lmer(stress ~ 1 + (1|pid), data=dat1, REML=FALSE)
```

```
> summary(out1a)
```

```
Linear mixed model fit by maximum likelihood ['lmerMod']
```

```
Formula: stress ~ 1 + (1 | pid)
```

```
Data: dat1
```

```
          AIC      BIC   logLik deviance df.resid
103315.8 103338.4 -51654.9 103309.8   13997
```

```
Scaled residuals:
```

```
      Min       1Q   Median       3Q      Max
-3.7791 -0.6489  0.0212  0.6755  3.2755
```

```
Random effects:
```

```
Groups   Name             Variance Std.Dev.
pid      (Intercept)    9.076   3.013
Residual                    88.021   9.382
Number of obs: 14000, groups: pid, 1000
```

ความแปรปรวนระดับบุคคล = 9.08

ความแปรปรวนระดับการวัดซ้ำภายในบุคคล = 88.02

```
Fixed effects:
```

```
              Estimate Std. Error t value
(Intercept)  50.2054     0.1239     405
```

$$ICC = 9.08 / (9.08 + 88.02) = .093$$

ค่าเฉลี่ยของความเครียดระหว่างทุกคนทุกวัน = 50.20 คะแนน

ใส่ตัวแปรเวลา โดยอัตราการเปลี่ยนแปลงเชิงเส้นตรง ยังไม่แบ่งช่วง ยังไม่เปลี่ยนตามบุคคล

```
> out1b <- lmer(stress ~ 1 + timec + (1|pid), data=dat1, REML=FALSE)
```

```
> summary(out1b)
```

Linear mixed model fit by maximum likelihood ['lmerMod']

Formula: stress ~ 1 + timec + (1 | pid)

Data: dat1

AIC	BIC	logLik	deviance	df.resid
102801.3	102831.5	-51396.6	102793.3	13996

Scaled residuals:

Min	1Q	Median	3Q	Max
-3.8198	-0.6463	0.0086	0.6626	3.2683

Random effects:

Groups	Name	Variance	Std.Dev.
pid	(Intercept)	9.321	3.053
Residual		84.592	9.197

Number of obs: 14000, groups: pid, 1000

Fixed effects:

	Estimate	Std. Error	t value
(Intercept)	53.08240	0.17628	301.13
timec	-0.44262	0.01928	-22.95

← ความแปรปรวนระดับบุคคล = 9.32

← ความแปรปรวนระดับการวัดซ้ำภายในบุคคลคงเหลือ = 84.59

← ค่าเฉลี่ยของความเครียดในวันที่ 1 (ก่อนบำบัด) = 53.08 คะแนน

← เมื่อผ่านไปแต่วัน ความเครียดลดลง วันละ 0.44 คะแนน ซึ่งลดลงอย่างมีนัยสำคัญ

ใส่ตัวแปรเวลา เปลี่ยนแปลงเชิงเส้นตรงแบบแบ่งช่วง ยังไม่เปลี่ยนตามบุคคล

```
> out1c <- lmer(stress ~ 1 + timebase + timetreat  
+               + timefollow + (1|pid), data=dat1, REML=FALSE)  
> summary(out1c)  
Linear mixed model fit by maximum likelihood ['lmerMod']  
Formula: stress ~ 1 + timebase + timetreat + timefollow + (1 | pid)  
Data: dat1
```

```
          AIC      BIC   logLik deviance df.resid  
102693.1 102738.3 -51340.5 102681.1   13994
```

Scaled residuals:


```
      Min       1Q   Median       3Q      Max  
-3.8092 -0.6436  0.0062  0.6596  3.3402
```

Random effects:

```
Groups   Name          Variance Std.Dev.  
pid      (Intercept)    9.373    3.062  
Residual                   83.865    9.158  
Number of obs: 14000, groups: pid, 1000
```

Fixed effects:

```
              Estimate Std. Error t value  
(Intercept)  52.44186    0.23946  218.998  
timebase     -0.01506    0.07770   -0.194  
timetreat    -0.87487    0.04711  -18.572  
timefollow    0.58362    0.10854   5.377
```



ค่าเฉลี่ยของความเครียดในวันที่ 1 (ก่อนบำบัด) = 52.44 คะแนน

ความเครียดช่วงเก็บฐาน ลดลงวันละ 0.02 คะแนน ซึ่งไม่ถึงระดับนัยสำคัญ

ความเครียดช่วงทดลอง ลดลงวันละ 0.87 คะแนน ซึ่งถึงระดับนัยสำคัญ

ความเครียดช่วงติดตาม เพิ่มขึ้นวันละ 0.58 คะแนน ซึ่งถึงระดับนัยสำคัญ

เปรียบเทียบระหว่างโมเดลการเปลี่ยนแปลงเชิงเส้น แบบแบ่งและไม่แบ่งช่วงเวลา

```
> anova(out1b, out1c)
Data: dat1
Models:
out1b: stress ~ 1 + timec + (1 | pid)
out1c: stress ~ 1 + timebase + timetreat + timefollow + (1 | pid)
      Df    AIC    BIC logLik deviance Chisq Chi Df Pr(>Chisq)
out1b  4 102801 102831 -51397   102793
out1c  6 102693 102738 -51341   102681 112.21    2 < 2.2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

ความแตกต่างถึงระดับนัยสำคัญ แสดงว่าการแบ่งช่วงเวลาเป็นสิ่งที่ควรทำ

การเปรียบเทียบ 2 โมเดลนี้ เหมือนการตรวจสอบว่า การจำกัดให้การเปลี่ยนแปลงทั้งสามช่วงเท่ากันนั้น เหมาะสมหรือไม่ ซึ่งผลออกมาว่าไม่เหมาะสม

$$Y_{ij} = \gamma_{00} + \gamma_{10}T_{1ij} + \gamma_{20}T_{2ij} + \gamma_{30}T_{3ij} + u_{0j} + e_{ij}$$


$$H_0: \gamma_{10} = \gamma_{20} = \gamma_{30}$$

```

> dat1 <- split(dat1, dat1$pid)
> stresspred <- lapply(dat1, function(x) { predict(lm(stress ~ timebase + timetreat + timefollow, data=x)) })
> dat1$stress2 <- do.call(c, stresspred)
> dat1_2 <- dat1[dat1$pid%%20 == 0,]
> dat1_2$treat <- factor(dat1_2$treat, labels=c("Control", "Treatment"))
> ggplot(data=dat1_2, aes(x=time, y=stress, group=pid, colour=treat)) + geom_line()

```

การเปลี่ยนแปลงของคะแนนดิบ
 คนไข้ทีละคน โดยแบ่งกลุ่ม
 บำบัดและกลุ่มควบคุม




```

> dat1 <- split(dat1, dat1$pid)
> stresspred <- lapply(dat1, function(x) { predict(lm(stress ~ timebase + timetreat + timefollow, data=x)) })
> dat1$stress2 <- do.call(c, stresspred)
> dat1_2 <- dat1[dat1$pid%%20 == 0,]
> dat1_2$treat <- factor(dat1_2$treat, labels=c("Control", "Treatment"))
> ggplot(data=dat1_2, aes(x=time, y=stress2, group=pid, colour=treat)) + geom_line()

```

การเปลี่ยนแปลงโดยดูจาก
ค่าความเครียดที่ทำนายได้ จาก
โมเดลการเปลี่ยนแปลงเชิงเส้น
ช่วงย่อย ของคนไข้ทีละคน
โดยแบ่งกลุ่มบำบัด
และกลุ่มควบคุม



ตรวจสอบว่าการเปลี่ยนแปลงในแต่ละช่วงนั้น แตกต่างกันระหว่างบุคคลหรือไม่

อันดับแรก ตรวจสอบว่าการเปลี่ยนแปลงเชิงเส้นช่วงเก็บฐาน แตกต่างกันระหว่างกลุ่มหรือไม่ พบว่าเมื่อกำหนดให้อิทธิพลของตัวแปรเป็นค่าสุ่มแล้ว ไม่สามารถประมาณค่าได้

```
> out1d <- lmer(stress ~ 1 + timebase + timetreat  
+               + timefollow + (1 + timebase|pid),  
+               data=dat1, REML=FALSE,  
+               control = lmerControl(optimizer = "Nelder_Mead"))  
boundary (singular) fit: see ?isSingular
```

เนื่องจากผลการเปลี่ยนแปลงเชิงเส้นช่วงเก็บฐาน ไม่ถึงระดับนัยสำคัญ และไม่ใช่สิ่งที่ผู้วิจัยสนใจตั้งแต่ต้น จึงนำตัวแปรนี้ออกจากโมเดลในอนาคต

ตรวจสอบว่าการเปลี่ยนแปลงในแต่ละช่วงนั้น แตกต่างกันระหว่างบุคคลหรือไม่

```
> out1e <- lmer(stress ~ 1 + timebase + timetreat
+               + timefollow + (1 + timetreat|pid),
+               data=dat1, REML=FALSE,
+               control = lmerControl(optimizer = "Nelder_Mead"))
> anova(out1c, out1e)
Data: dat1
Models:
out1c: stress ~ 1 + timebase + timetreat + timefollow + (1 | pid)
out1e: stress ~ 1 + timebase + timetreat + timefollow + (1 + timetreat |
out1e:      pid)
      Df    AIC    BIC logLik deviance  Chisq Chi Df Pr(>Chisq)
out1c  6 102693 102738 -51341   102681
out1e  8 101783 101843 -50884   101767 913.99    2 < 2.2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

การเปลี่ยนแปลงเชิงเส้นช่วงทดลอง แตกต่างกันระหว่างกลุ่มอย่างมีนัยสำคัญ

ตรวจสอบว่าการเปลี่ยนแปลงในแต่ละช่วงนั้น แตกต่างกันระหว่างบุคคลหรือไม่

```
> out1f <- lmer(stress ~ 1 + timebase + timetreat
+               + timefollow + (1 + timefollow|pid),
+               data=dat1, REML=FALSE,
+               control = lmerControl(optimizer = "Nelder_Mead"))
> anova(out1c, out1f)
Data: dat1
Models:
out1c: stress ~ 1 + timebase + timetreat + timefollow + (1 | pid)
out1f: stress ~ 1 + timebase + timetreat + timefollow + (1 + timefollow |
out1f:      pid)
      Df    AIC    BIC logLik deviance  Chisq Chi Df Pr(>Chisq)
out1c  6 102693 102738 -51341   102681
out1f  8 102450 102510 -51217   102434 247.44    2 < 2.2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

การเปลี่ยนแปลงเชิงเส้นช่วงติดตามผล แตกต่างกันระหว่างกลุ่มอย่างมีนัยสำคัญ

ด้วยเหตุนี้ จึงสร้างโมเดลใหม่ ให้ช่วงทดลองและช่วงติดตามผลมีอิทธิพลต่อ

```
> outlg <- lmer(stress ~ 1 + timetreat + timefollow
+ (1 + timetreat+ timefollow|pid),
+ data=dat1, REML=FALSE,
+ control = lmerControl(optimizer = "Nelder_Mead"))
```

```
> summary(outlg)
```

Linear mixed model fit by maximum likelihood ['lmerMod']
 Formula: stress ~ 1 + timetreat + timefollow + (1 + timetreat + t
 Data: dat1
 Control: lmerControl(optimizer = "Nelder_Mead")

AIC	BIC	logLik	deviance	df.resid
101766.7	101842.1	-50873.3	101746.7	13990

Scaled residuals:

Min	1Q	Median	3Q	Max
-4.0056	-0.6302	0.0125	0.6550	3.2871

Random effects:

Groups	Name	Variance	Std.Dev.	Corr
pid	(Intercept)	0.3362	0.5799	
	timetreat	1.3151	1.1468	0.20
	timefollow	1.8105	1.3455	-0.67 -0.31
Residual		74.5464	8.6340	

Number of obs: 14000, groups: pid, 1000

Fixed effects:

	Estimate	Std. Error	t value
(Intercept)	52.40588	0.11110	471.680
timetreat	-0.88024	0.05103	-17.248
timefollow	0.58704	0.10957	5.358

$$\sigma^2 = 74.54$$

$$\tau_{00} = 0.34$$

$$\rho_{01} = .20$$

$$\tau_{11} = 1.32$$

$$\rho_{02} = -.67$$

$$\tau_{22} = 1.81$$

$$\rho_{12} = -.31$$

$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + e_{ij}$$

$$\pi_{0j} = 52.41 + u_{0j}$$

$$\pi_{1j} = -0.88 + u_{1j}$$

$$\pi_{2j} = 0.59 + u_{2j}$$

$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + e_{ij} \quad \sigma^2 = 74.54$$

$$\pi_{0j} = 52.41 + u_{0j} \quad \tau_{00} = 0.34 \quad \rho_{01} = .20$$

$$\pi_{1j} = -0.88 + u_{1j} \quad \tau_{11} = 1.32 \quad \rho_{02} = -.67$$

$$\pi_{2j} = 0.59 + u_{2j} \quad \tau_{22} = 1.81 \quad \rho_{12} = -.31$$

ความเครียดช่วงก่อนบำบัด (เฉลี่ยข้อมูลการวัดครั้งที่ 1-5) เฉลี่ยคนไข้ทุกคนเท่ากับ 52.41 คะแนน มีช่วงเชื่อมั่น 95% เท่ากับ $52.41 \pm 1.96 \times \sqrt{0.34} = (51.27, 53.54)$ คะแนน

ในช่วงบำบัด คนไข้ทุกคนมีค่าเฉลี่ยความเครียดน้อยลง วันละ 0.88 คะแนน มีช่วงเชื่อมั่น 95% เท่ากับ $-0.88 \pm 1.96 \times \sqrt{1.32} = (-3.13, 1.37)$ คะแนนต่อวัน

ในช่วงติดตามผล คนไข้ทุกคนมีค่าเฉลี่ยความเครียดมากขึ้น วันละ 0.59 คะแนน มีช่วงเชื่อมั่น 95% เท่ากับ $0.59 \pm 1.96 \times \sqrt{1.81} = (-2.96, 4.14)$ คะแนนต่อวัน

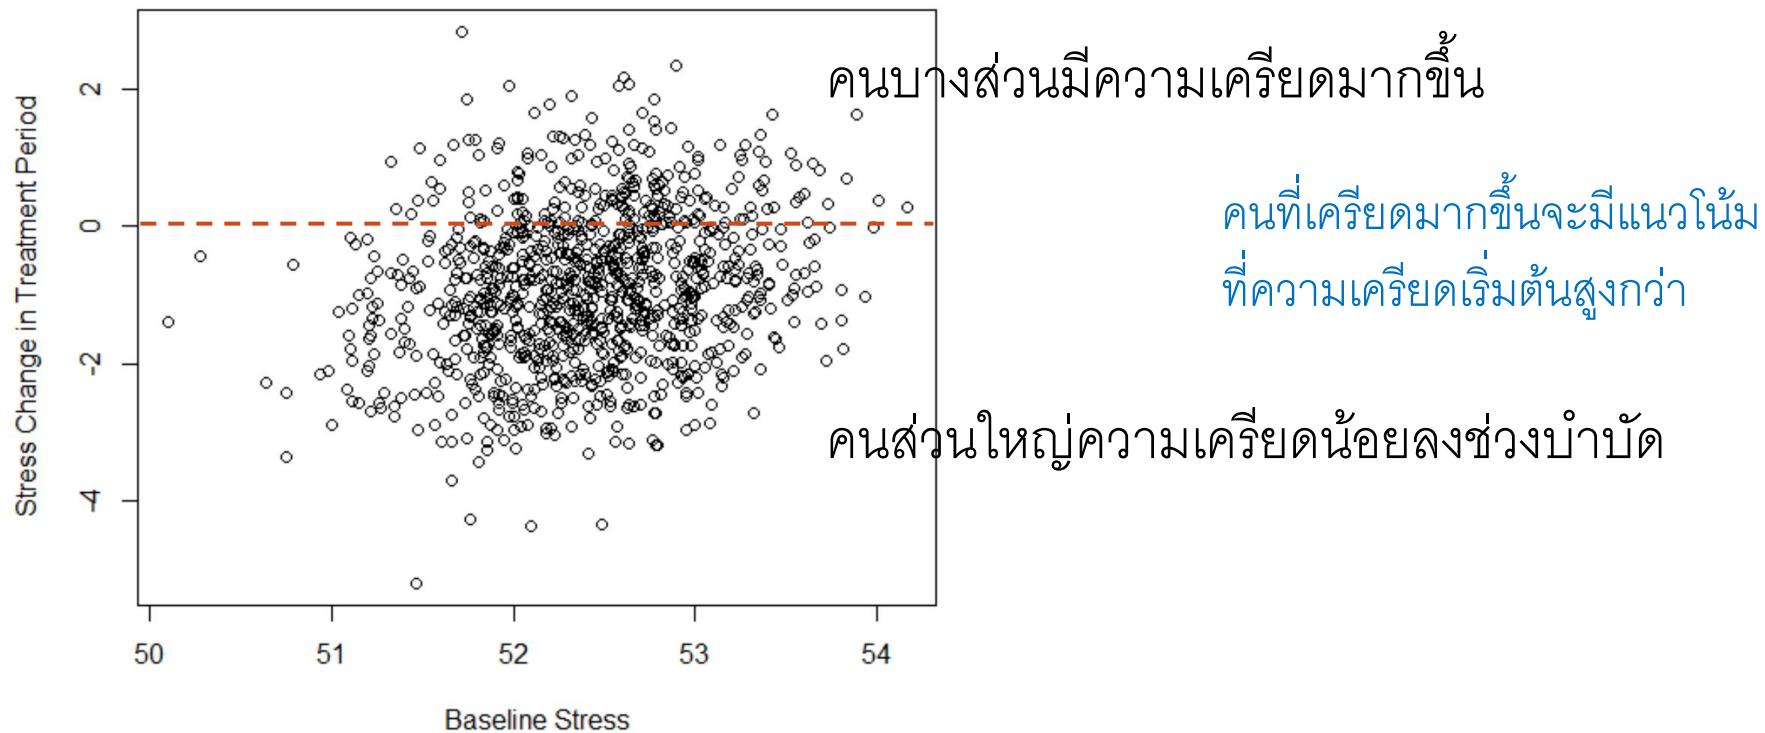
$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + e_{ij} \quad \sigma^2 = 74.54$$

$$\pi_{0j} = 52.41 + u_{0j} \quad \tau_{00} = 0.34 \quad \rho_{01} = .20$$

$$\pi_{1j} = -0.88 + u_{1j} \quad \tau_{11} = 1.32 \quad \rho_{02} = -.67$$

$$\pi_{2j} = 0.59 + u_{2j} \quad \tau_{22} = 1.81 \quad \rho_{12} = -.31$$

หากความเครียดช่วงก่อนบำบัดมีค่ามาก จะมีแนวโน้มที่ความลดลงของความเครียดมีค่าเบาลงในช่วงการบำบัด โดยมีค่าสหสัมพันธ์เท่ากับ .2



