7. Regressionsergebnisse professionell aufbereiten

Annotierte Streudiagramme mit R^2, Regressionsgleichung und Mittelwertlinien

Dr. Paul Schmidt

Wer die Grundlagen der linearen Regression verstanden hat, steht oft vor der nächsten Frage: Wie bereite ich die Ergebnisse professionell auf? In Berichten und Publikationen sieht man häufig Streudiagramme, die weit über einen einfachen Punkteplot hinausgehen – mit Regressionsgerade, R^2-Wert, Mittelwertlinien und beschrifteten Datenpunkten.

Dieses Kapitel zeigt Schritt für Schritt, wie solche Grafiken in R erstellt werden. Wir extrahieren die relevanten Kennzahlen aus dem Regressionsmodell und bauen daraus einen publikationsreifen Plot.

Pakete laden

Um alle in diesem Kapitel verwendeten Pakete zu installieren und zu laden, führt man folgenden Code aus:

```
# Pakete installieren (nur notwendig, falls noch nicht installiert)
for (pkg in c("broom", "ggrepel", "lubridate", "scales", "tidyverse")) {
  if (!require(pkg, character.only = TRUE)) install.packages(pkg)
}

# Pakete laden
library(broom)
library(ggrepel)
library(lubridate)
library(scales)
library(tidyverse)
```

Beispieldaten

Als Beispiel verwenden wir (synthetische) Regionaldaten zur Arbeitslosenquote in den 53 Kreisen und kreisfreien Städten Nordrhein-Westfalens.

```
set.seed(42)

# Echte Namen der 53 Kreise und kreisfreien Städte in NRW
kreis_namen <- c(
  "Düsseldorf", "Duisburg", "Essen", "Krefeld", "Mönchengladbach",
  "Mülheim an der Ruhr", "Oberhausen", "Remscheid", "Solingen", "Wuppertal",
  "Kleve", "Mettmann", "Rhein-Kreis Neuss", "Viersen", "Wesel",
  "Bonn", "Köln", "Leverkusen", "Städteregion Aachen", "Düren",
  "Rhein-Erft-Kreis", "Euskirchen", "Heinsberg", "Oberbergischer Kreis",
  "Rheinisch-Bergischer Kreis", "Rhein-Sieg-Kreis", "Bottrop", "Gelsenkirchen",
  "Münster", "Borken", "Coesfeld", "Recklinghausen", "Steinfurt", "Warendorf",
  "Bielefeld", "Gütersloh", "Herford", "Höxter", "Lippe", "Minden-Lübbecke",
  "Paderborn", "Bochum", "Dortmund", "Hagen", "Hamm", "Herne",
  "Ennepe-Ruhr-Kreis", "Märkischer Kreis", "Olpe", "Siegen-Wittgenstein",
  "Soest", "Unna", "Hochsauerlandkreis"
)
```

```
n <- length(kreis_namen)

# Hilfsvektoren für differenzierte Quoten
staedte_hoch <- c("Gelsenkirchen", "Essen", "Duisburg", "Herne", "Dortmund")
kreise_niedrig <- c("Borken", "Coesfeld", "Höxter", "Olpe")

# Synthetische Daten mit realistischen Zusammenhängen
dat <- tibble(
  kreis = kreis_namen,
  # Basis-Zufallswerte
  alo_quote = runif(n, 4, 9)
) %>%
  mutate(
    # Arbeitslosenquote: differenziert nach Kreistyp
    alo_quote = case_when(
      kreis %in% staedte_hoch ~ runif(n(), 10, 14),
      kreis %in% kreise_niedrig ~ runif(n(), 2, 4),
      TRUE ~ alo_quote
    ),
    # Veränderung 2015-2023: korreliert positiv mit Quote
    alo_veraenderung = -20 + 2.5 * alo_quote + rnorm(n(), 0, 8),
    # Bruttolohn-Veränderung: 15-40%
    bruttolohn_veraenderung = runif(n(), 15, 40),
    # Bevölkerungsveränderung: korreliert negativ mit Lohnentwicklung
    bevoelkerung_veraenderung = 5 - 0.3 * bruttolohn_veraenderung + rnorm(n(), 0,
3)
  ) %>%
  arrange(kreis)

dat
```

```
# A tibble: 53 × 5
   kreis       alo_quote alo_veraenderung bruttolohn_veraenderung
   <chr>           <dbl>            <dbl>                   <dbl>
 1 Bielefeld        4.02           -17.1                    15.8
 2 Bochum           6.18            -3.32                   24.8
 3 Bonn             8.70            -2.73                   26.6
 4 Borken           3.16           -15.1                    23.3
 5 Bottrop          5.95            -2.04                   33.3
 6 Coesfeld         3.64            -0.964                  17.2
 7 Dortmund        12.9              5.93                   19.0
 8 Duisburg        10.2              6.40                   36.7
 9 Düren            6.80           -12.7                    23.2
10 Düsseldorf       8.57             5.18                   18.4
# i 43 more rows
# i 1 more variable: bevoelkerung_veraenderung <dbl>
```

Datenaufbereitung

Kategorien bilden mit `cut()`

Die Funktion `cut()` teilt eine kontinuierliche Variable in Kategorien auf. Das ist nützlich, um z.B. Quoten in Gruppen wie “niedrig”, “mittel”, “hoch” einzuteilen.

```
dat <- dat %>%
  mutate(
    quote_kategorie = cut(
      alo_quote,
      breaks = c(0, 4, 7, 10, Inf),
      labels = c("niedrig (<4%)", "mittel (4-7%)", "erhöht (7-10%)", "hoch
(>10%)"),
      right = FALSE
```

```
    )
  )

# Verteilung der Kategorien
dat %>%
  count(quote_kategorie)
```

```
# A tibble: 4 × 2
  quote_kategorie     n
  <fct>           <int>
1 niedrig (<4%)       4
2 mittel (4-7%)      22
3 erhöht (7-10%)     22
4 hoch (>10%)         5
```

Der Parameter `right = FALSE` bedeutet, dass die Intervalle links geschlossen sind: `[0, 4)` enthält 0, aber nicht 4. Mit `labels` vergeben wir aussagekräftige Namen für die Kategorien.