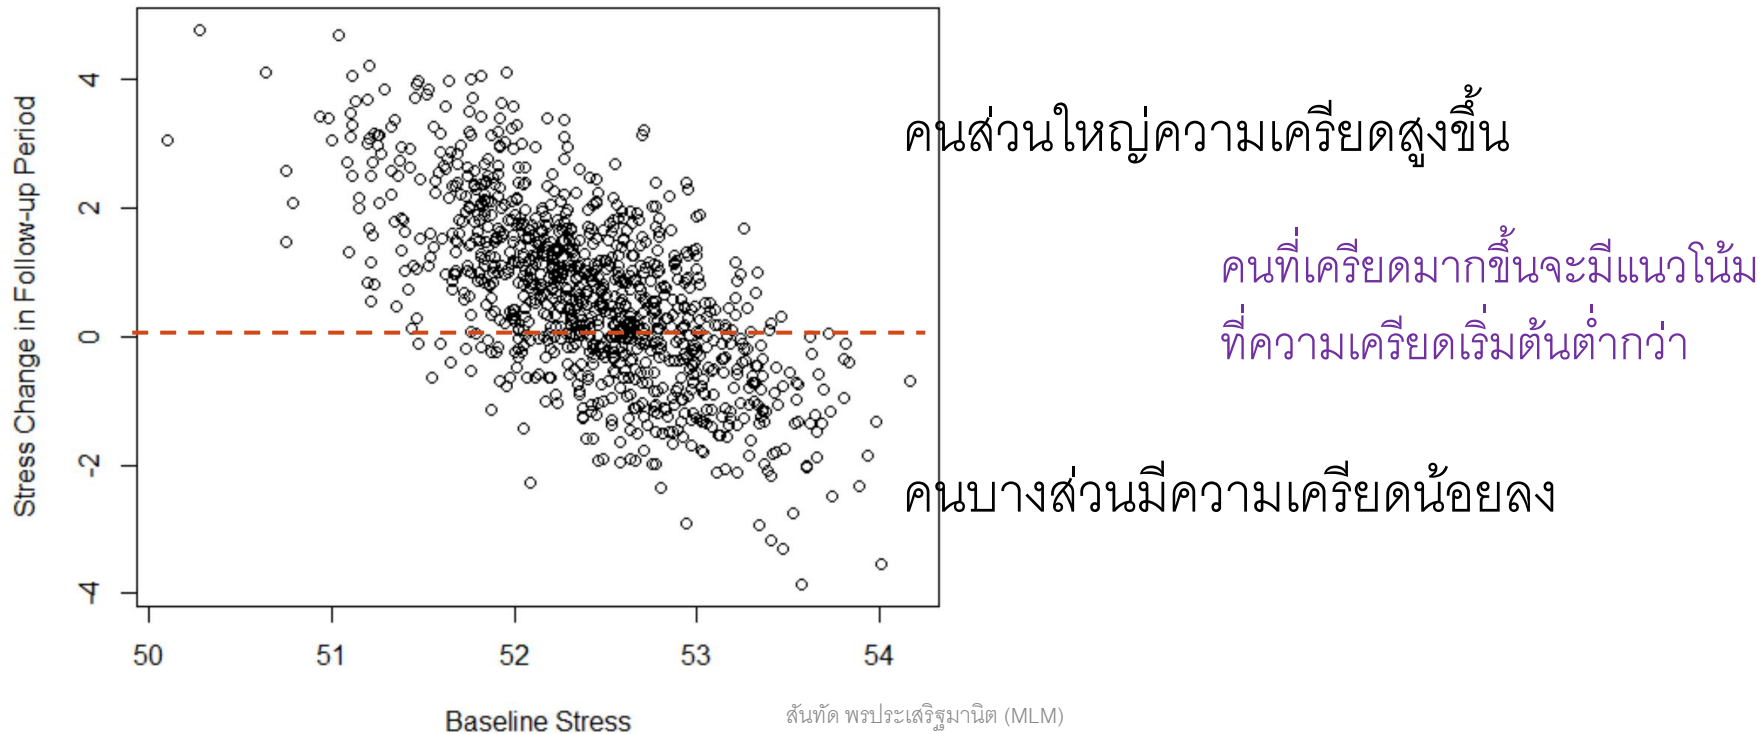
$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + e_{ij} \quad \sigma^2 = 74.54$$

$$\pi_{0j} = 52.41 + u_{0j} \quad \tau_{00} = 0.34 \quad \rho_{01} = .20$$

$$\pi_{1j} = -0.88 + u_{1j} \quad \tau_{11} = 1.32 \quad \rho_{02} = -.67$$

$$\pi_{2j} = 0.59 + u_{2j} \quad \tau_{22} = 1.81 \quad \rho_{12} = -.31$$

หากความเครียดช่วงก่อนบำบัดมีค่ามาก จะมีแนวโน้มที่ช่วงติดตามจะมีความเครียดลดลง แต่หากความเครียดก่อนบำบัดมีค่าน้อย จะมีแนวโน้มความเครียดช่วงติดตามจะมีความเครียดเพิ่มขึ้น
ค่าสหสัมพันธ์เท่ากับ -.67



$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + e_{ij} \quad \sigma^2 = 74.54$$

$$\pi_{0j} = 52.41 + u_{0j}$$

$$\pi_{1j} = -0.88 + u_{1j}$$

$$\pi_{2j} = 0.59 + u_{2j}$$

$$\tau_{00} = 0.34$$

$$\rho_{01} = .20$$

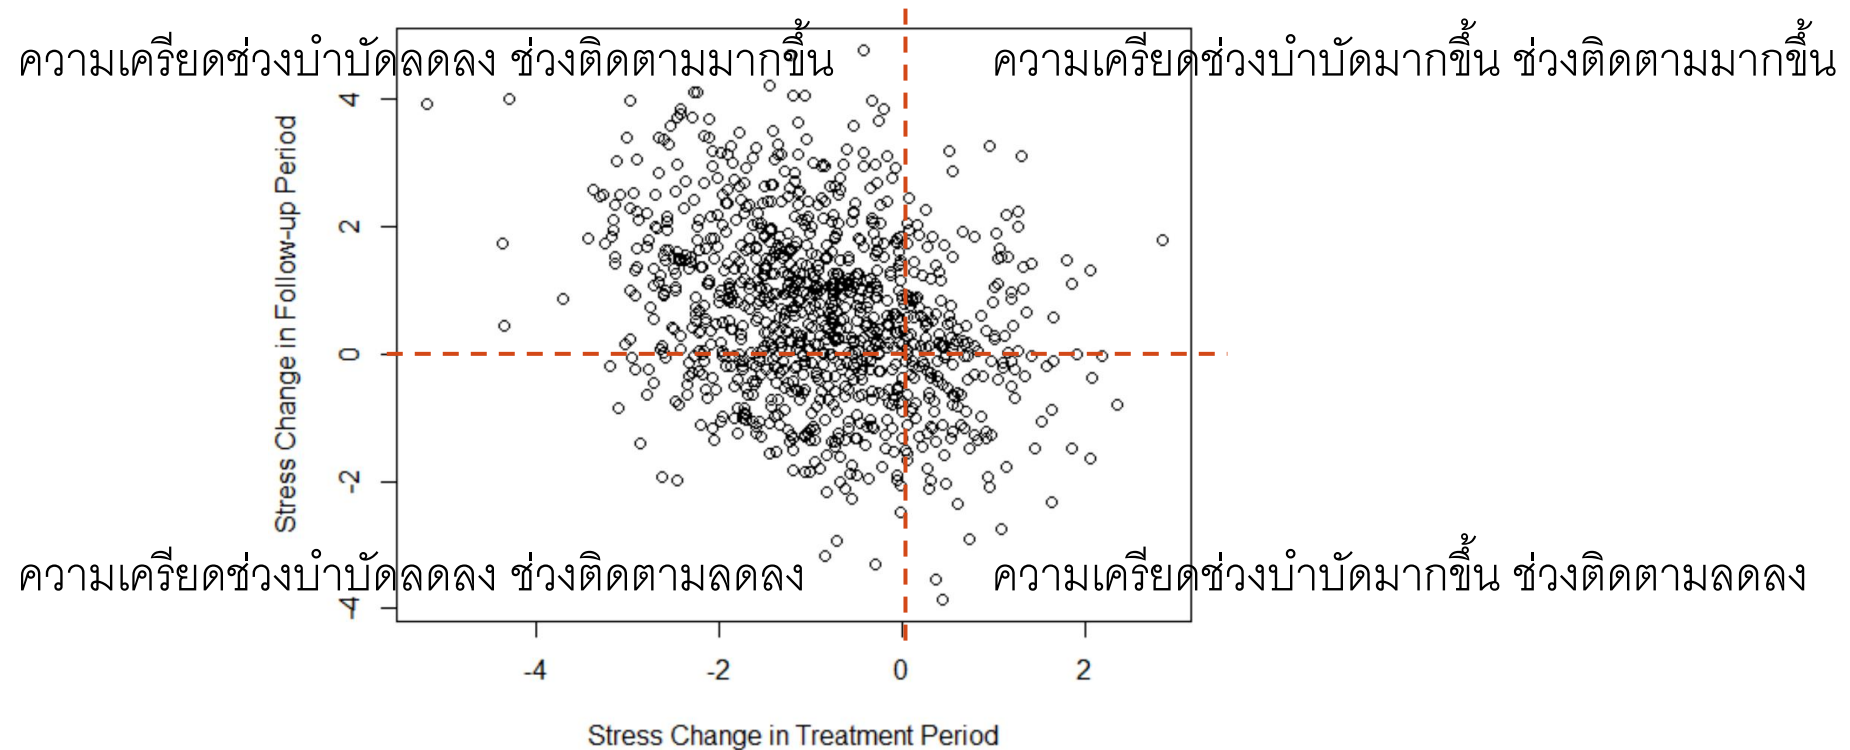
$$\tau_{11} = 1.32$$

$$\rho_{02} = -.67$$

$$\tau_{22} = 1.81$$

$$\rho_{12} = -.31$$

หากความเครียดช่วงบำบัดลดลง จะมีแนวโน้มที่ความเครียดช่วงติดตามผลมากขึ้น ค่าสหสัมพันธ์ อยู่ที่ -.31



แปลงช่วงนอนการนอนออกเป็น 2 ระดับ คือ ระดับวันและระดับบุคคล

```
> dat1$sleephrs <- dat1$sleep / 60    เปลี่ยนหน่วยจากนาที่เป็นชั่วโมง  
> dat1$avesleep <- ave(dat1$sleephrs, dat1$pid)  
> dat1$diffsleep <- dat1$sleephrs - dat1$avesleep
```

หาค่าเฉลี่ยของตัวแปรระดับบุคคล เพื่อนำไปย้ายศูนย์กลาง

```
> dat1a <- dat1[!duplicated(dat1$pid),]  
> round(apply(dat1a, 2, mean), 3)
```

rowid	pid	time	stress	treat	sleep
6994.000	500.500	1.000	52.543	0.500	424.507
age	timec	timebase	timetreat	timefollow	sleephrs
36.638	0.000	0.000	0.000	0.000	7.075
avesleep	diffsleep				
7.060	0.015				

หากย้ายศูนย์กลางของตัวแปรตัวนี้มีเท่ากับค่าเฉลี่ยแล้ว
จะเรียกตัวแปรตัวนี้มีว่าการใส่รหัสแบบอิทธิพล (Effect Coding)

```

> outlh <- lmer(stress ~ 1 + timetreat + timefollow + diffsleep
+             + I(avesleep - 7.075) + I(treat - 0.5) + I(age - 36.638)
+             + (1 + timetreat+ timefollow|pid), data=dat1, REML=FALSE,
+             control = lmerControl(optimizer = "Nelder_Mead"))
> summary(outlh)

```

Linear mixed model fit by maximum likelihood ['lmerMod']
 Formula: stress ~ 1 + timetreat + timefollow + diffsleep + I(avesleep - 7.075) + I(treat - 0.5) + I(age - 36.638) + (1 + timetreat + timefollow | pid)
 Data: dat1
 Control: lmerControl(optimizer = "Nelder_Mead")

AIC	BIC	logLik	deviance	df.resid
101443.5	101549.2	-50707.7	101415.5	13986

Scaled residuals:

Min	1Q	Median	3Q	Max
-4.0920	-0.6324	0.0072	0.6530	3.2911

Random effects:

Groups	Name	Variance	Std.Dev.	Corr
pid	(Intercept)	2.446	1.564	
	timetreat	1.306	1.143	-0.65
	timefollow	1.713	1.309	0.16 -0.30
Residual		73.511	8.574	

Number of obs: 14000, groups: pid, 1000

Fixed effects:

	Estimate	Std. Error	t value
(Intercept)	52.41799	0.11955	438.465
timetreat	-0.88473	0.05077	-17.427
timefollow	0.59457	0.10847	5.481
diffsleep	-1.91626	0.14072	-13.617
I(avesleep - 7.075)	0.18586	0.12980	1.432
I(treat - 0.5)	-2.82121	0.18266	-15.445
I(age - 36.638)	0.01326	0.01724	0.769

$$\sigma^2 = 73.51$$

$$\tau_{00} = 2.45$$

$$\tau_{11} = 1.31$$

$$\tau_{22} = 1.71$$

$$\rho_{01} = -.65$$

$$\rho_{02} = .16$$

$$\rho_{12} = -.30$$

$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + \pi_{3j}X_{ij} + e_{ij}$$

$$\pi_{0j} = 52.42 - 2.82(W_{1j} - 0.5) + 0.013(W_{2j} - 36.638) + 0.186(\bar{X}_{2ij} - 7.075) + u_{0j}$$

$$\pi_{1j} = -0.88 + u_{1j}$$

$$\pi_{2j} = 0.59 + u_{2j}$$

$$\pi_{3j} = -1.92$$

$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + \pi_{3j}X_{ij} + e_{ij}$$

$$\pi_{0j} = 52.42 - 2.82(W_{1j} - 0.5) + 0.013(W_{2j} - 36.638) + 0.186(\bar{X}_{2ij} - 7.075) + u_{0j}$$

$$\pi_{1j} = -0.88 + u_{1j} \quad \pi_{2j} = 0.59 + u_{2j} \quad \pi_{3j} = -1.92$$

ความเครียดช่วงก่อนบำบัด (เฉลี่ยข้อมูลการวัดครั้งที่ 1-5) เฉลี่ยคนไข้ทุกคนเท่ากับ 52.42 คะแนน เมื่อตัวแปรการเข้าบำบัด อายุของผู้เข้าร่วม และจำนวนชั่วโมงการนอน เท่ากับค่าเฉลี่ย

ในช่วงบำบัด คนไข้ทุกคนมีค่าเฉลี่ยความเครียดน้อยลง วันละ 0.88 คะแนน

ในช่วงติดตามผล คนไข้ทุกคนมีค่าเฉลี่ยความเครียดมากขึ้น วันละ 0.59 คะแนน

ภายในคนไข้คนเดียวกัน หากคนดังกล่าวมีชั่วโมงการนอนน้อยลง 1 ชั่วโมง จะมีความเครียดน้อยลง 1.92 แต้ม

$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + \pi_{3j}X_{ij} + e_{ij}$$

$$\pi_{0j} = 52.42 - 2.82(W_{1j} - 0.5) + 0.013(W_{2j} - 36.638) + 0.186(\bar{X}_{2ij} - 7.075) + u_{0j}$$

$$\pi_{1j} = -0.88 + u_{1j} \quad \pi_{2j} = 0.59 + u_{2j} \quad \pi_{3j} = -1.92$$

เปรียบเทียบระหว่างกลุ่มบำบัดและกลุ่มควบคุม กลุ่มบำบัดมีความเครียดช่วงเก็บฐานน้อยกว่ากลุ่มควบคุม 2.82 คะแนน เมื่อควบคุมตัวแปรอายุ และชั่วโมงการนอนเฉลี่ยให้คงที่

หากอายุมากขึ้น 1 ปี ความเครียดช่วงเก็บฐานเพิ่มขึ้น 0.013 คะแนน เมื่อควบคุมเงื่อนไขกลุ่มทดลอง และชั่วโมงการนอนให้คงที่ แต่ผลนี้ไม่ถึงระดับนัยสำคัญ

เปรียบเทียบระหว่างคนไข้สองคน ที่มีชั่วโมงการนอนเฉลี่ยแตกต่างกัน 1 ชั่วโมง คนที่ชั่วโมงการนอนสูงกว่า จะมีความเครียดมากกว่า 0.186 คะแนน เมื่อควบคุมเงื่อนไขกลุ่มทดลอง และอายุให้คงที่ แต่ผลนี้ไม่ถึงระดับนัยสำคัญ

อีกคำสั่งหนึ่งที่ช่วยให้การวิเคราะห์ด้วย lmer หาคำตอบ คือ

```
control = lmerControl(calc.derivs = FALSE)
```

← → ↻ 🏠 cran.r-project.org/web/packages/lme4/vignettes/lmerperf.html 🔍 ☆ 🗑️ (๓) 🌐 🌐

```
library("lme4")
```

lme4 Performance Tips

- use `control = [g]lmerControl(calc.derivs = FALSE)` to turn off the time consuming derivative calculation that is performed after the optimization is finished, e.g.

```
lmer(y ~ service * dept + (1|s) + (1|d), InstEval,  
      control = lmerControl(calc.derivs = FALSE))
```

Note that this will disable some of the convergence tests, as well as (for glmer only) making lme4 use a less accurate approximation to compute the standard errors of the fixed effects.