Datumsdifferenzen mit lubridate

Für Analysen über Zeiträume müssen häufig Differenzen zwischen Datumsangaben berechnet werden. Das Paket `lubridate` macht dies einfach.

```
# Beispiel: Beobachtungszeitraum
dat <- dat %>%
  mutate(
    datum_start = ymd("2015-01-01"),
    datum_ende = ymd("2023-12-31"),
    # Differenz in Tagen
    tage = as.numeric(datum_ende - datum_start),
    # Differenz in Jahren (exakt)
    jahre = interval(datum_start, datum_ende) / years(1)
  )

# Ergebnis prüfen
dat %>%
  select(kreis, datum_start, datum_ende, tage, jahre) %>%
  head(3)
```

```
# A tibble: 3 × 5
  kreis     datum_start datum_ende  tage jahre
  <chr>     <date>      <date>     <dbl> <dbl>
1 Bielefeld 2015-01-01  2023-12-31  3286  9.00
2 Bochum    2015-01-01  2023-12-31  3286  9.00
3 Bonn      2015-01-01  2023-12-31  3286  9.00
```

Die Funktion `interval()` erzeugt ein Zeitintervall, das wir dann durch `years(1)` teilen, um die exakte Anzahl der Jahre zu erhalten. Für einfache Differenzen in Tagen reicht die Subtraktion mit anschließender Umwandlung via `as.numeric()`.

Lineare Regression

Bevor wir die Daten visualisieren, passen wir das Regressionsmodell an. Die Ergebnisse – insbesondere Steigung, Achsenabschnitt und R^2 – benötigen wir später für den Plot.

Modell anpassen

```
# Einfache lineare Regression:
# Wie hängt die Veränderung der Quote mit der aktuellen Höhe zusammen?
```

```r
mod <- lm(alo_veraenderung ~ alo_quote, data = dat)

# Zusammenfassung
summary(mod)
```

```
Call:
lm(formula = alo_veraenderung ~ alo_quote, data = dat)

Residuals:
    Min      1Q  Median      3Q     Max
-16.378  -6.249   0.163   5.930  14.790

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -20.2319     3.2374  -6.249 8.32e-08 ***
alo_quote     2.4302     0.4329   5.614 8.19e-07 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 7.31 on 51 degrees of freedom
Multiple R-squared:  0.382, Adjusted R-squared:  0.3698
F-statistic: 31.52 on 1 and 51 DF,  p-value: 8.194e-07
```

Ergebnisse extrahieren mit broom

Das Paket `broom` bietet drei zentrale Funktionen, um Modellausgaben in ordentliche Tibbles zu überführen:

```r
# Koeffizienten mit Standardfehlern und p-Werten
tidy(mod)
```

```
# A tibble: 2 × 5
  term        estimate std.error statistic      p.value
  <chr>          <dbl>     <dbl>     <dbl>        <dbl>
1 (Intercept)   -20.2      3.24      -6.25 0.0000000832
2 alo_quote       2.43     0.433      5.61 0.000000819
```

```r
# Modellgüte: R², adjustiertes R², F-Statistik, etc.
glance(mod)
```

```
# A tibble: 1 × 12
  r.squared adj.r.squared sigma statistic     p.value    df logLik   AIC   BIC
      <dbl>         <dbl> <dbl>     <dbl>       <dbl> <dbl>  <dbl> <dbl> <dbl>
1     0.382         0.370  7.31      31.5 0.000000819     1  -180.  365.  371.
# i 3 more variables: deviance <dbl>, df.residual <int>, nobs <int>
```

```r
# Vorhersagewerte und Residuen für jede Beobachtung
augment(mod) %>%
  head()
```

```
# A tibble: 6 × 8
  alo_veraenderung alo_quote .fitted .resid   .hat .sigma  .cooksd .std.resid
             <dbl>     <dbl>   <dbl>  <dbl>  <dbl>  <dbl>    <dbl>      <dbl>
1          -17.1        4.02 -10.5    -6.65 0.0524   7.32 0.0241       -0.934
2           -3.32       6.18  -5.22    1.90 0.0219   7.38 0.000774      0.263
3           -2.73       8.70   0.911  -3.64 0.0277   7.36 0.00364      -0.505
4          -15.1        3.16 -12.6    -2.56 0.0736   7.37 0.00525      -0.364
5           -2.04       5.95  -5.77    3.73 0.0236   7.36 0.00321       0.516
6           -0.964      3.64 -11.4    10.4  0.0610   7.22 0.0703        1.47
```

Werte für die Visualisierung speichern

Für den Plot benötigen wir den Achsenabschnitt, die Steigung und das R^2:

```
# Achsenabschnitt und Steigung für geom_abline()
intercept <- coef(mod)[1]
slope <- coef(mod)[2]

# R² für die Annotation
r_squared <- glance(mod)$r.squared

# Werte ausgeben
glue::glue("Achsenabschnitt (a): {scales::number(intercept, accuracy = 0.01,
decimal.mark = ',')}")
```

```
Achsenabschnitt (a): -20,23
```

```
glue::glue("Steigung (b): {scales::number(slope, accuracy = 0.001, decimal.mark =
',')}")
```

```
Steigung (b): 2,430
```

```
glue::glue("R²: {scales::number(r_squared, accuracy = 0.001, decimal.mark = ',')}")
```

```
R²: 0,382
```