ในกรณีในคาบเรียนนี้ ที่ใช้เฉพาะตัวแปรตามแบบต่อเนื่อง การคำนวณ SE ยังไม่มีผล

```

> out1i <- lmer(stress ~ 1 + timetreat + timefollow + diffsleep
+               + timetreat*I(avesleep - 7.075) + timetreat*I(treat - 0.5)
+               + timetreat*I(age - 36.638) + timefollow*I(avesleep - 7.075)
+               + timefollow*I(treat - 0.5) + timefollow*I(age - 36.638)
+               + (1 + timetreat+ timefollow|pid), data=dat1, REML=FALSE,
+               control = lmerControl(optimizer = "Nelder_Mead", calc.derivs = FALSE))
> summary(out1i)
Linear mixed model fit by maximum likelihood ['lmerMod']
Formula: stress ~ 1 + timetreat + timefollow + diffsleep + timetreat *
  I(avesleep - 7.075) + timetreat * I(treat - 0.5) + timetreat *
  I(age - 36.638) + timefollow * I(avesleep - 7.075) + timefollow *
  I(treat - 0.5) + timefollow * I(age - 36.638) + (1 + timetreat +
  timefollow | pid)
Data: dat1
Control: lmerControl(optimizer = "Nelder_Mead", calc.derivs = FALSE)

```

AIC	BIC	logLik	deviance	df.resid
101023.0	101173.9	-50491.5	100983.0	13980

$$\sigma^2 = 73.52$$

Scaled residuals:

Min	1Q	Median	3Q	Max
-4.0674	-0.6351	0.0053	0.6621	3.3091

$$\tau_{00} = 0.36$$

$$\rho_{01} = .46$$

$$\tau_{11} = 0.43$$

$$\rho_{02} = -.79$$

Random effects:

Groups	Name	Variance	Std.Dev.	Corr
pid	(Intercept)	<u>0.3553</u>	0.5960	
	timetreat	<u>0.4344</u>	0.6591	<u>0.46</u>
	timefollow	<u>1.3450</u>	1.1598	<u>-0.79</u> <u>0.14</u>
Residual		<u>73.5184</u>	8.5743	

Number of obs: 14000, groups: pid, 1000

$$\tau_{22} = 1.35$$

$$\rho_{12} = .14$$

Fixed effects:

	Estimate	Std. Error	t value
(Intercept)	52.418891	0.110471	474.503
timetreat	-0.885219	0.041316	-21.426
timefollow	0.593959	0.106793	5.562
diffsleep	-1.892950	0.139462	-13.573
I(avesleep - 7.075)	0.251976	0.156970	1.605
I(treat - 0.5)	0.059906	0.220894	0.271
I(age - 36.638)	0.013452	0.020844	0.645
timetreat:I(avesleep - 7.075)	-0.035437	0.058707	-0.604
timetreat:I(treat - 0.5)	-1.864007	0.082616	-22.562
timetreat:I(age - 36.638)	0.002091	0.007796	0.268
timefollow:I(avesleep - 7.075)	-0.033808	0.151753	-0.223
timefollow:I(treat - 0.5)	1.188626	0.213551	5.566
timefollow:I(age - 36.638)	-0.018400	0.020154	-0.913

$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + \pi_{3j}X_{ij} + e_{ij}$$

$$\pi_{0j} = 52.42 + 0.060(W_{1j} - 0.5) + 0.013(W_{2j} - 36.638) + 0.252(\bar{X}_{2ij} - 7.075) + u_{0j}$$

$$\pi_{1j} = -0.88 - 1.864(W_{1j} - 0.5) + 0.002(W_{2j} - 36.638) - 0.035(\bar{X}_{2ij} - 7.075) + u_{1j}$$

$$\pi_{2j} = 0.59 + 1.189(W_{1j} - 0.5) - 0.018(W_{2j} - 36.638) - 0.034(\bar{X}_{2ij} - 7.075) + u_{2j}$$

$$\pi_{3j} = -1.89$$

$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + \pi_{3j}X_{ij} + e_{ij}$$

$$\pi_{0j} = 52.42 + 0.060(W_{1j} - 0.5) + 0.013(W_{2j} - 36.638) + 0.252(\bar{X}_{2ij} - 7.075) + u_{0j}$$

$$\pi_{1j} = -0.88 - 1.864(W_{1j} - 0.5) + 0.002(W_{2j} - 36.638) - 0.035(\bar{X}_{2ij} - 7.075) + u_{1j}$$

$$\pi_{2j} = 0.59 + 1.189(W_{1j} - 0.5) - 0.018(W_{2j} - 36.638) - 0.034(\bar{X}_{2ij} - 7.075) + u_{2j}$$

$$\pi_{3j} = -1.89$$

ความเครียดช่วงก่อนบำบัด (เฉลี่ยข้อมูลการวัดครั้งที่ 1-5) เฉลี่ยคนไข้ทุกคนเท่ากับ 52.42 คะแนน เมื่อตัวแปรการเข้าบำบัด อายุของผู้เข้าร่วม และจำนวนชั่วโมงการนอน เท่ากับค่าเฉลี่ย

เปรียบเทียบระหว่างกลุ่มบำบัดและกลุ่มควบคุม กลุ่มบำบัดมีความเครียดช่วงเก็บฐานน้อยกว่ากลุ่มควบคุม 0.06 คะแนน เมื่อตัวแปรอายุ และชั่วโมงการนอนเฉลี่ยเท่ากับค่าเฉลี่ยรวมแต่ผลไม่ถึงระดับนัยสำคัญ

หากอายุมากขึ้น 1 ปี ความเครียดช่วงเก็บฐานเพิ่มขึ้น 0.013 คะแนน เมื่อค่าเงื่อนไขกลุ่มทดลอง และชั่วโมงการนอนให้เท่ากับค่าเฉลี่ย แต่ผลนี้ไม่ถึงระดับนัยสำคัญ

เปรียบเทียบระหว่างคนไข้สองคน ที่มีชั่วโมงการนอนเฉลี่ยแตกต่างกัน 1 ชั่วโมง คนที่ชั่วโมงการนอนสูงกว่า จะมีความเครียดมากกว่า 0.252 คะแนน เมื่อค่าเงื่อนไขกลุ่มทดลอง และอายุเท่ากับค่าเฉลี่ย แต่ผลนี้ไม่ถึงระดับนัยสำคัญ

ภายในคนไข้ที่เงื่อนไขกลุ่มทดลอง อายุ และจำนวนการนอนเฉลี่ยเท่ากับค่าเฉลี่ย หากคนดังกล่าวมีชั่วโมงการนอนน้อยลง 1 ชั่วโมง จะมีความเครียดน้อยลง 1.89 แต้ม

$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + \pi_{3j}X_{ij} + e_{ij}$$

$$\pi_{0j} = 52.42 + 0.060(W_{1j} - 0.5) + 0.013(W_{2j} - 36.638) + 0.252(\bar{X}_{2ij} - 7.075) + u_{0j}$$

$$\pi_{1j} = -0.88 - 1.864(W_{1j} - 0.5) + 0.002(W_{2j} - 36.638) - 0.035(\bar{X}_{2ij} - 7.075) + u_{1j}$$

$$\pi_{2j} = 0.59 + 1.189(W_{1j} - 0.5) - 0.018(W_{2j} - 36.638) - 0.034(\bar{X}_{2ij} - 7.075) + u_{2j}$$

$$\pi_{3j} = -1.89$$

ในช่วงบำบัด คนไข้ทุกคนมีค่าเฉลี่ยความเครียดน้อยลง วันละ 0.88 คะแนน เมื่อตัวแปรการเข้าบำบัด อายุของผู้เข้าร่วม และจำนวนชั่วโมงการนอน เท่ากับค่าเฉลี่ย

เปรียบเทียบระหว่างกลุ่มบำบัดและกลุ่มควบคุม กลุ่มบำบัดมีความเครียดลดลงในช่วงบำบัด ในอัตราที่เร็วกว่ากลุ่มควบคุมอยู่ 1.86 คะแนนต่อวัน เมื่อควบคุมตัวแปรอายุ และชั่วโมงการนอนเฉลี่ยให้คงที่

หากอายุมากขึ้น 1 ปี อัตราการลดลงของความเครียดในช่วงบำบัด มีอัตราที่น้อยลง 0.002 คะแนนต่อวัน เมื่อควบคุมเงื่อนไขกลุ่มทดลอง และชั่วโมงการนอนให้คงที่ แต่ผลนี้ไม่ถึงระดับนัยสำคัญ

เปรียบเทียบระหว่างคนไข้สองคน ที่มีชั่วโมงการนอนเฉลี่ยแตกต่างกัน 1 ชั่วโมง คนที่ชั่วโมงการนอนสูงกว่า จะมีอัตราการลดลงของความเครียดที่เร็วขึ้นในช่วงบำบัด 0.035 คะแนนต่อวัน เมื่อควบคุมเงื่อนไขกลุ่มทดลอง และอายุให้คงที่ แต่ผลนี้ไม่ถึงระดับนัยสำคัญ

$$Y_{ij} = \pi_{0j} + \pi_{1j}T_{Tij} + \pi_{2j}T_{Fij} + \pi_{3j}X_{ij} + e_{ij}$$

$$\pi_{0j} = 52.42 + 0.060(W_{1j} - 0.5) + 0.013(W_{2j} - 36.638) + 0.252(\bar{X}_{2ij} - 7.075) + u_{0j}$$

$$\pi_{1j} = -0.88 - 1.864(W_{1j} - 0.5) + 0.002(W_{2j} - 36.638) - 0.035(\bar{X}_{2ij} - 7.075) + u_{1j}$$

$$\pi_{2j} = 0.59 + 1.189(W_{1j} - 0.5) - 0.018(W_{2j} - 36.638) - 0.034(\bar{X}_{2ij} - 7.075) + u_{2j}$$

$$\pi_{3j} = -1.89$$

ในช่วงติดตามผล คนไข้ทุกคนมีค่าเฉลี่ยความเครียดมากขึ้น วันละ 0.59 คะแนน

เมื่อตัวแปรการเข้าบำบัด อายุของผู้เข้าร่วม และจำนวนชั่วโมงการนอน เท่ากับค่าเฉลี่ย

เปรียบเทียบระหว่างกลุ่มบำบัดและกลุ่มควบคุม กลุ่มบำบัดมีความเครียดเพิ่มขึ้นในช่วงติดตามผล ในอัตราที่มากกว่ากลุ่มควบคุมอยู่ 1.19 คะแนนต่อวัน เมื่อควบคุมตัวแปรอายุ และชั่วโมงการนอนเฉลี่ยให้คงที่

หากอายุมากขึ้น 1 ปี อัตราการเพิ่มขึ้นของความเครียดในช่วงติดตาม มีอัตราที่น้อยลง 0.018 คะแนนต่อวัน เมื่อควบคุมเงื่อนไขกลุ่มทดลอง และชั่วโมงการนอนให้คงที่ แต่ผลนี้ไม่ถึงระดับนัยสำคัญ

เปรียบเทียบระหว่างคนไข้สองคน ที่มีชั่วโมงการนอนเฉลี่ยแตกต่างกัน 1 ชั่วโมง คนที่ชั่วโมง


การนอนสูงกว่า จะมีอัตราการเพิ่มขึ้นของความเครียดในช่วงติดตามช้าลง 0.034 คะแนนต่อวัน เมื่อควบคุมเงื่อนไขกลุ่มทดลอง และอายุให้คงที่ แต่ผลนี้ไม่ถึงระดับนัยสำคัญ

แทนตัวแปรอื่นนอกจากเงื่อนไขการบำบัดให้เท่ากับค่าเฉลี่ย เพื่อดูการเปลี่ยนแปลงของความเครียด ในแต่ละเงื่อนไขการบำบัด

$$Y_{ij} = 52.42 + 0.060(W_{1j} - 0.5) - 0.88T_{Tij} - 1.864(W_{1j} - 0.5)T_{Tij} + 0.59T_{Fij} + 1.189(W_{1j} - 0.5)T_{Fij}$$

$$\text{ให้ } W_1 = 1 \quad Y_{ij} = 52.499 - 1.812T_{Tij} + 1.185T_{Fij}$$

$$\text{ให้ } W_1 = 0 \quad Y_{ij} = 52.389 + 0.052T_{Tij} - 0.005T_{Fij}$$



```
> treatcval <- c(0, 1) - 0.5
> library(interactions)
> ss11 <- sim_slopes(model=outlin, pred=timetreat, modx=treatc, modx.values=treatcval)
```

```
> ss11
```

JOHNSON-NEYMAN INTERVAL

When treatc is **OUTSIDE** the interval [-0.54, -0.42], the slope of timetreat is $p < .05$.

Note: The range of observed values of treatc is [-0.50, 0.50]

SIMPLE SLOPES ANALYSIS

Slope of timetreat when treatc = -0.50:

Est.	S.E.	t val.	p
0.05	0.06	0.81	0.42

Slope of timetreat when treatc = 0.50:

Est.	S.E.	t val.	p
-1.82	0.06	-31.06	0.00

```
> ss12 <- sim_slopes(model=outlin, pred=timefollow, modx=treatc, modx.values=treatcval)
```

```
> ss12
```

JOHNSON-NEYMAN INTERVAL

When treatc is **OUTSIDE** the interval [-0.85, -0.30], the slope of timefollow is $p < .05$.

Note: The range of observed values of treatc is [-0.50, 0.50]

SIMPLE SLOPES ANALYSIS

Slope of timefollow when treatc = -0.50:

Est.	S.E.	t val.	p
0.00	0.15	0.00	1.00

Slope of timefollow when treatc = 0.50:

Est.	S.E.	t val.	p
1.19	0.15	7.85	0.00

```

> timetreatval <- c(0, 1, 2, 3, 4, 5, 6)
> timefollowval <- c(0, 1, 2, 3)
> ss13 <- sim_slopes(model=outlin, pred=treatc, modx=timetreat, mod2=timefollow,
modx.values=timetreatval, mod2.values=timefollowval)

```

```
> ss13
```

```

■■■■■■■■■■■■■■■■■■■■ while timefollow (2nd moderator) = 3.00 ■■■■■■■■■■■■■■■■■■■■

```

JOHNSON-NEYMAN INTERVAL

When timetreat is **OUTSIDE** the interval [1.27, 2.57], the slope of treatc is $p < .05$.

Note: The range of observed values of timetreat is [0.00, 6.00]

SIMPLE SLOPES ANALYSIS

Slope of treatc when timetreat = 6.00:

Est.	S.E.	t val.	p
-7.56	0.57	-13.32	0.00

while timefollow (2nd moderator) = 2.00

JOHNSON-NEYMAN INTERVAL

When timetreat is **OUTSIDE** the interval [0.82, 1.75], the slope of treatc is $p < .05$.

Note: The range of observed values of timetreat is [0.00, 6.00]

SIMPLE SLOPES ANALYSIS

Slope of treatc when timetreat = 6.00:

Est.	S.E.	t val.	p
-8.75	0.42	-20.60	0.00

while timefollow (2nd moderator) = 1.00

JOHNSON-NEYMAN INTERVAL

When timetreat is **OUTSIDE** the interval [0.35, 0.96], the slope of treatc is $p < .05$.

Note: The range of observed values of timetreat is [0.00, 6.00]

SIMPLE SLOPES ANALYSIS

Slope of treatc when timetreat = 6.00:

Est.	S.E.	t val.	p
-9.94	0.37	-27.11	0.00

while timefollow (2nd moderator) = 0.00

JOHNSON-NEYMAN INTERVAL

When timetreat is **OUTSIDE** the interval [-0.21, 0.25], the slope of treatc is $p < .05$.