Vorhersagewerte berechnen

Mit `predict()` können wir Vorhersagen für beliebige x-Werte erhalten:

```
# Vorhersage für bestimmte Arbeitslosenquoten
neue_werte <- tibble(alo_quote = c(3, 6, 9, 12))

neue_werte %>%
  mutate(
    vorhergesagt = predict(mod, newdata = neue_werte)
  )
```

```
# A tibble: 4 × 2
  alo_quote vorhergesagt
      <dbl>        <dbl>
1         3       -12.9
2         6        -5.65
3         9         1.64
4        12         8.93
```

Alternativ fügt `augment()` die Vorhersagewerte direkt an den Originaldatensatz an (Spalte `.fitted`).

Annotierte Streudiagramme

Nun erstellen wir Schritt für Schritt einen publikationsreifen Plot mit allen relevanten Annotationen.

Basis-Streudiagramm

Der Grundplot zeigt die Beziehung zwischen der Arbeitslosenquote (x-Achse) und deren Veränderung über die Zeit (y-Achse):

```
p <- ggplot(dat, aes(x = alo_quote, y = alo_veraenderung)) +
  geom_point(color = "#00923f", size = 3) +
  labs(
    x = "Arbeitslosenquote 2023 in %",
    y = "Veränderung der Arbeitslosenquote 2015-2023 in %"
  ) +
  theme_minimal()

p
```

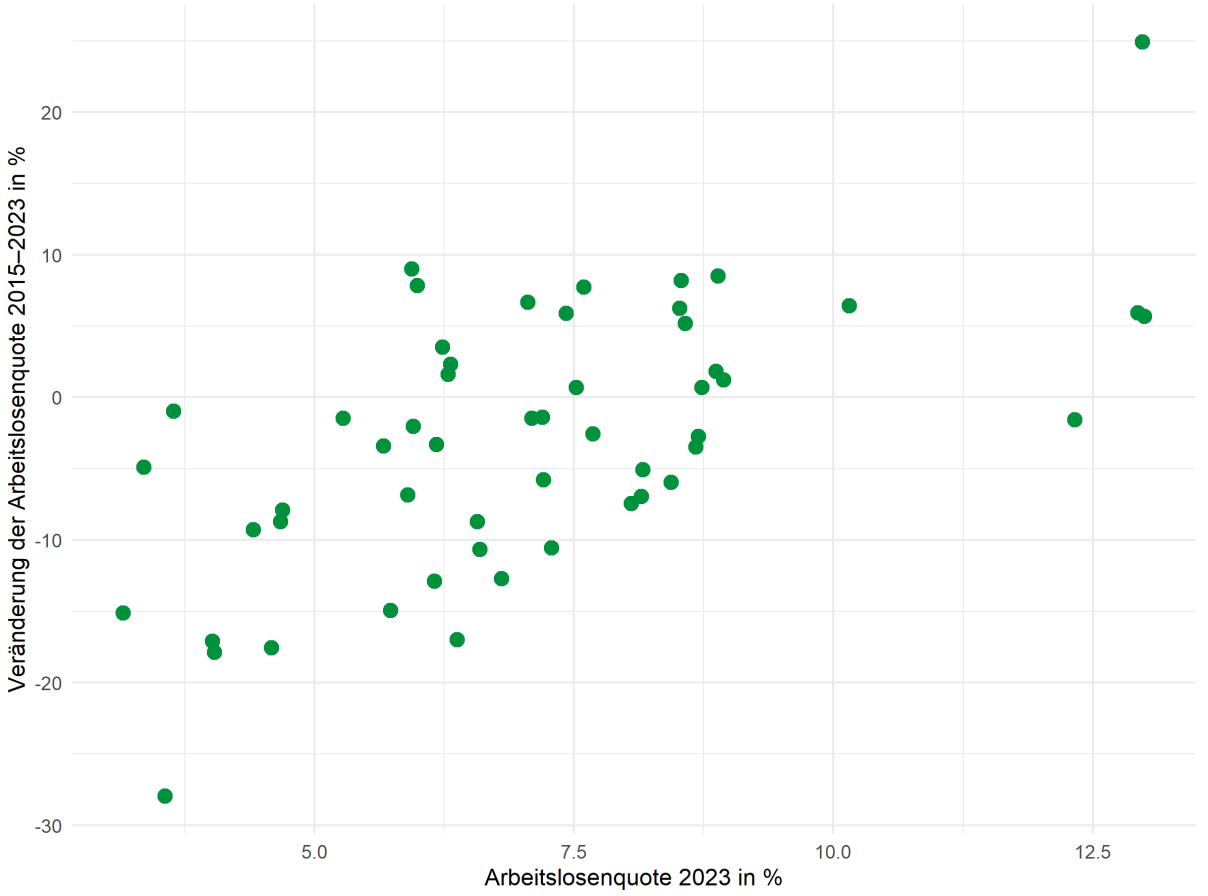

Punktbeschriftungen mit ggrepel

Das Paket `ggrepel` positioniert Beschriftungen automatisch so, dass sie sich nicht überlappen:

```
p <- p +
  geom_text_repel(
    aes(label = kreis),
    size = 2.5,
    max.overlaps = 20,
    segment.color = "grey50",
    segment.size = 0.3
  )

p
```

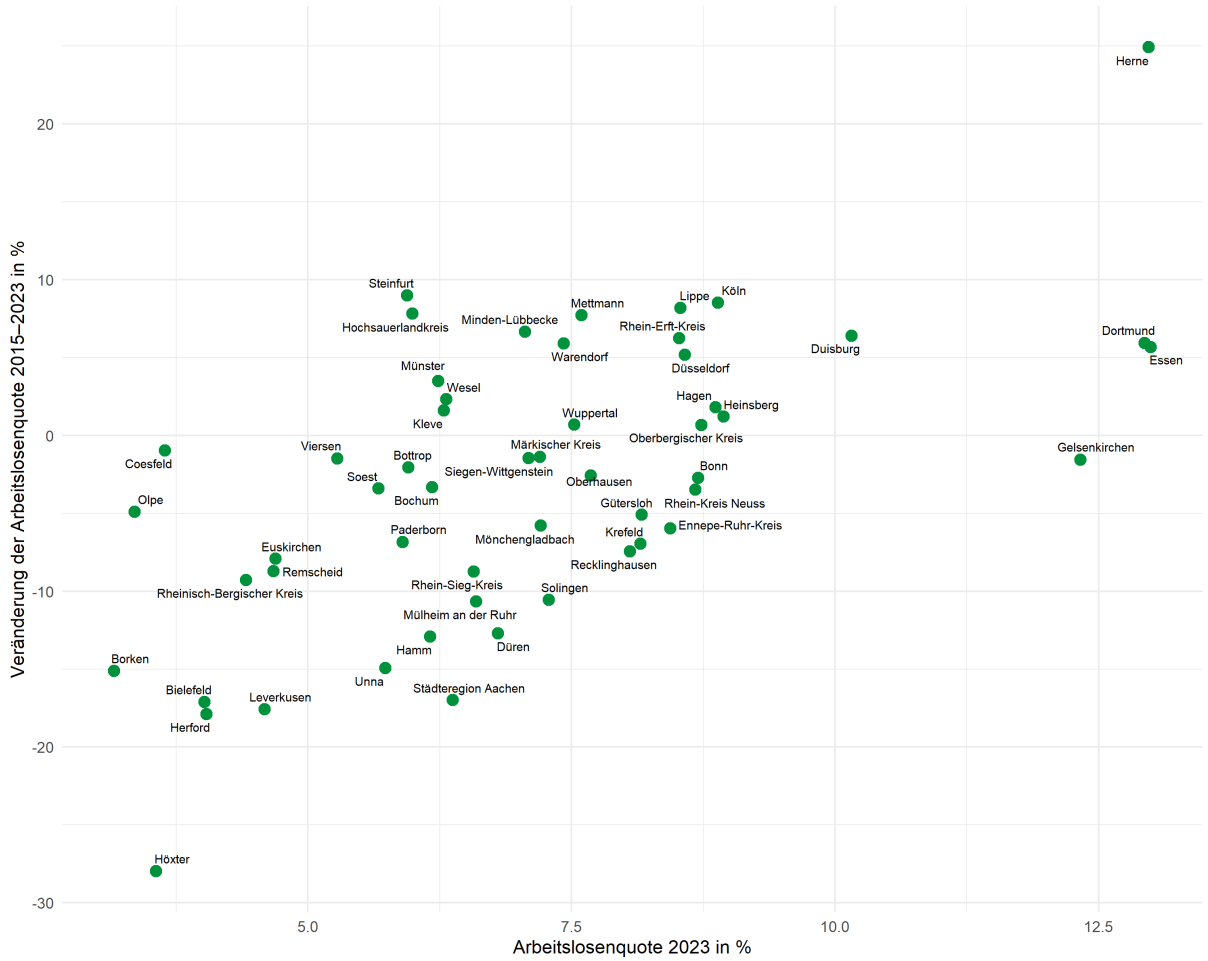

Der Parameter `max.overlaps` steuert, wie viele Überlappungen toleriert werden – bei vielen Punkten muss dieser Wert erhöht werden, damit alle Beschriftungen angezeigt werden.

Mittelwertlinien

Gestrichelte Linien markieren die Mittelwerte beider Variablen und teilen den Plot in vier Quadranten:

```
# Mittelwerte berechnen
mean_x <- mean(dat$alo_quote)
mean_y <- mean(dat$alo_veraenderung)

p <- p +
  geom_hline(yintercept = mean_y, linetype = "dashed", color = "grey40") +
  geom_vline(xintercept = mean_x, linetype = "dashed", color = "grey40")

p
```