Note: The range of observed values of timetreat is [0.00, 6.00]

SIMPLE SLOPES ANALYSIS

Slope of treatc when timetreat = 6.00:

Est.	S.E.	t val.	p
-11.12	0.42	-26.37	0.00

Slope of treatc when timetreat = 5.00:

Est.	S.E.	t val.	p
-9.26	0.35	-26.49	0.00

Slope of treatc when timetreat = 4.00:

Est.	S.E.	t val.	p
-7.40	0.28	-26.13	0.00

Slope of treatc when timetreat = 3.00:

Est.	S.E.	t val.	p
-5.53	0.23	-24.31	0.00

Slope of treatc when timetreat = 2.00:

Est.	S.E.	t val.	p
-3.67	0.16	-22.45	0.00

Slope of treatc when timetreat = 1.00:

Est.	S.E.	t val.	p
-1.80	0.19	-9.49	0.00

Slope of treatc when timetreat = 0.00:

Est.	S.E.	t val.	p
0.06	0.22	0.27	0.78

จากสมการ

$$Y_{ij} = 52.42 + 0.060(W_{1j} - 0.5) - 0.88T_{Tij} - 1.864(W_{1j} - 0.5)T_{Tij} + 0.59T_{Fij} + 1.189(W_{1j} - 0.5)T_{Fij}$$

สามารถตรวจสอบปฏิสัมพันธ์ได้ 2 แบบ คือ

1. ตรวจสอบว่าความชันของ T_T และ T_F ว่าแตกต่างจาก 0 อย่างมีนัยสำคัญหรือไม่ ในกลุ่มบำบัด ($W_1 = 1$) และกลุ่มควบคุม ($W_1 = 0$)

$$Y_{ij} = 52.42 + 0.060(W_{1j} - 0.5) + \left(-0.88T_{Tij} - 1.864(W_{1j} - 0.5) \right) T_{Tij} + \left(0.59T_{Fij} + 1.189(W_{1j} - 0.5) \right) T_{Fij}$$

W_1	$W_1 - 0.5$	จุดตัดอย่างง่าย	ความชันอย่างง่ายของ T_T	ความชันอย่างง่ายของ T_F
1	0.5	$52.52 + (0.060 \times (1 - 0.5)) = 52.50$	$-0.88 + (-1.86 \times (1 - 0.5)) = -1.81$	$0.59 + (1.19 \times (1 - 0.5)) = 1.19$
0	-0.5	$52.52 + (0.060 \times (0 - 0.5)) = 52.39$	$-0.88 + (-1.86 \times (0 - 0.5)) = 0.05$	$0.59 + (1.19 \times (0 - 0.5)) = -0.01$

W_1	$W_1 - 0.5$	จุดตัดอย่างง่าย	ความชันอย่างง่ายของ T_T	ความชันอย่างง่ายของ T_F
1	0.5	$52.52 + (0.060 \times (1 - 0.5)) = 52.50$	$-0.88 + (-1.86 \times (1 - 0.5)) = -1.81$	$0.59 + (1.19 \times (1 - 0.5)) = 1.19$
0	-0.5	$52.52 + (0.060 \times (0 - 0.5)) = 52.39$	$-0.88 + (-1.86 \times (0 - 0.5)) = 0.05$	$0.59 + (1.19 \times (0 - 0.5)) = -0.01$

```
> sumout1i <- summary(out1i)
> coef(sumout1i)
```

```
(Intercept) 52.418891213
timetreat -0.885219293
timefollow 0.593958519
diffsleep -1.892949777
I(avesleep - 7.075) 0.251976002
I(treat - 0.5) 0.059905775
I(age - 36.638) 0.013452280
timetreat:I(avesleep - 7.075) -0.035437335
timetreat:I(treat - 0.5) -1.864006760
timetreat:I(age - 36.638) 0.002091415
timefollow:I(avesleep - 7.075) -0.033807955
timefollow:I(treat - 0.5) 1.188625511
timefollow:I(age - 36.638) -0.018400424
```

	Intercept	Slope T	Slope F
1	1	0	0
0	0	1	0
0	0	0	1
0	0	0	0
0	0	0	0
-0.5, 0.5	0	0	0
0	0	0	0
0	0	-0.5, 0.5	0
0	0	0	0
0	0	0	0
0	0	0	-0.5, 0.5
0	0	0	0

```

> psi <- coef(sumout1i)[,1]
> vpsi <- vcov(sumout1i)
> cvec1 <- c(1, 0, 0, 0, 0, 0.5, 0, 0, 0, 0, 0, 0, 0)
> cvec2 <- c(1, 0, 0, 0, 0, -0.5, 0, 0, 0, 0, 0, 0, 0)
> cvec3 <- c(0, 1, 0, 0, 0, 0, 0, 0, 0.5, 0, 0, 0, 0)
> cvec4 <- c(0, 1, 0, 0, 0, 0, 0, 0, -0.5, 0, 0, 0, 0)
> cvec5 <- c(0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0.5, 0)
> cvec6 <- c(0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, -0.5, 0)
> cmat <- cbind(cvec1, cvec2, cvec3, cvec4, cvec5, cvec6)
> est <- t(cmat) %*% psi
> se <- sqrt(diag(t(cmat) %*% vpsi %*% cmat))
> zval <- est/se
> pval <- round(pnorm(-abs(zval)) * 2, 6)
> cbind(est, se, zval, pval)

```

```

                se
cvec1 52.4488441003 0.15621377 335.750457705 0.000000
cvec2 52.3889383256 0.15621178 335.371236171 0.000000
cvec3 -1.8172226734 0.05842283 -31.104665646 0.000000
cvec4 0.0467840870 0.05842488 0.800756198 0.423273
cvec5 1.1882712746 0.15101591 7.868517250 0.000000
cvec6 -0.0003542361 0.15101620 -0.002345683 0.998128

```

ในกลุ่มบำบัด มีความเครียดลดลง 1.82 ต่อวัน
 ในช่วงบำบัด และมีความเครียดกลับมาสูงขึ้น
 1.19 ต่อวันในช่วงติดตาม

ในกลุ่มควบคุม มีความเครียดในช่วง
 บำบัดและช่วงติดตาม ไม่เปลี่ยนแปลง
 อย่างมีนัยสำคัญ

เงื่อนไข ทดลอง	จุดตัดแบบง่าย			ความชันแบบง่ายช่วงบำบัด			ความชันแบบง่ายช่วงติดตาม		
	b	SE	z	b	SE	z	b	SE	z
กลุ่มบำบัด	52.50	0.16	335.75**	-1.82	0.06	-31.10**	1.19	0.15	7.87**
กลุ่มควบคุม	52.39	0.16	335.37**	0.05	0.06	0.80	0.00	0.15	-0.00

สามารถตรวจสอบปฏิสัมพันธ์ได้ 2 แบบ คือ

2. ในแต่ละช่วงเวลา ความเครียดแตกต่างกันระหว่างกลุ่มทดลองและกลุ่มควบคุมหรือไม่

$$Y_{ij} = 52.42 - 0.88T_{Tij} + 0.59T_{Fij} + (0.060 - 1.864T_{Tij} + 1.189T_{Fij})(W_{1j} - 0.5)$$

T	T_T	T_F	จุดตัดอย่างง่าย	ความชันอย่างง่าย
1-5	0	0	$52.42 + (-0.88 \times 0) + (0.59 \times 0) = 52.42$	$0.060 + (-1.864 \times 0) + (1.189 \times 0) = 0.06$
6	1	0	$52.42 + (-0.88 \times 1) + (0.59 \times 0) = 51.54$	$0.060 + (-1.864 \times 1) + (1.189 \times 0) = -1.80$
7	2	0	$52.42 + (-0.88 \times 2) + (0.59 \times 0) = 50.66$	$0.060 + (-1.864 \times 2) + (1.189 \times 0) = -3.67$
8	3	0	$52.42 + (-0.88 \times 3) + (0.59 \times 0) = 49.78$	$0.060 + (-1.864 \times 3) + (1.189 \times 0) = -5.53$
9	4	0	$52.52 + (-0.88 \times 4) + (0.59 \times 0) = 48.90$	$0.060 + (-1.864 \times 4) + (1.189 \times 0) = -7.40$
10	5	0	$52.42 + (-0.88 \times 5) + (0.59 \times 0) = 48.02$	$0.060 + (-1.864 \times 5) + (1.189 \times 0) = -9.26$
11	6	0	$52.42 + (-0.88 \times 6) + (0.59 \times 0) = 47.14$	$0.060 + (-1.864 \times 6) + (1.189 \times 0) = -11.12$
12	6	1	$52.42 + (-0.88 \times 6) + (0.59 \times 1) = 47.73$	$0.060 + (-1.864 \times 6) + (1.189 \times 1) = -9.94$
13	6	2	$52.42 + (-0.88 \times 6) + (0.59 \times 2) = 48.32$	$0.060 + (-1.864 \times 6) + (1.189 \times 2) = -8.75$
14	6	3	$52.42 + (-0.88 \times 6) + (0.59 \times 3) = 48.91$	$0.060 + (-1.864 \times 6) + (1.189 \times 3) = -7.56$

```
> sumout1i <- summary(out1i)
> coef(sumout1i)
```

	Estimate	Slope F
(Intercept)	52.418891213	0
timetreat	-0.885219293	0
timefollow	0.593958519	0
diffsleep	-1.892949777	0
I(avesleep - 7.075)	0.251976002	0
I(treat - 0.5)	0.059905775	1
I(age - 36.638)	0.013452280	0
timetreat:I(avesleep - 7.075)	-0.035437335	0
timetreat:I(treat - 0.5)	-1.864006760	0, 1, 2, 3, 4, 5, 6, 6, 6, 6
timetreat:I(age - 36.638)	0.002091415	0
timefollow:I(avesleep - 7.075)	-0.033807955	0
timefollow:I(treat - 0.5)	1.188625511	0, 0, 0, 0, 0, 0, 0, 0, 1, 2, 3
timefollow:I(age - 36.638)	-0.018400424	0

```

> cvec1 <- c(0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0)
> cvec2 <- c(0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 0, 0, 0)
> cvec3 <- c(0, 0, 0, 0, 0, 1, 0, 0, 2, 0, 0, 0, 0)
> cvec4 <- c(0, 0, 0, 0, 0, 1, 0, 0, 3, 0, 0, 0, 0)
> cvec5 <- c(0, 0, 0, 0, 0, 1, 0, 0, 4, 0, 0, 0, 0)
> cvec6 <- c(0, 0, 0, 0, 0, 1, 0, 0, 5, 0, 0, 0, 0)
> cvec7 <- c(0, 0, 0, 0, 0, 1, 0, 0, 6, 0, 0, 0, 0)
> cvec8 <- c(0, 0, 0, 0, 0, 1, 0, 0, 6, 0, 0, 1, 0)
> cvec9 <- c(0, 0, 0, 0, 0, 1, 0, 0, 6, 0, 0, 2, 0)
> cvec10 <- c(0, 0, 0, 0, 0, 1, 0, 0, 6, 0, 0, 3, 0)
> cmat <- cbind(cvec1, cvec2, cvec3, cvec4, cvec5, cvec6, cvec7, cvec8, cvec9, cvec10)
> est <- t(cmat) %*% psi
> se <- sqrt(diag(t(cmat) %*% vpsi %*% cmat))
> zval <- est/se
> pval <- round(pnorm(-abs(zval)) * 2, 6)
> cbind(est, se, zval, pval)

```

	se			
cvec1	0.05990577	0.2208941	0.2711968	0.78624
cvec2	-1.80410099	0.1899213	-9.4992019	0.00000
cvec3	-3.66810775	0.1923457	-19.0703922	0.00000
cvec4	-5.53211451	0.2271001	-24.3598044	0.00000
cvec5	-7.39612127	0.2824941	-26.1815083	0.00000
cvec6	-9.26012803	0.3488298	-26.5462676	0.00000
cvec7	-11.12413479	0.4209660	-26.4252602	0.00000
cvec8	-9.93550928	0.3658028	-27.1608344	0.00000
cvec9	-8.74688377	0.4261681	-20.5244901	0.00000
cvec10	-7.55825826	0.5662465	-13.3479996	0.00000

ในวันที่ 6-14 ซึ่งอยู่ในช่วงบำบัด
หรือช่วงติดตาม พบว่ากลุ่มบำบัด
มีความเครียดน้อยกว่ากลุ่มควบคุม

ความแปรปรวนค่าคงเหลือไม่เท่ากัน

- โมเดลเส้นโค้งพัฒนาการจะมีสมมติฐานทางสถิติ (Assumption) ว่าความแปรปรวนของค่าคงเหลือเท่ากัน ในทุกๆ ระดับของเวลา (Homoscedasticity) กล่าวคือ e_{ij} มีความแปรปรวนเท่ากันในทุกค่าของ i และ j คือ σ^2
- แต่ในบางครั้ง σ^2 อาจเปลี่ยนแปลงไปตามเวลา เช่น คำศัพท์ที่ทารกพูดได้ ตอนแรกเกิดอาจมีความแตกต่างกันน้อย เช่น 0-3 คำ แต่พอเข้าวัยเตาะแตะ บางคนก็ยังไม่พูดได้ บางคนกลับพูดได้เยอะมาก เช่น ช่วงอายุถึง 0-40 คำ ซึ่งแสดงให้เห็นว่าความแปรปรวนของคำศัพท์พูด เพิ่มขึ้นตามวัยด้วย

ความแปรปรวนค่าคงเหลือไม่เท่ากัน

- ในการวิเคราะห์พหุระดับ (หรือการวิเคราะห์ถดถอย) สามารถสร้างโมเดลที่ความแปรปรวนค่าคงเหลือขึ้นอยู่กับค่าของตัวแปรอิสระได้ โดยสามารถแบ่งออกได้หลายรูปแบบ
- ให้ X เป็นตัวแปรอิสระระดับใดก็ได้ ซึ่งในบทนี้จะหมายถึงตัวแปรเวลา เราสามารถสร้างโมเดลที่ความแปรปรวนค่าคงเหลือระดับที่ 1 ให้อยู่ในรูปแบบใดรูปแบบหนึ่ง ดังต่อไปนี้
 - ค่าความแปรปรวนค่าคงเหลือคงที่ (Homoscedasticity): $\text{Var}(e_{ij}) = \sigma^2$
 - ค่าความแปรปรวนค่าคงเหลือไม่เท่ากัน (Heteroscedasticity):
$$\text{Var}(e_{ij}) = f(X)$$

ความแปรปรวนค่าคงเหลือไม่เท่ากัน


- รูปแบบของฟังก์ชันที่มีในโปรแกรม
 - ความแปรปรวนขึ้นอยู่กับค่าของ X กล่าวคือ $\text{Var}(e_{ij}) = \sigma_x^2$ เช่น ความแปรปรวนของค่าคงเหลือที่วัดในปีที่ 1, 2, 3, และ 4 แตกต่างกันไป
 - สำหรับวิธีการนี้ หากใช้กับตัวแปรเวลาจะเหมาะสมกับเวลาที่มีค่าจำกัด ถ้าค่าของเวลาของแต่ละคนแตกต่างกัน (Individually-varying time) จะไม่สามารถใช้ได้ เช่น คนแรกวัดวันที่ 0, 25, และ 55, คนที่สองวัดวันที่ 0, 17, และ 38, คนที่สามวัดวันที่ 0, 34, และ 42
 - ความแปรปรวนเปลี่ยนแปลงตามฟังก์ชันยกกำลัง (Power Function): $\text{Var}(e_{ij}) = \sigma^2 \cdot |x|^{2k}$ โดย
 - $k < 0$ ยิ่ง X เพิ่ม ความแปรปรวนยิ่งลดลง
 - $k > 0$ ยิ่ง X เพิ่ม ความแปรปรวนยิ่งมากขึ้น

ความแปรปรวนค่าคงเหลือไม่เท่ากัน

- รูปแบบของฟังก์ชันที่มีในโปรแกรม
 - ความแปรปรวนเปลี่ยนแปลงตามฟังก์ชันยกกำลังบวกค่าคงที่ (Constant Power Function): $\text{Var}(e_{ij}) = \sigma^2 \cdot (c + |x|^k)^2$
 - เหมือนฟังก์ชันยกกำลัง ค่า c เป็นเพียงตัวเลื่อนกราฟขึ้นลงตามแนวตั้ง
 - ความแปรปรวนเปลี่ยนแปลงตามฟังก์ชัน Exponential: $\text{Var}(e_{ij}) = \sigma^2 \cdot e^{2kx}$ โดย
 - การเปลี่ยนแปลงเป็นรูปแบบ Exponential Function: $Y = \exp(kX)$
 - $k < 0$ ยิ่ง X เพิ่ม ความแปรปรวนยิ่งลดลง
 - $k > 0$ ยิ่ง X เพิ่ม ความแปรปรวนยิ่งมากขึ้น

ความแปรปรวนค่าคงเหลือไม่เท่ากัน


- ตรวจสอบการเปลี่ยนแปลง SD ของค่าคงเหลือ ให้ $X = 1, 2, 3, 4$
- Fixed: $SD_e = 1.5$
- Power: $SD_e = 1.5 \cdot |X|^k$
- Constant Power:
 $SD_e = 1.5 \cdot (c + |X|^k)$
- Exponential: $SD_e = e^{kX}$



ความแปรปรวนค่าคงเหลือไม่เท่ากัน

- ตัวอย่างข้อมูลฟังก์ชัน Power ที่ $SD_e = 1.5 \cdot |X|^{0.8}$

เส้นสีแดงมีความกว้าง
 $\pm 1 SD$ ในแต่ละช่วงเวลา



ความแปรปรวนค่าคงเหลือไม่เท่ากัน

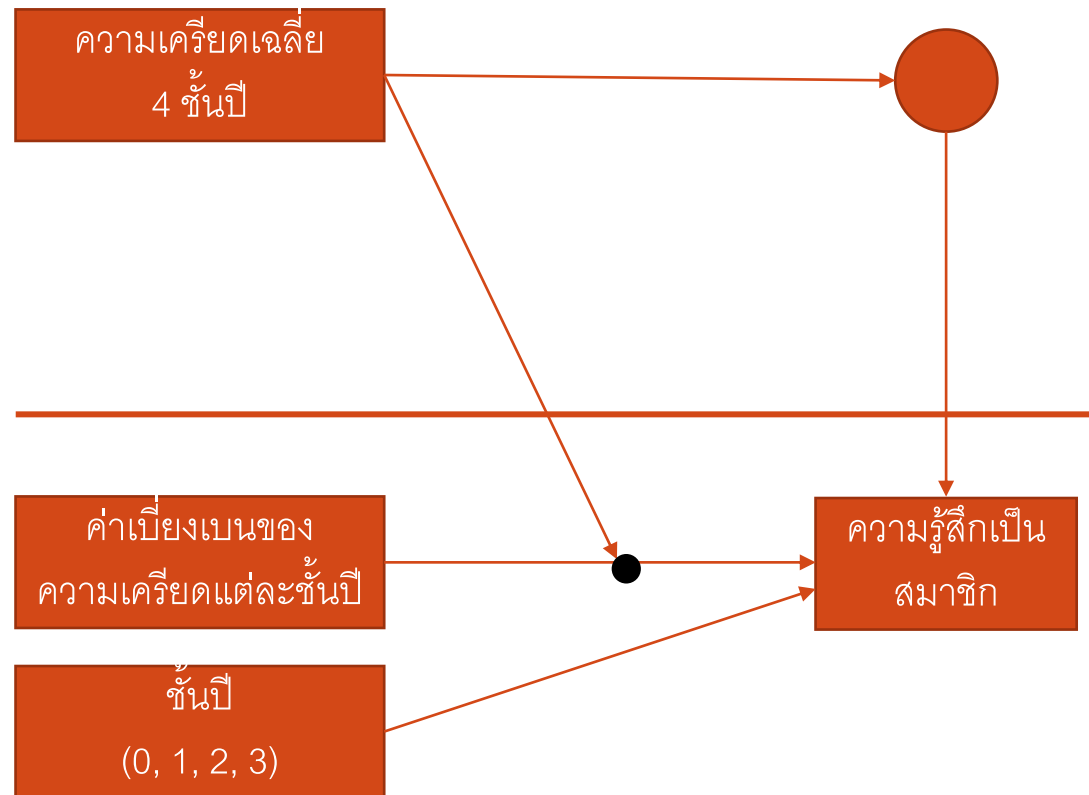
- ในกรณีที่ $X = 1, 2, 3, 4$ หากกำหนดให้ค่าความแปรปรวนขึ้นอยู่กับค่าของ X จะหมายความว่า $\sigma_1^2 \neq \sigma_2^2 \neq \sigma_3^2 \neq \sigma_4^2$ จากเดิมประมาณค่าพารามิเตอร์ตัวเดียว ตอนนี้ประมาณค่าพารามิเตอร์ 4 ค่า df จะลดลง 3
- ส่วนค่า df ที่ลดลงค่าฟังก์ชันความแปรปรวนโมเดลอื่น ขึ้นอยู่กับค่าพารามิเตอร์ที่ทำนายเพิ่ม เช่น ฟังก์ชันกำลัง จะทำให้ df ลดลง 1
- สามารถเปรียบเทียบโมเดลความแปรปรวนเท่าและแตกต่างกันได้ ด้วย Likelihood Ratio Test
- รายละเอียดเพิ่มเติมที่ <https://data.library.virginia.edu/modeling-non-constant-variance/>