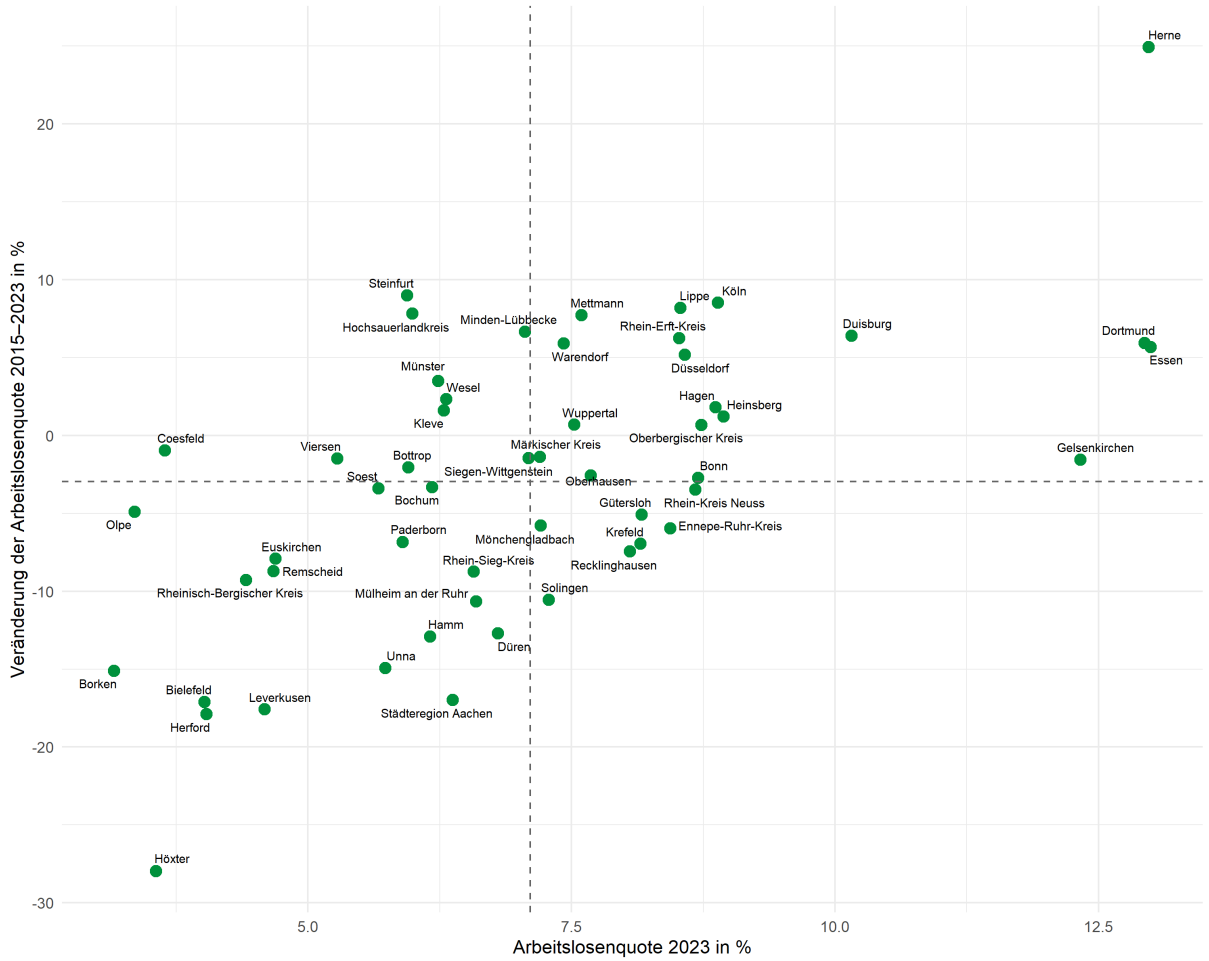

Regressionsgerade

Anstatt `geom_smooth()` verwenden wir `geom_abline()` mit den zuvor extrahierten Koeffizienten. So haben wir volle Kontrolle über die dargestellte Gerade:

```
p <- p +
  geom_abline(
    intercept = intercept,
    slope = slope,
    color = "#E31937",
    linewidth = 0.8
  )

p
```

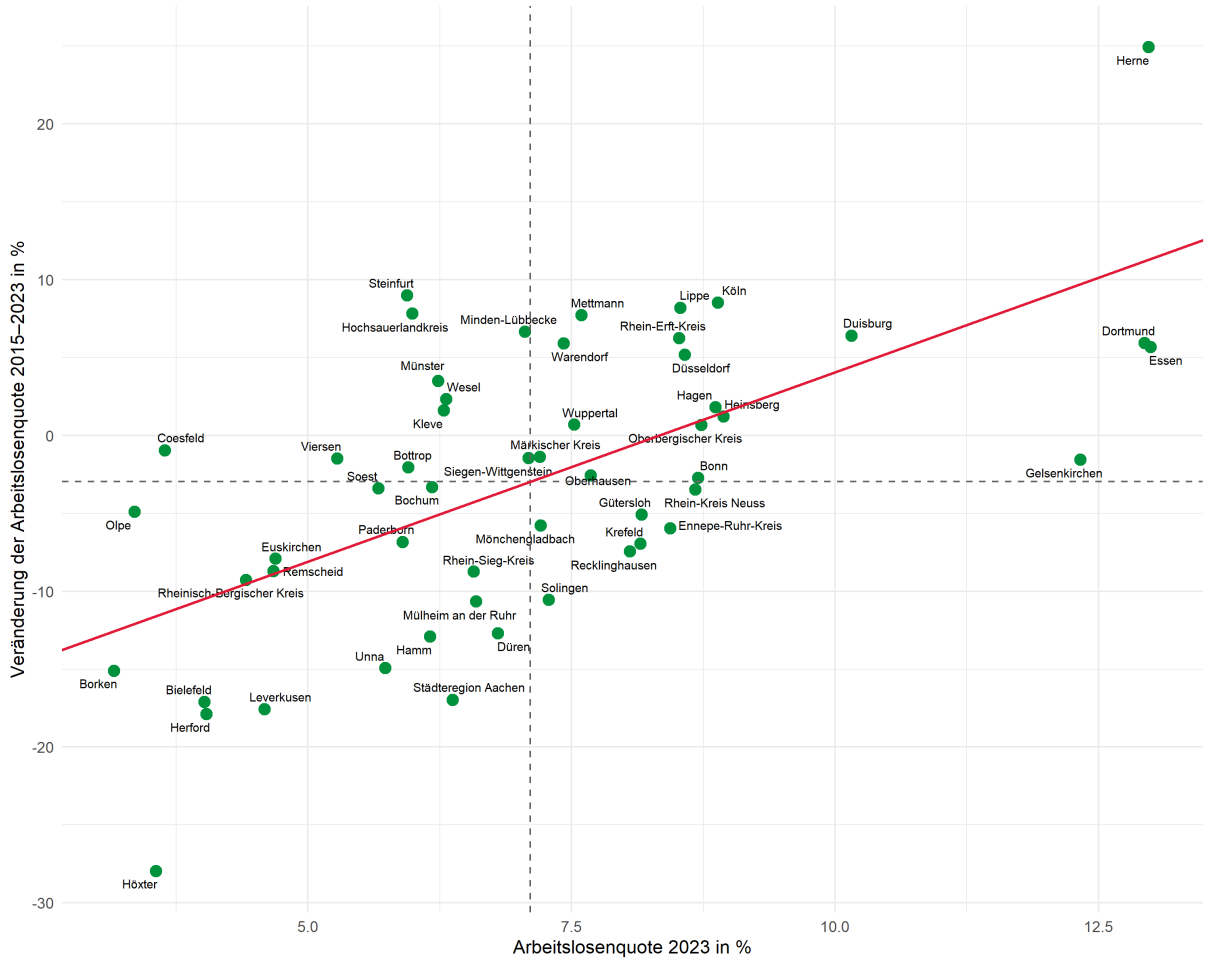

R2-Annotation

Die R²-Annotation platzieren wir mit `annotate()`. Die Position wählen wir manuell, passend zum Datenbereich:

```
# R² formatiert mit deutschem Dezimaltrennzeichen
r2_label <- glue::glue("R² = {scales::number(r_squared, accuracy = 0.001,
decimal.mark = ',')}")

p <- p +
  annotate(
    "text",
    x = min(dat$alo_quote) + 0.5,
    y = max(dat$alo_veraenderung) - 2,
    label = r2_label,
    hjust = 0,
    size = 3.5,
    color = "#E31937"
  )

p
```