ความแปรปรวนค่าคงเหลือไม่เท่ากัน

ทำนายความรู้สึกเป็นสมาชิก
ของนิสิตจากคณะแห่งหนึ่ง



เก็บข้อมูลจากนิสิต 850 คน เป็นนิสิตรุ่น
2550 ทั้งหมด 426 คน และนิสิตรุ่น
2551 จำนวน 424 คน เก็บข้อมูลระยะยาว
ตลอดเวลา 4 ปี



```

> dat5 <- read.table("lecture8ex2.csv", sep=";", header=TRUE)
> dat5$timec <- dat5$time - 1
> dat5$avestress <- ave(dat5$stress, dat5$pid)
> dat5$diffstress <- dat5$stress - dat5$avestress
> library(lme4)
> out5 <- lmer(mem ~ 1 + timec + diffstress + avestress + (1 + timec|pid), data=dat5, REML=FALSE)
> summary(out5)

```

Linear mixed model fit by maximum likelihood ['lmerMod']

Formula:

mem ~ 1 + timec + diffstress + avestress + (1 + timec | pid)

Data: dat5

AIC	BIC	logLik	deviance	df.resid
25552.9	25602.0	-12768.5	25536.9	3392

Scaled residuals:

Min	1Q	Median	3Q	Max
-3.10411	-0.48077	0.00681	0.49606	2.61723

Random effects:

Groups	Name	Variance	Std.Dev.	Corr
pid	(Intercept)	234.68	15.319	
	timec	35.29	5.941	-0.15
Residual		<u>25.92</u>	5.091	

Number of obs: 3400, groups: pid, 850

Fixed effects:

	Estimate	Std. Error	t value
(Intercept)	56.78964	2.57724	22.035
timec	-1.88457	0.21823	-8.636
diffstress	0.40878	0.01212	33.730
avestress	0.10050	0.05011	2.006

โมเดลเดิมที่กล่าวถึงในบทที่แล้ว
 ตอนนี้นำค่าความแปรปรวนคงเหลือ
 ระดับที่ 1 เท่ากันทุกช่วงเวลา เท่ากับ
 $\sigma^2 = 25.92$ โดยส่วนเบี่ยง
 เบนมาตรฐานคือ $\sigma = 5.09$

ความแปรปรวนค่าคงเหลือไม่เท่ากัน

- ในการวิเคราะห์โมเดลความแปรปรวนค่าคงเหลือไม่เท่ากัน (Heteroscedastic Model) เราจะใช้ `nlme` package ซึ่ง Doug Bates ผู้พัฒนา `nlme4` เคยพัฒนามาก่อนที่ย้ายมาพัฒนา `nlme4`
- `nlme4` จะมีการวิเคราะห์ที่รวดเร็วกว่า เพราะโครงสร้างโปรแกรมการคำนวณออกแบบดีกว่าเดิม แต่ไม่ได้พัฒนาให้ครอบคลุมทุกตัวเลือกที่ `nlme` ทำได้

ความแปรปรวนค่าคงเหลือไม่เท่ากัน

- วิเคราะห์โมเดลเดิมใน nlme

```
> library(nlme)
> out5a <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit)
```

เรียก package nlme

คำสั่ง Fixed Effect

แยกเขียน Random Effect

เลือกได้ระหว่าง ML และ REML
โดยค่าเริ่มต้นคือ REML แต่ผม
เลือกใช้ ML

ค่าเริ่มต้น คือ `na.fail` ที่เมื่อเจอค่าสูญหาย
จะยกเลิกการวิเคราะห์ทันที ในที่นี้เลือก
`na.omit` เพื่อลบแถวที่มีค่าสูญหายออก
(listwise deletion)

```

> library(nlme)
> out5a <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit)
> summary(out5a)

```

ผลการวิเคราะห์จะเหมือนกับ lme4

```

Linear mixed-effects model fit by maximum likelihood
Data: dat5
      AIC      BIC    logLik
25552.95 25602 -12768.47

```

ค่าความเหมาะสมของโมเดล

```

Random effects:
Formula: ~1 + timec | pid
Structure: General positive-definite, Log-Cholesky parametrization

```

```

      StdDev      Corr
(Intercept) 15.319143 (Intr)
timec        5.940565 -0.152
Residual     5.090837

```

ค่าส่วนเบี่ยงเบนมาตรฐาน และสหสัมพันธ์ของอิทธิพลสุ่ม

```

Fixed effects: mem ~ 1 + timec + diffstress + avestress
      Value Std.Error   DF  t-value p-value
(Intercept) 56.78964 2.5787499 2548 22.02216 0.0000
timec       -1.88457 0.2183537 2548 -8.63082 0.0000
diffstress  0.40878 0.0121265 2548 33.70962 0.0000
avestress   0.10050 0.0501375  848  2.00458 0.0453

```

ค่าสถิติของอิทธิพลคงที่ ซึ่งในที่นี้ให้

p-value มาด้วย ต่างกับ lme4

ที่ไม่ให้ p-value มา

```

Correlation:
      (Intr) timec  dffstr
timec   -0.045
diffstress -0.004  0.011
avestress -0.977  0.000  0.003

```

ค่าความสัมพันธ์ระหว่างอิทธิพลคงที่ แทนไม่ได้ใช้แปลความหมาย

```

Standardized Within-Group Residuals:
      Min          Q1          Med          Q3          Max
-3.104097747 -0.480769826  0.006814801  0.496061463  2.617219474

```

ค่าสถิติของ $e_{ij}/\sqrt{\sigma^2}$

```

Number of Observations: 3400
Number of Groups: 850

```

```
> out5b <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit,
+             weights=varIdent(form = ~1|timec))
> summary(out5b)
```

```
Linear mixed-effects model fit by maximum likelihood
Data: dat5
      AIC      BIC    logLik
25510.7 25578.15 -12744.35
```

Random effects:

```
Formula: ~1 + timec | pid
Structure: General positive-definite, Log-Cholesky parametrization
      StdDev   Corr
(Intercept) 15.332929 (Intr)
timec        5.888771 -0.154
Residual     6.527770
```

Variance function:

```
Structure: Different standard deviations per stratum
Formula: ~1 | timec
Parameter estimates:
      0      1      2      3
1.0000000 0.6696639 0.9035288 0.3313774
```

```
Fixed effects: mem ~ 1 + timec + diffstress + avestress
      Value Std.Error   DF t-value p-value
(Intercept) 56.91609 2.5920724 2548 21.95776 0.0000
timec      -1.78621 0.2110655 2548 -8.46280 0.0000
diffstress  0.40682 0.0119806 2548 33.95679 0.0000
avestress   0.09579 0.0503951  848  1.90079 0.0577
```

เพิ่มบรรทัดนี้มา เพื่อทำ Heteroscedastic Model
ที่ค่าความแปรปรวนของค่าคงเหลือในกลุ่มของ
timec เดียวกัน จะมีค่าเท่ากัน

σ มีค่าเท่ากับ 6.528

ค่าคงเหลือแต่ละชั้นปีมี *SD* ดังนี้

- $\sigma_1 = 6.528 \times 1 = 6.528$
- $\sigma_2 = 6.528 \times 0.670 = 4.371$
- $\sigma_3 = 6.528 \times 0.904 = 5.898$
- $\sigma_4 = 6.528 \times 0.331 = 2.163$

```
> anova(out5a, out5b)
      Model df      AIC      BIC   logLik   Test L.Ratio p-value
out5a     1   8 25552.95 25602.00 -12768.47
out5b     2  11 25510.70 25578.15 -12744.35 1 vs 2 48.2462 <.0001
```

ค่าแปรปรวนคงเหลือของทั้ง 4 เวลาแตกต่างกันอย่างมีนัยสำคัญ จึงใช้โมเดลค่าคงเหลือ
มีความแปรปรวนแตกต่างกัน (Heteroscedastic Model) ทั้ง 4 เวลา

```
> out5bsigma <- as.numeric(VarCorr(out5b)[3, 2])
> out5bsigmatime <- out5bsigma * coef(out5b$modelStruct$varStruct, uncons = FALSE)
> c(out5bsigma, out5bsigmatime)
      1      2      3
6.527770 4.371412 5.898028 2.163155
```

คำนวณค่าส่วนเบี่ยงเบนมาตรฐานของแต่ละช่วงเวลา

```

> out5c <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit,
+             weights=varExp(form = ~time))
> summary(out5c)

```

Linear mixed-effects model fit by maximum likelihood

```

Data: dat5
      AIC      BIC    logLik
25552.81 25607.99 -12767.4

```

Random effects:

```

Formula: ~1 + timec | pid
Structure: General positive-definite, Log-Cholesky param

```

```

          StdDev   Corr
(Intercept) 15.271202 (Intr)
timec        5.899540 -0.144
Residual     5.560076

```

Variance function:

```

Structure: Exponential of variance covariate
Formula: ~time
Parameter estimates:
      expon
-0.03465453

```

```

> out5csigma <- as.numeric(VarCorr(out5c)[3, 2])
> expvalue <- coef(out5c$modelStruct$varStruct, uncons = FALSE)
> out5csigma * exp(expvalue * (1:4))

```

```

[1] 5.370695 5.187764 5.011064 4.840382

```

ความแปรปรวนแต่ละช่วงเวลา

```

> anova(out5a, out5c)
      Model df      AIC      BIC    logLik  Test L.Ratio p-value
out5a     1   8 25552.95 25602.00 -12768.47
out5c     2   9 25552.81 25607.99 -12767.40 1 vs 2 2.14082 0.1434

```

เพิ่มบรรทัดนี้มา เพื่อทำ Heteroscedastic Model
ที่ค่าความแปรปรวนของค่าคงเหลือเป็นฟังก์ชัน
Exponential ของ time

$$\sigma_t = \sigma \cdot e^{kt} = 5.37 \cdot e^{-0.035t}$$

ไม่แตกต่างจาก
homoscedastic model
อย่างมีนัยสำคัญ

```
> out5d <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit,
+             weights=varPower(form = ~time))
> summary(out5d)
```

```
Linear mixed-effects model fit by maximum likelihood
Data: dat5
      AIC      BIC    logLik
25551.99 25607.17 -12766.99
```

```
Random effects:
Formula: ~1 + timec | pid
Structure: General positive-definite, Log-Cholesky parameter
      StdDev   Corr
(Intercept) 15.252170 (Intr)
timec        5.883418 -0.141
Residual     5.495261
```

เพิ่มบรรทัดนี้มา เพื่อทำ Heteroscedastic Model
ที่ค่าความแปรปรวนของค่าคงเหลือเป็นฟังก์ชัน
Power ของ time

$$\sigma_t = \sigma \cdot |t|^k = 5.495 \cdot |t|^{-0.09}$$

```
Variance function:
Structure: Power of variance covariate
Formula: ~time
Parameter estimates:
      power
-0.08991353
```

```
> out5dsigma <- as.numeric(VarCorr(out5d)[3, 2])
> powervalue <- coef(out5d$modelStruct$varStruct, uncons = FALSE)
> out5dsigma * (1:4)^powervalue
[1] 5.495261 5.163232 4.978387 4.851265
```

ความแปรปรวนแต่ละช่วงเวลา

```
> anova(out5a, out5d)
      Model df      AIC      BIC    logLik  Test  L.Ratio p-value
out5a    1   8 25552.95 25602.00 -12768.47
out5d    2   9 25551.99 25607.17 -12767.00 1 vs 2 2.958496 0.0854
```

ไม่แตกต่างจาก
homoscedastic model
อย่างมีนัยสำคัญ

```

> out5e <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit,
+             weights=varConstPower(form = ~time),
+             control = lmeControl(maxIter=200, msMaxIter = 200))
> summary(out5e)

```

Linear mixed-effects model fit by maximum likelihood

Data: dat5

	AIC	BIC	logLik
	25547.19	25608.51	-12763.6

Random effects:

Formula: ~1 + timec | pid

Structure: General positive-definite, Log-Cholesky parametrization

	StdDev	Corr
(Intercept)	15.192037	(Intr)
timec	5.813103	-0.126
Residual	1.157416	

Variance function:

Structure: Constant plus power of variance covariate

Formula: ~time

Parameter estimates:

	const	power
	4.246259	-22.457879

```

> out5esigma <- as.numeric(VarCorr(out5e)[3, 2])
> paramvar <- coef(out5e$modelStruct$varStruct, uncons = FALSE)
> out5esigma * (paramvar[1] + (1:4)^paramvar[2])
[1] 6.072104 4.914688 4.914688 4.914688

```

```

> anova(out5a, out5e)

```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
out5a	1	8	25552.95	25602.00	-12768.47			
out5e	2	10	25547.19	25608.51	-12763.60	1 vs 2	9.753751	0.0076

เพิ่มบรรทัดนี้มา เพื่อทำ Heteroscedastic Model
ที่ค่าความแปรปรวนของค่าคงเหลือเป็นฟังก์ชัน
Constant Power ของ time

เพิ่มจำนวนรอบในการหาค่าพารามิเตอร์ของ ML
เพื่อให้เจอ Convergent Solution

$$\sigma_t = \sigma \cdot (c + |t|^k) = 1.157 \cdot (4.246 + t^{-22.458})$$

ความแปรปรวนแต่ละช่วงเวลา

แตกต่างจาก

homoscedastic model

อย่างมีนัยสำคัญ

โมเดล	ปีที่ 1	ปีที่ 2	ปีที่ 3	ปีที่ 4
a) คงที่	5.091	5.091	5.091	5.091
b) ต่างกันแต่ละช่วงเวลา	6.528	4.371	5.898	2.163
c) Exponential	5.371	5.188	5.011	4.840
d) Power	5.495	5.163	4.978	4.851
e) Constant Power	6.072	4.915	4.915	4.915

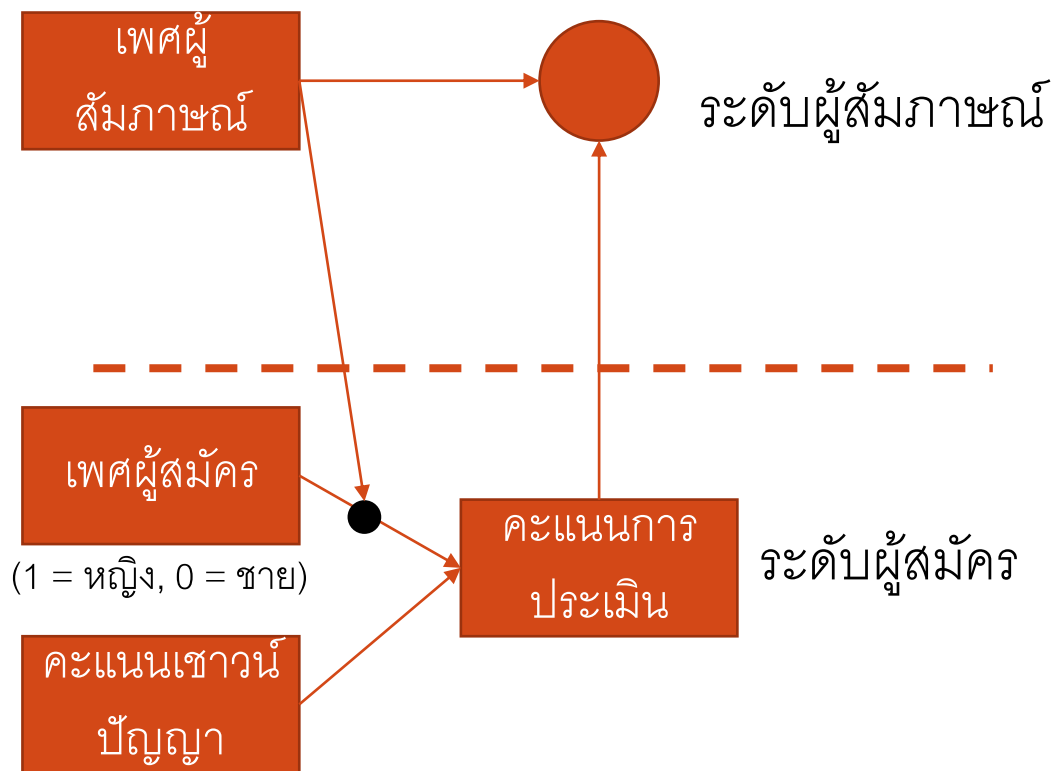
โมเดล b และ e ดีกว่าโมเดล a ทั้งคู่ เปรียบเทียบโมเดล b และ e ด้วย Likelihood Ratio Test เนื่องจากโมเดลทั้งสองซ้อนกัน โดยความแปรปรวนของโมเดล b ทำนายด้วย 4 พารามิเตอร์ แต่โมเดล c ทำนายด้วย 3 พารามิเตอร์

```
> anova(out5e, out5b)
      Model df      AIC      BIC    logLik  Test  L.Ratio p-value
out5e     1  10 25547.19 25608.51 -12763.60
out5b     2  11 25510.70 25578.15 -12744.35 1 vs 2 38.49245 <.0001
```

โมเดล b เป็นโมเดลที่อธิบายความแปรปรวนได้ดีที่สุด

ความแปรปรวนค่าคงเหลือไม่เท่ากัน

ทดสอบโมเดลที่ความแปรปรวนของค่าคงเหลือ
แตกต่างกันระหว่างเพศผู้สัมภาษณ์และ
เพศของผู้สมัคร



```
> dat6 <- read.table("lecture4ex2.csv", sep=",", header=TRUE)
> out6a <- lme(score ~ 1 + ersex + eesex + eesex:ersex + I(iq - 100),
+             random = ~1 + eesex|erid,
+             data=dat6, method="ML", na.action=na.omit)
> summary(out6a)
```

Linear mixed-effects model fit by maximum likelihood

Data: dat6

	AIC	BIC	logLik
	61640.99	61705.88	-30811.5

Random effects:

Formula: ~1 + eesex | erid

Structure: General positive-definite, Log-Cholesky parametrization

	StdDev	Corr
(Intercept)	4.4849853	(Intr)
eesex	0.8932369	0.125
Residual	4.6652498	

Fixed effects: score ~ 1 + ersex + eesex + eesex:ersex + I(iq - 100)

	Value	Std.Error	DF	t-value	p-value
(Intercept)	75.53870	0.22127123	8997	341.3851	0.0000
ersex	0.00989	0.31292407	998	0.0316	0.9748
eesex	-0.41323	0.13790183	8997	-2.9966	0.0027
I(iq - 100)	0.02942	0.00329961	8997	8.9155	0.0000
ersex:eesex	1.07365	0.19502919	8997	5.5051	0.0000

```
> out6b <- lme(score ~ 1 + ersex + eesex + eesex:ersex + I(iq - 100),
+             random = ~1 + eesex|erid,
+             data=dat6, method="ML", na.action=na.omit,
+             weights=varIdent(form = ~1|eesex))
> summary(out6b)
```

Linear mixed-effects model fit by maximum likelihood

Data: dat6

	AIC	BIC	logLik
	61642.39	61714.49	-30811.19

Random effects:

Formula: ~1 + eesex | erid

Structure: General positive-definite, Log-Cholesky parametrization

	StdDev	Corr
(Intercept)	4.4790343	(Intr)
eesex	0.8932343	0.138
Residual	4.6937412	

Variance function:

Structure: Different standard deviations per stratum

Formula: ~1 | eesex

Parameter estimates:

	0	1
	1.0000000	0.9878226

Fixed effects: score ~ 1 + ersex + eesex + eesex:ersex + I(iq - 100)

	Value	Std.Error	DF	t-value	p-value
(Intercept)	75.53870	0.22127116	8997	341.3852	0.0000
ersex	0.00989	0.31292398	998	0.0316	0.9748
eesex	-0.41323	0.13790180	8997	-2.9966	0.0027
I(iq - 100)	0.02941	0.00329918	8997	8.9143	0.0000
ersex:eesex	1.07365	0.19502915	8997	5.5051	0.0000

```
> anova(out6a, out6b)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
out6a	1	9	61640.99	61705.88	-30811.49			
out6b	2	10	61642.39	61714.49	-30811.19	1 vs 2	0.6004415	0.4384

ความแปรปรวนแตกต่างกันระหว่างเพศผู้สมัคร

ผู้สมัคร

เพศชาย	เพศหญิง
4.694	$4.694 \times 0.988 = 4.638$

ความแปรปรวนระหว่างเพศ

ผู้สมัครไม่ต่างกันอย่างมีนัยสำคัญ

```
> out6c <- lme(score ~ 1 + ersex + eesex + eesex:ersex + I(iq - 100),
+             random = ~1 + eesex|erid,
+             data=dat6, method="ML", na.action=na.omit,
+             weights=varIdent(form = ~1|ersex))
> summary(out6c)
```

Linear mixed-effects model fit by maximum likelihood

Data: dat6

	AIC	BIC	logLik
	61642.85	61714.95	-30811.43

Random effects:

Formula: ~1 + eesex | erid

Structure: General positive-definite, Log-Cholesky parametrization

	StdDev	Corr
(Intercept)	4.4850480	(Intr)
eesex	0.8929552	0.125
Residual	4.6783279	

Variance function:

Structure: Different standard deviations per stratum

Formula: ~1 | ersex

Parameter estimates:

	0	1
	1.0000000	0.9944001

Fixed effects: score ~ 1 + ersex + eesex + eesex:ersex + I(iq - 100)

	Value	Std.Error	DF	t-value	p-value
(Intercept)	75.53871	0.22138425	8997	341.2108	0.0000
ersex	0.00988	0.31292764	998	0.0316	0.9748
eesex	-0.41324	0.13825236	8997	-2.9890	0.0028
I(iq - 100)	0.02939	0.00329958	8997	8.9061	0.0000
ersex:eesex	1.07366	0.19502394	8997	5.5053	0.0000

```
> anova(out6a, out6c)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
out6a	1	9	61640.99	61705.88	-30811.49			
out6c	2	10	61642.85	61714.95	-30811.42	1 vs 2	0.1395039	0.7088

ความแปรปรวนแตกต่างกันระหว่างเพศผู้สัมภาษณ์

ผู้สัมภาษณ์

	เพศชาย	เพศหญิง
	4.678	$4.678 \times 0.994 = 4.650$

ความแปรปรวนระหว่างเพศ

ผู้สัมภาษณ์ไม่ต่างกันอย่างมีนัยสำคัญ

```
> out6d <- lme(score ~ 1 + ersex + eesex + eesex:ersex + I(iq - 100),
+             random = ~1 + eesex|erid,
+             data=dat6, method="ML", na.action=na.omit,
+             weights=varIdent(form = ~1|eesex * ersex))
> summary(out6d)
```

Linear mixed-effects model fit by maximum likelihood
 Data: dat6
 AIC BIC logLik
 61646.21 61732.73 -30811.11

Random effects:
 Formula: ~1 + eesex | erid
 Structure: General positive-definite, Log-Cholesky parametrization

StdDev Corr
 (Intercept) 4.4791338 (Intr)
 eesex 0.8928087 0.139
 Residual 4.7142126

Variance function:
 Structure: Different standard deviations per stratum
 Formula: ~1 | eesex * ersex
 Parameter estimates:

0*0 1*0 0*1 1*1
 1.0000000 0.9847240 0.9913071 0.9823362

Fixed effects: score ~ 1 + ersex + eesex + eesex:ersex + I(iq - 100)

Value Std.Error DF t-value p-value
 (Intercept) 75.53871 0.22144929 8997 341.1106 0.0000
 ersex 0.00988 0.31292999 998 0.0316 0.9748
 eesex -0.41324 0.13825089 8997 -2.9890 0.0028
 I(iq - 100) 0.02938 0.00329901 8997 8.9058 0.0000
 ersex:eesex 1.07367 0.19502165 8997 5.5054 0.0000

```
> anova(out6a, out6d)
Model df AIC BIC logLik Test L.Ratio p-value
out6a 1 9 61640.99 61705.88 -30811.49
out6d 2 12 61646.21 61732.73 -30811.10 1 vs 2 0.7796672 0.8543
```

ความแปรปรวนแตกต่างกันระหว่างทั้งเพศผู้สัมภาษณ์และเพศผู้สมัคร

ผู้สมัคร

	เพศชาย	เพศหญิง
เพศชาย	4.714	4.714 x 0.985 = 4.643
เพศหญิง	4.714 x 0.991 = 4.672	4.714 x 0.982 = 4.629

ผู้สัมภาษณ์

ความแปรปรวนทั้งสี่กลุ่มไม่ต่างกันอย่างมีนัยสำคัญ

ความสัมพันธ์ในตัว (Autocorrelation)

- ให้ Y_{tj} เป็นค่าของตัวแปรตามเวลาที่ t ในคนที่ j สมมติว่าไม่มีการเปลี่ยนแปลงค่าเฉลี่ยระหว่างช่วงเวลา ทำให้ Y_{tj} มีความสัมพันธ์ตามโมเดลพหุระดับดังต่อไปนี้

$$Y_{tj} = \gamma_{00} + u_{0j} + e_{tj} \text{ (ไม่มี } T_{tj} \text{ เพราะไม่มีการเปลี่ยนแปลงค่าเฉลี่ย)}$$

- หากโมเดลนี้เป็นจริง ความสัมพันธ์ระหว่างตัวแปรเป็นดังนี้

$$\text{Cov}(Y_{tj}, Y_{t'j}) = \begin{bmatrix} \tau_{00} + \sigma^2 & \tau_{00} & \cdots & \tau_{00} \\ \tau_{00} & \tau_{00} + \sigma^2 & \cdots & \tau_{00} \\ \vdots & \vdots & \ddots & \vdots \\ \tau_{00} & \tau_{00} & \cdots & \tau_{00} + \sigma^2 \end{bmatrix}$$

ความสัมพันธ์ในตัวเอง (Autocorrelation)

- ดังนั้น ความแปรปรวนร่วมระหว่างคะแนนของใครคนหนึ่ง ใน 2 ช่วงเวลา เช่น เวลาที่ 1 และ 2 หรือ เวลาที่ 1 และ 4 เท่ากับ τ_{00}
- ความแปรปรวนของ Y จะมีค่าเท่ากันในทุกคนและทุกช่วงเวลา คือ $\tau_{00} + \sigma^2$
- รูปแบบเมทริกซ์ที่สมาชิกแนวทแยงเท่ากัน และสมาชิกนอกแนวทแยงเท่ากัน จะเรียกว่าเมทริกซ์สมมาตรประกอบ (Compound Symmetry) กล่าวคือ มีค่าความแปรปรวนเท่ากันเพียงค่าเดียว และมีค่าความแปรปรวนร่วมเท่ากันเพียงค่าเดียว

ความสัมพันธ์ในตัวเอง (Autocorrelation)

- จากสมการข้างต้น ความสัมพันธ์ระหว่างค่าคงเหลือระดับที่ 1 จะมีรูปแบบดังนี้

$$\text{Cov}(e_{tj}, e_{t'j}) = \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix} = \sigma^2 \mathbf{I}_{T \times T}$$

- หมายความว่า ความแปรปรวนร่วมระหว่างคะแนนในคนเดียวจะเกิดจากการเป็นสมาชิกคนเดียวเท่านั้น ซึ่งเท่ากับ τ_{00}

ความสัมพันธ์ในตัวเอง (Autocorrelation)

- อย่างไรก็ตาม ในสถานการณ์จริง เรามักจะพบว่าค่าคงเหลือที่มาจากคนเดียวกันในเวลาใกล้เคียงกัน มักจะมีความคล้ายคลึงกัน เช่น ในกรณีที่ไม่มีตัวแปรอิสระ $Cov(Y_{1j}, Y_{2j})$ ควรจะมากกว่า $Cov(Y_{1j}, Y_{4j})$
 - เช่น วัดอารมณ์ทุกๆ ชั่วโมง เวลาในชั่วโมงที่ติดกัน ควรจะมีอารมณ์คล้ายคลึงกัน ตอน 10:00 ผู้ร่วมการทดลองคนหนึ่งอารมณ์เสีย เวลา 11:00 น่าจะยังมีอารมณ์เสียค้างอยู่ คะแนนเวลา 10 และ 11 โมงควรมีความสัมพันธ์กัน และความสัมพันธ์กันนี้ควรมากกว่าเวลาที่ห่างกัน
- ปราบกฎการณดังกล่าวเรียกว่า ความสัมพันธ์ในตัวเอง (Autocorrelation) ซึ่งสามารถทำโมเดลพหุระดับเพื่อตรวจสอบปราบกฎการณดังกล่าวได้ดังนี้

ความสัมพันธ์ในตัวเอง (Autocorrelation)

- โมเดลแบบง่ายที่สุดในการตรวจจับอิทธิพลระหว่างค่าคงเหลือ คือ โมเดลความสัมพันธ์ในตัวเองแบบง่าย (Simplex model) โดย

$$Y_{tj} = \gamma_{00} + u_{0j} + e_{tj}$$

$$e_{tj} = \rho e_{t-1,j} + r_{tj}$$



สมมติว่าไม่มีการ
เปลี่ยนแปลงค่าเฉลี่ย


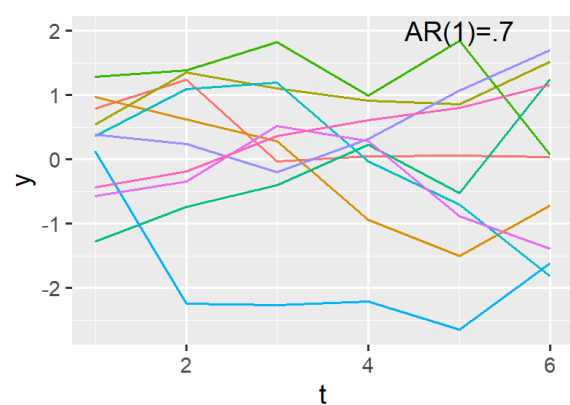

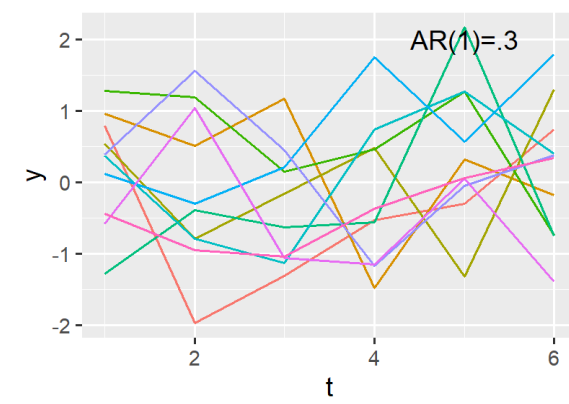

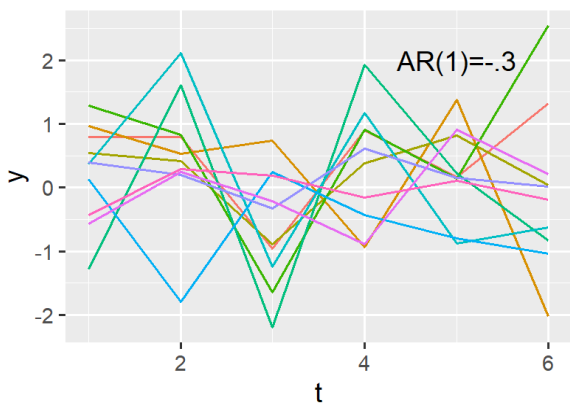



- e_t คือ ค่าคงเหลือในเวลา t
- ρ คือ ค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเอง (Autocorrelation; AR(1)) มีค่าตั้งแต่ -1 ถึง 1
- r_t คือ ค่าสุ่มที่เกิดขึ้นในเวลา t มีความแปรปรวนเท่ากับ σ^2

ความสัมพันธ์ในตัว (Autocorrelation)

- หาก $\rho > 0$ ค่าที่อยู่ในเวลาใกล้เคียงกัน จะคล้ายคลึงกัน ยิ่งค่าสูง ยิ่งคล้ายกัน
- หาก $\rho < 0$ ค่าที่อยู่ในเวลาใกล้เคียงกัน จะมีค่าใกล้เคียงกัน แต่กระโดดไปฝั่งตรงข้ามของเส้น $y = 0$ ยิ่งขนาดสูง ยิ่งเห็นเป็นฟันปลา

สมการที่ใช้สร้างข้อมูล : $Y_{ij} = \gamma_{00} + e_{ij}$ $e_{tj} = \rho e_{t-1,j} + r_{tj}$





จาก $e_{tj} = \rho e_{t-1,j} + r_{tj}$

คำนวณความแปรปรวนของค่าคงเหลือแต่ละช่วงเวลา

$$\text{Var}(e_{tj}) = \text{Var}(\rho e_{t-1,j}) + \text{Var}(r_{tj}) \quad e \text{ และ } r \text{ ไม่สัมพันธ์กัน}$$

$$\text{Var}(e_{tj}) = \rho^2 \text{Var}(e_{t-1,j}) + \sigma^2$$

$$\text{Var}(e_{tj}) = \rho^2 \text{Var}(e_{tj}) + \sigma^2 \quad \text{ความแปรปรวนแต่ละช่วงเวลาเท่ากัน}$$

$$(1 - \rho^2) \text{Var}(e_{tj}) = \sigma^2$$

$$\text{Var}(e_{tj}) = \frac{\sigma^2}{1 - \rho^2}$$

คำนวณความแปรปรวนร่วมของค่าคงเหลือในช่วงเวลาที่ติดกัน

$$\text{Cov}(e_{tj}, e_{t-1,j}) = \text{Cov}(\rho e_{t-1,j}, e_{t-1,j}) + \text{Cov}(r_{tj}, e_{t-1,j}) \quad e \text{ และ } r \text{ ไม่สัมพันธ์กัน}$$

$$= \rho \text{Var}(e_{t-1,j})$$

$$= \frac{\rho \sigma^2}{1 - \rho^2}$$

r ต่างช่วงเวลาไม่สัมพันธ์กัน

$$\text{จาก } e_{tj} = \rho e_{t-1,j} + r_{tj} = \rho(\rho e_{t-2,j} + r_{t-1,j}) + r_{tj} = \rho^2 e_{t-2,j} + \rho r_{t-1,j} + r_{tj}$$

คำนวณความแปรปรวนร่วมของค่าคงเหลือในช่วงเวลาที่ห่างกัน 2 ช่วง

$$\begin{aligned} \text{Cov}(e_{tj}, e_{t-2,j}) &= \text{Cov}(\rho^2 e_{t-2,j}, e_{t-2,j}) + \text{Cov}(\rho r_{t-1,j}, e_{t-1,j}) + \text{Cov}(r_{tj}, e_{t-1,j}) \\ &= \rho \text{Var}(e_{t-2,j}) && e \text{ และ } r \text{ ไม่สัมพันธ์กัน} \\ &= \frac{\rho^2 \sigma^2}{1 - \rho^2} && r \text{ ต่างช่วงเวลาไม่สัมพันธ์กัน} \end{aligned}$$

จากแนวทางการวิเคราะห์ด้านบน สามารถพิสูจน์ได้ว่า

$$\text{Cov}(e_{tj}, e_{t-k,j}) = \frac{\rho^k \sigma^2}{1 - \rho^2}$$

ความสัมพันธ์ในตัวเอง (Autocorrelation)