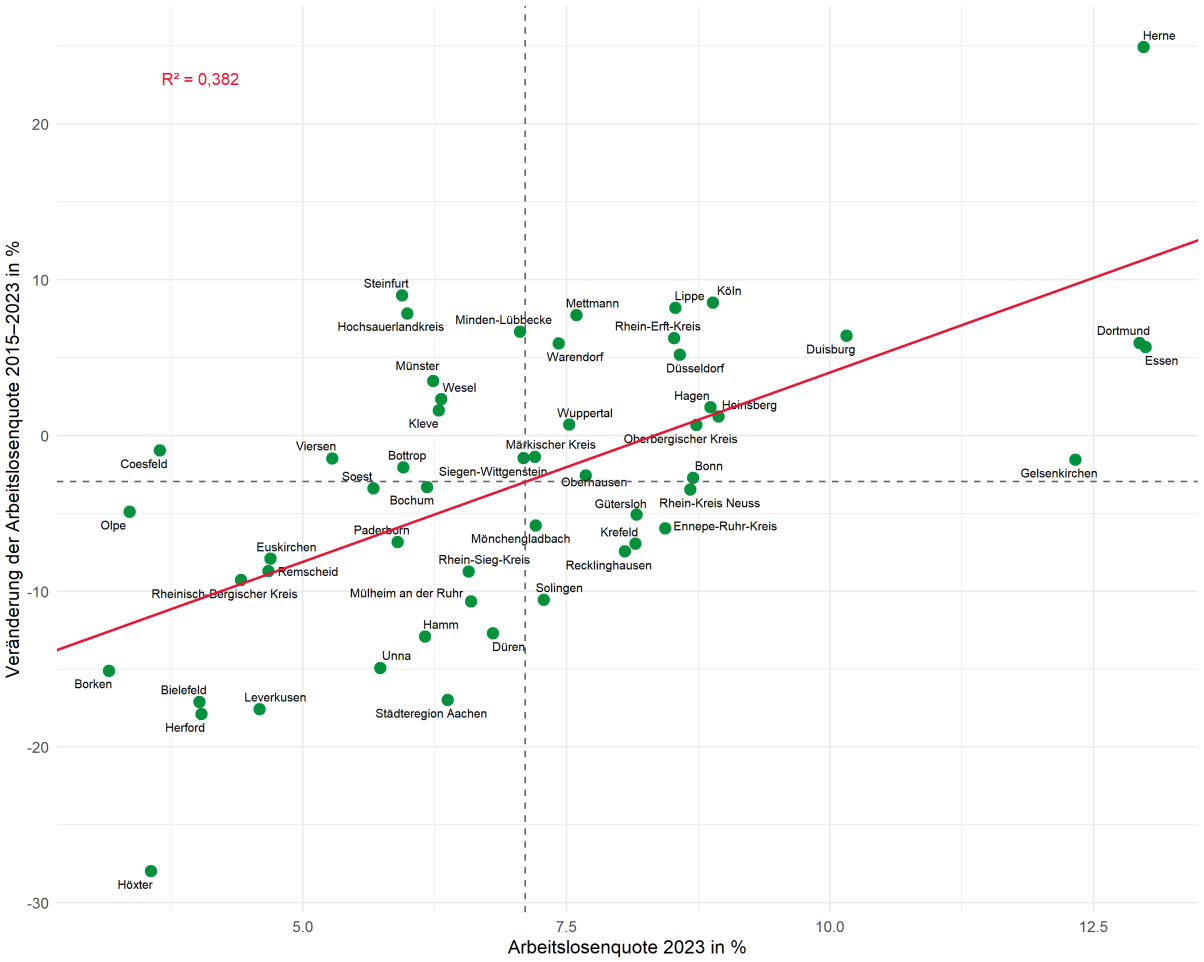

Vollständiger Plot

Hier der komplette Code für den fertigen Plot:

```
# Mittelwerte und Regressionsparameter
mean_x <- mean(dat$alo_quote)
mean_y <- mean(dat$alo_veraenderung)
r2_label <- glue::glue("R² = {scales::number(r_squared, accuracy = 0.001,
decimal.mark = ',')}")

ggplot(dat, aes(x = alo_quote, y = alo_veraenderung)) +
  # Punkte
  geom_point(color = "#00923f", size = 3) +
  # Beschriftungen
  geom_text_repel(
    aes(label = kreis),
    size = 2.5,
    max.overlaps = 25,
    segment.color = "grey50",
    segment.size = 0.3
  ) +
  # Mittelwertlinien
  geom_hline(yintercept = mean_y, linetype = "dashed", color = "grey40") +
  geom_vline(xintercept = mean_x, linetype = "dashed", color = "grey40") +
  # Regressionsgerade
  geom_abline(
    intercept = intercept,
    slope = slope,
    color = "#E31937",
    linewidth = 0.8
  ) +
  # R²-Annotation
```

```
  annotate(
    "text",
    x = min(dat$alo_quote) + 0.5,
    y = max(dat$alo_veraenderung) - 2,
    label = r2_label,
    hjust = 0,
    size = 3.5,
    color = "#E31937"
  ) +
  # Achsenbeschriftungen
  labs(
    x = "Arbeitslosenquote 2023 in %",
    y = "Veränderung der Arbeitslosenquote 2015-2023 in %"
  ) +
  theme_minimal(base_size = 11)
```