- ดังนั้น เมทริกซ์ความแปรปรวนร่วมเป็นดังนี้

$$\text{Cov}(e_{tj}, e_{t'j}) = \frac{\sigma^2}{1 - \rho^2} \begin{bmatrix} 1 & \rho & \rho^2 & \dots & \rho^{T-1} \\ \rho & 1 & \rho & \dots & \rho^{T-2} \\ \rho^2 & \rho & 1 & \dots & \rho^{T-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho^{T-1} & \rho^{T-2} & \rho^{T-3} & \dots & 1 \end{bmatrix}$$

$$\text{Cov}(Y_{tj}, Y_{t'j}) = \text{Cov}(e_{tj}, e_{t'j}) + \tau_{00} \mathbf{1}_{T \times T}$$

- จะเห็นว่าในโมเดลนี้ ยิ่งเวลาห่างความสัมพันธ์ยิ่งน้อยลง

ความสัมพันธ์ในตัว (Autocorrelation)


- นอกจากโมเดล AR(1) ยังมีโมเดล AR(2)

$$e_{tj} = \rho_1 e_{t-1,j} + \rho_2 e_{t-2,j} + r_{tj}$$

- โมเดลนี้ จะมีความเหมาะสมเมื่อรูปแบบตัวแปรจะออกมาเป็นแบบคลื่น เช่น การเปลี่ยนแปลงอารมณ์ทางบวก

$$e_t = .4e_{t-1} - .1e_{t-2} + r_t$$

$$r_t \sim N(0,0.71), e_1 = 1, e_2 = -0.5$$

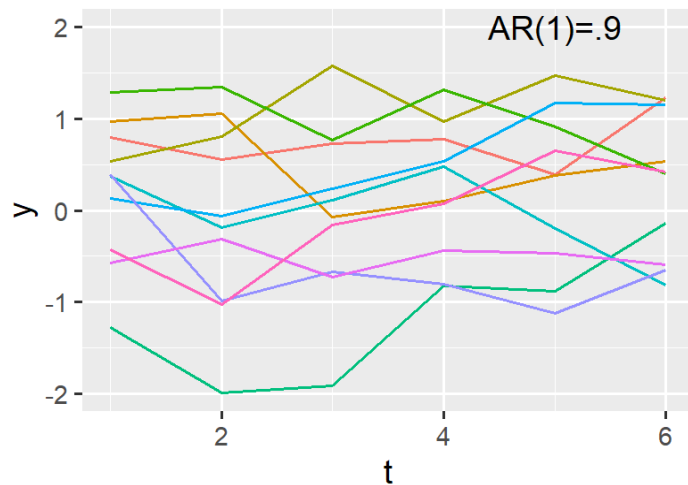


ความสัมพันธ์ในตัวเอง (Autocorrelation)

- ข้อตกลงเบื้องต้นของโมเดลนี้ คือ โมเดลความสัมพันธ์ในตัวเอง ยังเป็นแบบเดิมในช่วงเวลาทุกช่วงเวลา หรือที่เรียกว่า ความนิ่งของอนุกรมเวลา (Stationary of Time Series Model)

ความสัมพันธ์ในตัวเอง (Autocorrelation)

- อย่างไรก็ตาม ข้อมูลที่เกิดจากโมเดลที่มีสหสัมพันธ์ในตัวเอง อาจดูใกล้เคียงกับโมเดลอื่นๆ ในการวิเคราะห์พหุระดับ เช่น



โมเดลนี้ อาจมองว่าเป็นโมเดลสหสัมพันธ์ในตัวเองได้
หรืออาจมองเป็นโมเดลที่มีจุดตัดแกน Y แบบสุ่ม
(Random Intercept Model) ได้

กล่าวคือ ทั้งสองโมเดลอาจเหมาะสมกับข้อมูล
ทั้งคู่ และการเลือกโมเดลที่เหมาะสมควรเลือก
จากทฤษฎี

ความสัมพันธ์ในตัว (Autocorrelation)

- ความสัมพันธ์ของตัวแปรตามในแต่ละช่วงเวลาในโมเดลที่มีความชันสุ่ม จะไม่ใช่เมทริกซ์สมมาตรประกอบ (Compound Symmetry) โดย

$$\text{Var}(Y_{tj}) = \tau_{00} + \tau_{01}(T_t - T_0) + \tau_{11}(T_t - T_0) + \sigma^2$$

$$\text{Cov}(Y_{tj}, Y_{t'j}) = \tau_{00} + \tau_{01} \left((T_t - T_0) + (T_{t'} - T_0) \right) + \tau_{11}(T_t - T_0)(T_{t'} - T_0)$$

- $T_t - T_0$ และ $T_{t'} - T_0$ คือ ระยะห่างของจุดเวลาที่สนใจกับจุดที่เวลาตั้งศูนย์กลางไว้

ความสัมพันธ์ในตัว (Autocorrelation)

- อย่างไรก็ตาม โมเดลที่มีความชันสุ่ม (Random Slope Model) ก็ทำให้ค่าของตัวแปรตาม มีความแปรปรวนเปลี่ยนแปลงไปตามเวลา และความสัมพันธ์ของตัวแปรตามระหว่างสองช่วงเวลา ก็ไม่ได้มีค่าคงที่ ขึ้นอยู่กับช่วงเวลาทั้งสองจุด
- ดังนั้น ข้อมูลที่เหมาะสมกับความสัมพันธ์ในตัว อาจจะเหมาะสมกับโมเดลที่มีความชันสุ่มด้วย กล่าวคือ โมเดลทั้งสองก็เป็นไปได้ทั้งคู่
- ในกรณีนี้ การเลือกโมเดลที่เหมาะสมควรเลือกจากทฤษฎี

ความสัมพันธ์ในตัวเอง (Autocorrelation)

- Verbeke และ Lesaffre (1997) ได้ทดลองและพบว่าโมเดลพหุระดับที่ไม่ได้สนใจโครงสร้างของความสัมพันธ์ระหว่างตัวแปรตามในแต่ละช่วงเวลาอาจเป็นโมเดลที่ใช้ได้ การประมาณค่าพารามิเตอร์ในโมเดลถูกต้อง หากการละเมิดนั้น ไม่ใช่การละเมิดที่รุนแรง
- ส่วนตัวผม เชื่อว่าความสัมพันธ์ในตัวเอง (Autocorrelation) เป็นปรากฏการณ์ที่มีจริง แต่มักไม่ใช่ค่าพารามิเตอร์ที่นักวิจัยสนใจ ในการวิเคราะห์พหุระดับ
- แนะนำให้วิเคราะห์อิทธิพลของตัวแปรเวลาและตัวแปรอิสระต่อตัวแปรตามก่อน หากได้โมเดลที่สมบูรณ์แล้ว ค่อยวิเคราะห์ความสัมพันธ์ในตัวเองเพิ่มเติม

ความสัมพันธ์ในตัวเอง (Autocorrelation)

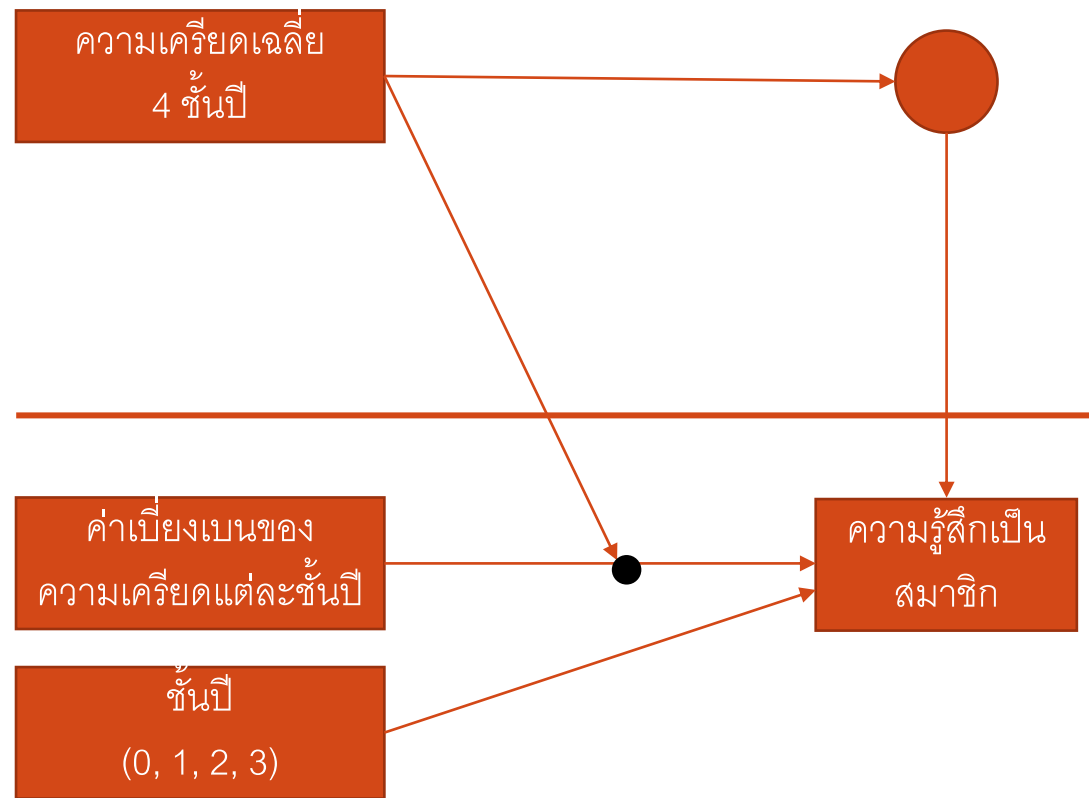
- การวิเคราะห์ต้องใช้ `nlme` package เพื่อให้สามารถประมาณค่าความสัมพันธ์ในตัวเอง (Autocorrelation) ได้

ความสัมพันธ์ในตัวเอง (Autocorrelation)

ทำนายความรู้สึกเป็นสมาชิก
ของนิสิตจากคณะแห่งหนึ่ง



เก็บข้อมูลจากนิสิต 850 คน เป็นนิสิตรุ่น
2550 ทั้งหมด 426 คน และนิสิตรุ่น
2551 จำนวน 424 คน เก็บข้อมูลระยะยาว
ตลอดเวลา 4 ปี



```
> out5e <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit,
+             correlation=corARMA(form = ~ 1 + timec | pid, p = 1))
> summary(out5e)
```

Linear mixed-effects model fit by maximum likelihood

Data: dat5

	AIC	BIC	logLik
	25546.58	25601.76	-12764.29

Random effects:

Formula: ~1 + timec | pid
Structure: General positive-definite, Log-Cholesky parametrization

	StdDev	Corr
(Intercept)	15.040698	(Intr)
timec	5.761743	-0.133
Residual	5.762396	

Correlation structure: AR(1)

Formula: ~1 + timec | pid
Parameter estimate(s):
Phi

0.2107785

Fixed effects: mem ~ 1 + timec + diffstress + avestress

	Value	Std.Error	DF	t-value	p-value
(Intercept)	56.73589	2.5786525	2548	22.00214	0.0000
timec	-1.87752	0.2177654	2548	-8.62177	0.0000
diffstress	0.40889	0.0120720	2548	33.87091	0.0000
avestress	0.10181	0.0501331	848	2.03083	0.0426

```
> anova(out5a, out5e)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
out5a	1	8	25552.95	25602.00	-12768.47			
out5e	2	9	25546.58	25601.76	-12764.29	1 vs 2	8.370098	0.0038

เพิ่มบรรทัดนี้มา เพื่อให้มี AR(1) ระหว่างค่าคงเหลือ
ระดับที่ 1 โดยค่าคงเหลือจากเวลาที่ timec ใกล้เคียงกัน
ภายในคน (pid) เดียวกัน จะมีอิทธิพลต่อกัน

$$e_{tj} = 0.211e_{t-1,j} + r_{tj} \quad \sigma_r = 5.76$$

เทียบกับโมเดลที่ไม่มี AR(1) พบว่า
โมเดลที่มี AR(1) อธิบายข้อมูลได้ดี
กว่าอย่างมีนัยสำคัญ



```

> set.seed(123321)
> ar1 <- coef(out5e$modelStruct$corStruct, uncons = FALSE)
> out5esigma <- as.numeric(VarCorr(out5e)["Residual", "StdDev"])
> e1 <- rnorm(20, 0, out5esigma/ sqrt(1 - ar1^2))
> e2 <- ar1*e1 + rnorm(20, 0, out5esigma)
> e3 <- ar1*e2 + rnorm(20, 0, out5esigma)
> e4 <- ar1*e3 + rnorm(20, 0, out5esigma)
>
> mye <- c(e1, e2, e3, e4)
> myid <- rep(1:20, 4)
> myt <- rep(1:4, each=20)
> daterror5 <- data.frame(t=myt, y=mye, id=myid)
> library(ggplot2)
> g <- ggplot(data=daterror5, aes(x=t, y=y, group=id))
> g + geom_line(aes(color=factor(id)), size=1)

```

$$e_{tj} = 0.211e_{t-1,j} + r_{tj}$$

$$\sigma_r = 5.76$$



```
> out5f <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit,
+             correlation=corARMA(form = ~ 1 + timec | pid, p = 2))
> summary(out5f)
```

```
Linear mixed-effects model fit by maximum likelihood
Data: dat5
      AIC      BIC    logLik
25547.67 25608.98 -12763.83
```

```
Random effects:
Formula: ~1 + timec | pid
Structure: General positive-definite, Log-Cholesky parametrization
      StdDev   Corr
(Intercept) 14.017530 (Intr)
timec        5.522065 -0.107
Residual     7.838444
```

```
Correlation structure: ARMA(2,0)
Formula: ~1 + timec | pid
Parameter estimate(s):
      Phi1      Phi2
0.4761667 0.1355471
```

```
Fixed effects: mem ~ 1 + timec + diffstress + avestress
      Value Std.Error   DF  t-value p-value
(Intercept) 56.64618 2.5773947 2548 21.97808 0.0000
timec       -1.87812 0.2178019 2548 -8.62307 0.0000
diffstress  0.40870 0.0120714 2548 33.85686 0.0000
avestress   0.10435 0.0501045  848  2.08274 0.0376
```

```
> anova(out5e, out5f)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
out5e	1	9	25546.58	25601.76	-12764.29			
out5f	2	10	25547.67	25608.99	-12763.83	1 vs 2	0.9078822	0.3407

เพิ่มบรรทัดนี้มา เพื่อให้มี AR(2) ระหว่างค่าคงเหลือ
ระดับที่ 1 โดยค่าคงเหลือจากเวลาที่ timec ใกล้เคียงกัน
ภายในคน (pid) เดียวกัน จะมีอิทธิพลต่อกัน

$$e_{tj} = 0.476e_{t-1,j} + 0.136e_{t-2,j} + r_{tj}$$

$$\sigma_r = 5.76$$

เทียบกับโมเดล AR(1) พบว่า

AR(2) อธิบายข้อมูลไม่แตกต่างจาก

AR(1) อย่างมีนัยสำคัญ


```

> set.seed(123321)
> ar <- coef(out5f$modelStruct$corStruct, uncons = FALSE)
> out5fsigma <- as.numeric(VarCorr(out5f)["Residual", "StdDev"])
> out5fsigma <- out5fsigma/sqrt(1 - ar[1]^2 - ar[2]^2 - ((ar[1]^2)*ar[2]/(1 - ar[2])))
> e1 <- rnorm(20, 0, out5fsigma)
> e2 <- ar[1]*e1 + rnorm(20, 0, out5fsigma)
> e3 <- ar[1]*e2 + ar[2]*e1 + rnorm(20, 0, out5fsigma)
> e4 <- ar[1]*e3 + ar[2]*e2 + rnorm(20, 0, out5fsigma)
>
> mye <- c(e1, e2, e3, e4)
> myid <- rep(1:20, 4)
> myt <- rep(1:4, each=20)
> daterror6 <- data.frame(t=myt, y=mye, id=myid)
> library(ggplot2)
> g <- ggplot(data=daterror6, aes(x=t, y=y, group=id))
> g + geom_line(aes(color=factor(id)), size=1)

```

$$e_{tj} = 0.476e_{t-1,j} + 0.136e_{t-2,j} + r_{tj}$$

$$\sigma_r = 5.76$$



```

> out5g <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit,
+             weights=varIdent(form = ~1|timec),
+             correlation=corARMA(form = ~ 1 + timec | pid, p = 1))
> summary(out5g)

```

Linear mixed-effects model fit by maximum likelihood

Data: dat5

	AIC	BIC	logLik
	25493.77	25567.35	-12734.89

Random effects:

Formula: ~1 + timec | pid

Structure: General positive-definite, Log-Cholesky parametrization

	StdDev	Corr
(Intercept)	14.711756	(Intr)
timec	5.794574	-0.108
Residual	7.054706	

Correlation structure: AR(1)

Formula: ~1 + timec | pid

Parameter estimate(s):

Phi
0.2803977

Variance function:

Structure: Different standard deviations per stratum

Formula: ~1 | timec

Parameter estimates:

	0	1	2	3
	1.0000000	0.7982946	0.9267197	0.1845082

Fixed effects: mem ~ 1 + timec + diffstress + avestress

	Value	Std.Error	DF	t-value	p-value
(Intercept)	56.74831	2.5775902	2548	22.01603	0.0000
timec	-1.79050	0.2109161	2548	-8.48917	0.0000
diffstress	0.40719	0.0119571	2548	34.05390	0.0000
avestress	0.10043	0.0501128	848	2.00404	0.0454

ใส่ทั้ง AR(1) และให้ความแปรปรวน
แตกต่างกันระหว่างช่วงเวลา

$$e_{tj} = 0.280e_{t-1,j} + r_{tj}$$

$$\sigma_{r_1} = 7.055$$

$$\sigma_{r_2} = 7.055 \times 0.798 = 5.630$$

$$\sigma_{r_3} = 7.055 \times 0.927 = 6.540$$

$$\sigma_{r_4} = 7.055 \times 0.185 = 1.305$$

```

> set.seed(123321)
> ar1 <- coef(out5g$modelStruct$corStruct, uncons = FALSE)
> sdratio <- coef(out5g$modelStruct$varStruct, uncons = FALSE)
> out5gsigma <- as.numeric(VarCorr(out5g)["Residual", "StdDev"])
> e1 <- rnorm(20, 0, out5gsigma/sqrt(1 - ar1^2))
> e2 <- ar1*e1 + rnorm(20, 0, out5gsigma * sdratio[1])
> e3 <- ar1*e2 + rnorm(20, 0, out5gsigma * sdratio[2])
> e4 <- ar1*e3 + rnorm(20, 0, out5gsigma * sdratio[3])
>
> mye <- c(e1, e2, e3, e4)
> myid <- rep(1:20, 4)
> myt <- rep(1:4, each=20)
> daterror5 <- data.frame(t=myt, y=mye, id=myid)
> library(ggplot2)
> g <- ggplot(data=daterror5, aes(x=t, y=y, group=id))
> g + geom_line(aes(color=factor(id)), size=1)

```


$$e_{tj} = 0.280e_{t-1,j} + r_{tj}$$

$$\sigma_{r_1} = 7.055$$

$$\sigma_{r_2} = 5.630$$

$$\sigma_{r_3} = 6.540$$

$$\sigma_{r_4} = 1.305$$



สัมประสิทธิ์การทำงาน

- ตัวแปรเวลามักจะไม่ใช้การย้ายศูนย์กลางไปที่ค่าเฉลี่ยกลุ่ม จึงไปใช้วิธีหาสัมประสิทธิ์การทำงานจากโมเดลที่ไม่ได้ย้ายศูนย์กลางไปที่ค่าเฉลี่ยกลุ่มได้
- การย้ายศูนย์กลางของตัวแปรเวลาด้วยค่าคงที่ไม่มีผลต่อสัมประสิทธิ์ทำงาน
- ยกตัวอย่างการเปลี่ยนแปลงความรู้สึกเป็นสมาชิก ตลอด 4 ชั้นปี
- ใช้ผลการวิเคราะห์จากคาบเรียนที่แล้ว เลือกโมเดลที่ไม่มีความสัมพันธ์ในตัว และความแปรปรวนของค่าคงเหลือเท่ากันในทุกช่วงเวลา

```

> dat5 <- read.table("lecture8ex2.csv", sep=",", header=TRUE)
> dat5$timec <- dat5$time - 1
> dat5$avestress <- ave(dat5$stress, dat5$pid)
> dat5$diffstress <- dat5$stress - dat5$avestress
> library(nlme)
> out5a <- lme(mem ~ 1 + timec + diffstress + avestress,
+           random = ~1 + timec|pid,
+           data=dat5, method="ML", na.action=na.omit)
> sumout5a <- summary(out5a)
>
> r2mlm:::r2mlm_long_manual(data=dat5,
+                           covs=c("timec", "diffstress", "avestress"),
+                           random_covs=c("timec"),
+                           gammas=coef(sumout5a)[-1, "value"],
+                           clusterID="pid",
+                           Tau=getVarCov(out5a),
+                           sigma2=out5a$sigma^2)

```

$$R_t^{2(f_1)} = .04$$

$$R_t^{2(f_2)} = .003$$

$$R_t^{2(v_1)} = .122$$

$$R_t^{2(v_2)} = .000$$

$$R_t^{2(m)} = .756$$

แบ่งความแปรปรวนออกเป็นส่วนต่างๆ

\$Decompositions

	total	within	between
fixed slopes (within)	0.0471088594128234	0.195211606767213	NA
fixed slopes (between)	0.00316696581884948	NA	0.00417432152419909
slope variation (within)	0.122351796082766	0.507006346616612	NA
slope variation (between)	0	NA	0
intercept variation (between)	0.755511013462372	NA	0.995825678475801
residual (within)	0.0718613652231889	0.297782046616175	NA

\$R2s

	total	within	between
f1	0.0471088594128234	0.195211606767213	NA
f2	0.00316696581884948	NA	0.00417432152419909
v1	0.122351796082766	0.507006346616612	NA
v2	0	NA	0
m	0.755511013462372	NA	0.995825678475801
f	0.0502758252316729	NA	NA
fv	0.172627621314439	0.702217953383825	0.00417432152419909
fvm	0.928138634776811	NA	NA

ผลของ R^2 ที่ได้

ตัวแปรต้นทั้งหมดโดยกำหนดให้ความเข้มข้นแบบแบบถาวรสามารถอธิบายความแปรปรวนได้ 5%, $R_t^{2(f)} = .05$

สัมประสิทธิ์การทำนาย

- Rights & Sterba (2021) ยังได้พิสูจน์เพิ่มเติมว่า โครงสร้างค่าสหสัมพันธ์ระหว่างค่าคงเหลือ เช่น ความสัมพันธ์ในตัวเอง ไม่มีผลต่อสูตรการหาสัมประสิทธิ์การทำนาย
 - อย่างไรก็ตาม ผู้วิเคราะห์ต้องใส่ $Var(e_{tj})$ ไม่ใช่ $Var(r_{tj})$ ซึ่งในโมเดล AR(1) จะมีค่าดังนี้

$$Var(e_{tj}) = \frac{Var(r_{tj})}{1 - \rho^2}$$

- ใช้ตัวอย่างเดิม แต่ปรับให้มี AR(1) และความแปรปรวนของค่าคงเหลือเท่ากันในทุกช่วงเวลา


```

> out5e <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit,
+             correlation=corARMA(form = ~ 1 + timec | pid, p = 1))
> sumout5e <- summary(out5e)
> ar1 <- coef(out5e$modelStruct$corStruct, uncons = FALSE)
> r2mlm::r2mlm_long_manual(data=dat5,
+                          covs=c("timec", "diffstress", "avestress"),
+                          random_covs=c("timec"),
+                          gammas=coef(sumout5e)[-1, "value"],
+                          clusterID="pid",
+                          Tau=getVarCov(out5e),
+                          sigma2=out5e$sigma^2/(1 - ar1^2)) ใช้สูตรเพื่อใส่ Var(eij)
$Decompositions

```

	total	within	between
fixed slopes (within)	0.0470165037236248	0.181952950274654	NA
fixed slopes (between)	0.00324887388858962	NA	0.00438089340729464
slope variation (within)	0.11506090083776	0.445283436891759	NA
slope variation (between)	0	NA	0
intercept variation (between)	0.738351887997082	NA	0.995619106592705
residual (within)	0.0963218335529436	0.372763612833588	NA

แบ่งความแปรปรวนออกเป็นส่วนต่างๆ

```

$R2s

```

	total	within	between
f1	0.0470165037236248	0.181952950274654	NA
f2	0.00324887388858962	NA	0.00438089340729464
v1	0.11506090083776	0.445283436891759	NA
v2	0	NA	0
m	0.738351887997082	NA	0.995619106592705
f	0.0502653776122144	NA	NA
fv	0.165326278449975	0.627236387166412	0.00438089340729464
fvm	0.903678166447056	NA	NA

ผลของ R² ที่ได้

$$R_t^{2(f_1)} = .047$$

$$R_t^{2(f_2)} = .003$$

$$R_t^{2(v_1)} = .115$$

$$R_t^{2(v_2)} = .000$$

$$R_t^{2(m)} = .738$$

ตัวแปรต้นทั้งหมดโดยกำหนดให้ความเข้มข้นแบบแบบถาวรสามารถอธิบายความแปรปรวนได้ 5%, $R_t^{2(f)} = .047$

สัมประสิทธิ์การทำนาย

- โมเดลค่าความแปรปรวนแตกต่างกัน (Heteroscedastic Model) มีผลต่อการคำนวณสัมประสิทธิ์ทำนาย เพราะมีผลต่อการหาสัดส่วนความแปรปรวนคงเหลือระดับที่ 1
- Rights & Sterba (2021) แสดงให้เห็นว่า ผู้วิเคราะห์ต้องหาค่าเฉลี่ยความแปรปรวนของทั้งกลุ่มตัวอย่าง หรือ $E(\sigma_i^2)$ เพื่อใส่เข้าไปในสูตรการคำนวณสัมประสิทธิ์การทำนาย ซึ่งค่อนข้างซับซ้อน

สัมประสิทธิ์การจำหน่าย

- คำแนะนำของผม คือ คำนวณค่าคาดหวังของความแปรปรวนจากทุกๆ หน่วยของตัวอย่างที่ 1 แล้วมาหารเฉลี่ยจากทั้งกลุ่มตัวอย่าง จะเป็นวิธีประมาณค่าที่ง่ายที่สุด
- ตัวอย่างโมเดลที่ 3 โมเดลที่ไม่มีความสัมพันธ์ในตัว และความแปรปรวนแตกต่างกันในแต่ละช่วงเวลา

```

> out5b <- lme(mem ~ 1 + timec + diffstress + avestress,
+             random = ~1 + timec|pid,
+             data=dat5, method="ML", na.action=na.omit,
+             weights=varIdent(form = ~1|timec))
> sumout5b <- summary(out5b)
>
> out5bsigma <- out5b$sigma
> out5bsigmatime <- out5bsigma * coef(out5b$modelStruct$varStruct, uncons = FALSE)
> out5berrvar <- c(out5bsigma, out5bsigmatime)^2   หาค่าความแปรปรวนของค่าคงเหลือทุกช่วงเวลา
> out5berrvar <- cbind(1:4, out5berrvar)   สร้างเป็นตาราง
>
> matchindex5 <- match(dat5$time, out5berrvar[,1])
> dat5$vare <- out5berrvar[matchindex5, 2]
> aveerrvar5b <- mean(dat5$vare)

```

หาค่าเฉลี่ยจากทุกแถว

เอาตารางความแปรปรวนของแต่ละช่วงเวลา
ไปจับคู่กับเวลาในแต่ละแถว แล้วนำความ
แปรปรวนมาใส่ในคอลัมน์ใหม่

```

> r2mlm::r2mlm_long_manual(data=dat5,
+                           covs=c("timec", "diffstress", "avestress"),
+                           random_covs=c("timec"),
+                           gammas=coef(sumout5b)[-1, "value"],
+                           clusterID="pid",
+                           Tau=getVarCov(out5b),
+                           sigma2=aveerrvar5b)
$Decompositions
fixed slopes (within) 0.0458638418328702 within 0.192808967631146 between NA
fixed slopes (between) 0.00290159730400247 NA 0.00380723060820706
slope variation (within) 0.121262016573532 0.509778581428324 NA
slope variation (between) 0 NA 0
intercept variation (between) 0.759226469681916 NA 0.996192769391793
residual (within) 0.0707460746076797 0.29741245094053 NA

```

แบ่งความแปรปรวนออกเป็นส่วนต่างๆ

```

$R2s
total within between
f1 0.0458638418328702 0.192808967631146 NA
f2 0.00290159730400247 NA 0.00380723060820706
v1 0.121262016573532 0.509778581428324 NA
v2 0 NA 0
m 0.759226469681916 NA 0.996192769391793
f 0.0487654391368726 NA NA
fv 0.170027455710405 0.70258754905947 0.00380723060820706
fvm 0.92925392539232 NA NA

```

ผลของ R^2 ที่ได้

$$R_t^2(f_1) = .046$$

$$R_t^2(f_2) = .003$$

$$R_t^2(v_1) = .121$$

$$R_t^2(v_2) = .000$$

$$R_t^2(m) = .759$$

ตัวแปรต้นทั้งหมดโดยกำหนดให้ความเข้มข้นแบบแบบถาวรสามารถอธิบายความแปรปรวนได้ 5%, $R_t^2(f) = .046$

สัมประสิทธิ์การทำนาย

- สำหรับโมเดลที่มีทั้ง AR(1) และความแปรปรวนแตกต่างกันในแต่ละช่วงเวลา จะซับซ้อน เนื่องจากเราไม่สามารถหาได้ว่า ความแปรปรวน ณ เวลาก่อนหน้าเท่ากับความแปรปรวนเวลาปัจจุบัน

$$\text{Var}(e_{tj}) = \rho^2 \text{Var}(e_{t-1,j}) + \text{Var}(r_{tj})$$

- ดังนั้น เราไม่สามารถหา $\text{Var}(e_{tj})$ ณ จุดเริ่มต้นได้เลย เพราะเราไม่ทราบ $\text{Var}(e_{t-1,j})$ หรือ ความแปรปรวนค่าคงเหลือ ณ เวลาก่อนหน้า เนื่องจากไม่ได้วัด
 - ดังนั้น สิ่งที่เราทำได้ จึงเป็นการเดาว่า เวลาก่อนจุดเริ่มต้น มีความแปรปรวนเท่ากับจุดเริ่มต้น

สัมประสิทธิ์การทำนาย

- จากการหามาแบบนี้ ทำให้

$$\text{Var}(e_1) = \frac{\sigma_1^2}{1 - \rho^2}$$

- ส่งผลให้

$$\text{Var}(e_2) = \rho^2 \text{Var}(e_1) + \sigma_2^2$$

$$\text{Var}(e_3) = \rho^2 \text{Var}(e_2) + \sigma_3^2$$

$$\text{Var}(e_t) = \rho^2 \text{Var}(e_{t-1}) + \sigma_t^2$$

- เมื่อได้แบบนี้แล้วให้นำค่าคาดหวังไปใส่ในทุกหน่วยของกลุ่มตัวอย่าง เพื่อหาค่าเฉลี่ย หา $E(\sigma^2)$

สัมประสิทธิ์การทำนาย

- ตัวอย่างโมเดลที่ 4 โมเดล AR(1) และความแปรปรวนแตกต่างกันในแต่ละช่วงเวลา


```

> out5g <- lme(mem ~ 1 + timec + diffstress + avestress,
+           random = ~1 + timec|pid,
+           data=dat5, method="ML", na.action=na.omit,
+           weights=varIdent(form = ~1|timec),
+           correlation=corARMA(form = ~ 1 + timec | pid, p = 1))
> sumout5g <- summary(out5g)
>
> ar1 <- coef(out5g$modelStruct$corStruct, uncons = FALSE)
> sdratio <- coef(out5g$modelStruct$varStruct, uncons = FALSE)
> out5gsigmatime <- out5g$sigma * sdratio
> out5gerrvar <- c(out5gsigma, out5gsigmatime)^2   หา  $Var(r_t)$  ทุกช่วงเวลา
>
> errvar1g <- out5gerrvar[1] / (1 - ar1^2)   หา  $Var(e_1)$ 
> errvar2g <- (ar1^2)*errvar1g + out5gerrvar[2]
> errvar3g <- (ar1^2)*errvar2g + out5gerrvar[3]
> errvar4g <- (ar1^2)*errvar3g + out5gerrvar[4]   }   หา  $Var(e_2), Var(e_3), Var(e_4)$ 
>
> out5gerrvar <- cbind(1:4, c(errvar1g, errvar2g, errvar3g, errvar4g))   สร้างเป็นตาราง
>
> matchindex5 <- match(dat5$time, out5gerrvar[,1])   }   เอาตารางความแปรปรวนของแต่ละช่วงเวลา
> dat5$varg <- out5gerrvar[matchindex5, 2]           }   ไปจับคู่กับเวลาในแต่ละแถว แล้วนำความ
> aveerrvar5g <- mean(dat5$varg)                   }   แปรปรวนมาใส่ในคอลัมน์ใหม่

```

หาค่าเฉลี่ยจากทุกแถว

```

> r2mlm::r2mlm_long_manual(data=dat5,
+                           covs=c("timec", "diffstress", "avestress"),
+                           random_covs=c("timec"),
+                           gammas=coef(sumout5g)[-1, "value"],
+                           clusterID="pid",
+                           Tau=getVarCov(out5g),
+                           sigma2=aveerrvar5g)
$Decompositions

```

	total	within	between
fixed slopes (within)	0.0457801518487724	0.175599608528289	NA
fixed slopes (between)	0.00317538573831712	NA	0.00429516889715021
slope variation (within)	0.116899028145694	0.448391338838945	NA
slope variation (between)	0	NA	0
intercept variation (between)	0.736117017972268	NA	0.99570483110285
residual (within)	0.0980284162949485	0.376009052632766	NA

แบ่งความแปรปรวนออกเป็นส่วนต่างๆ

$$R_t^{2(f_1)} = .046$$

$$R_t^{2(f_2)} = .003$$

$$R_t^{2(v_1)} = .117$$

$$R_t^{2(v_2)} = .000$$

$$R_t^{2(m)} = .736$$

```

$R2s

```

	total	within	between
f1	0.0457801518487724	0.175599608528289	NA
f2	0.00317538573831712	NA	0.00429516889715021
v1	0.116899028145694	0.448391338838945	NA
v2	0	NA	0
m	0.736117017972268	NA	0.99570483110285
f	0.0489555375870895	NA	NA
fv	0.165854565732783	0.623990947367234	0.00429516889715021
fvm	0.901971583705051	NA	NA

ผลของ R^2 ที่ได้

ตัวแปรต้นทั้งหมดโดยกำหนดให้ความซับซ้อนแบบแบบถาวรสามารถอธิบายความแปรปรวนได้ 5%, $R_t^{2(f)} = .046$

สัมประสิทธิ์การทำนาย

- จากตัวอย่างโมเดลที่ 1 ถึง 4 ตัวแปรความเครียดและตัวแปรเวลา สามารถอธิบายความแปรปรวนได้ประมาณ 5% เมื่อให้ขนาดอิทธิพลคงที่
- หากดูภายในแต่ละบุคคล ค่าเบี่ยงเบนความเครียดและตัวแปรเวลา สามารถอธิบายความแปรปรวนของการเปลี่ยนแปลงภายในบุคคลได้ $R_w^{2(fv)} = 62\%$
- ความแปรปรวนส่วนใหญ่ เป็นความแตกต่างระหว่างบุคคล (m)
- แม้โมเดลที่ 1 ถึง 4 ดูแล้วค่าไม่ค่อยแตกต่างกัน แต่อาจเป็นเฉพาะตัวอย่างนี้ ตัวอย่างอื่นอาจมีค่าแตกต่างกัน

คาบต่อไป

- โมเดล 3 ระดับและโมเดลข้อมูลเชิงซ้อนแบบอื่น
- การบ้านที่ 9