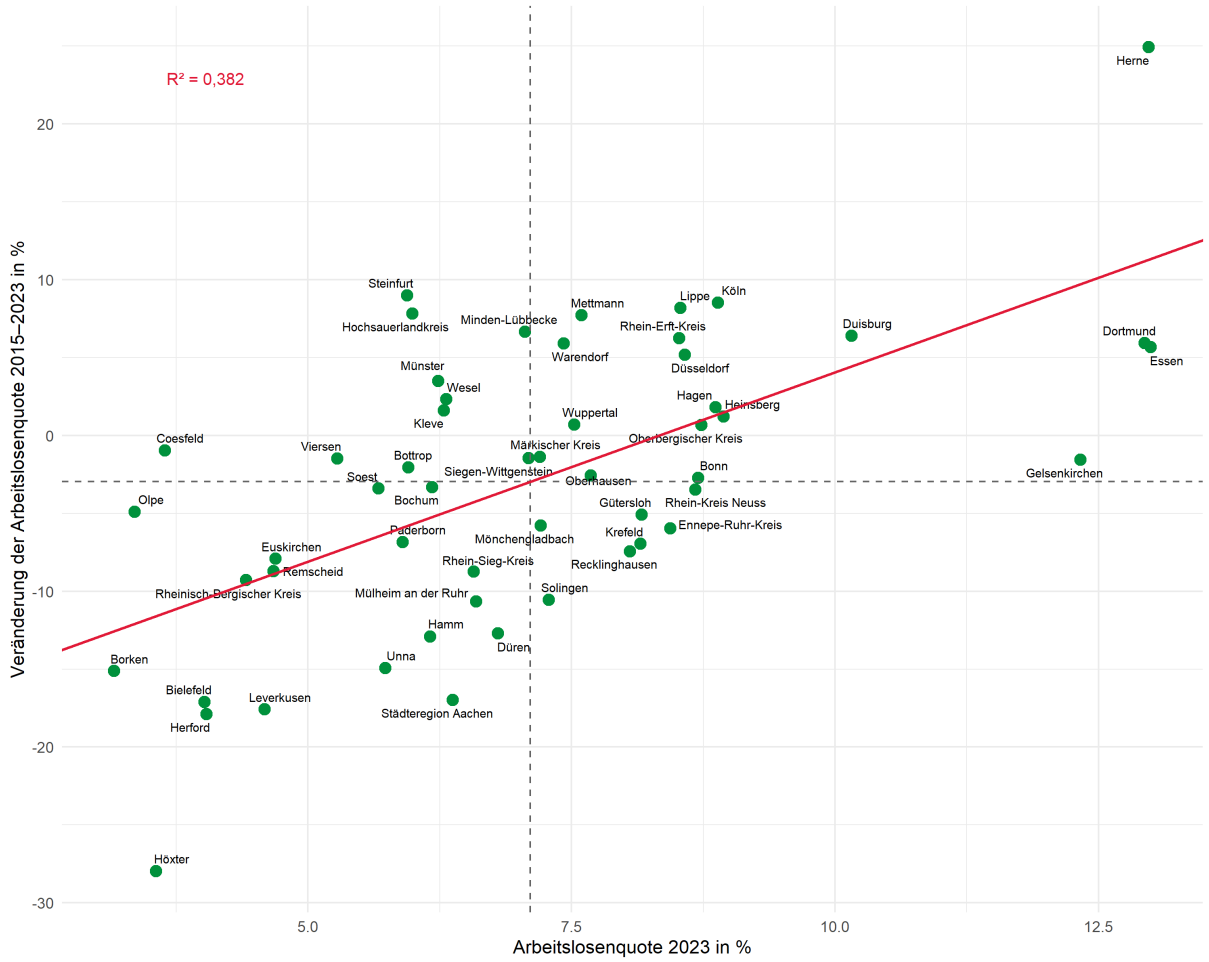

Zweites Beispiel: Lohnentwicklung und Bevölkerung

Der gleiche Workflow lässt sich auf andere Fragestellungen anwenden. Hier untersuchen wir den Zusammenhang zwischen der Bruttolohnentwicklung und der Bevölkerungsveränderung:

```
# Regression anpassen
mod2 <- lm(bevoelkerung_veraenderung ~ bruttolohn_veraenderung, data = dat)

# Werte extrahieren
intercept2 <- coef(mod2)[1]
slope2 <- coef(mod2)[2]
```

```
r_squared2 <- glance(mod2)$r.squared
r2_label2 <- glue::glue("R² = {scales::number(r_squared2, accuracy = 0.001,
decimal.mark = ',')}")

# Plot
ggplot(dat, aes(x = bruttolohn_veraenderung, y = bevoelkerung_veraenderung)) +
  geom_point(color = "#00923f", size = 3) +
  geom_text_repel(
    aes(label = kreis),
    size = 2.5,
    max.overlaps = 25,
    segment.color = "grey50"
  ) +
  geom_hline(yintercept = mean(dat$bevoelkerung_veraenderung), linetype = "dashed",
color = "grey40") +
  geom_vline(xintercept = mean(dat$bruttolohn_veraenderung), linetype = "dashed",
color = "grey40") +
  geom_abline(intercept = intercept2, slope = slope2, color = "#E31937", linewidth
= 0.8) +
  annotate(
    "text",
    x = max(dat$bruttolohn_veraenderung) - 1,
    y = max(dat$bevoelkerung_veraenderung) - 0.5,
    label = r2_label2,
    hjust = 1,
    size = 3.5,
    color = "#E31937"
  ) +
  labs(
    x = "Veränderung Bruttolohn 2015-2023 in %",
    y = "Bevölkerungsveränderung 2015-2023 in %"
  ) +
  theme_minimal(base_size = 11)
```

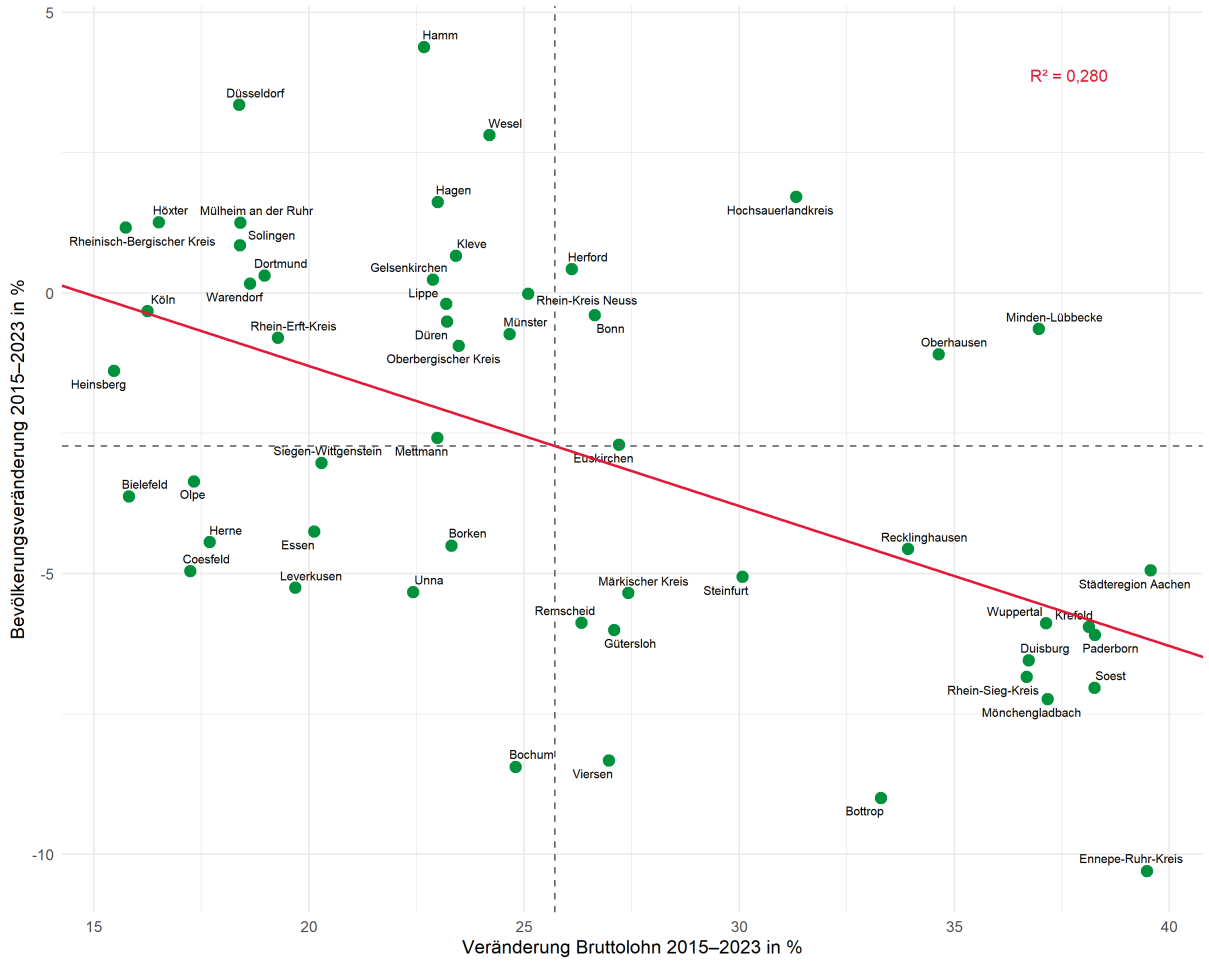

Bonus: Erweiterter Plot

In diesem Abschnitt erweitern wir den Plot um zusätzliche Elemente:

1. **Regressionsgleichung** als Annotation (in der Form y = a + bx)
2. **Mittelwerte beschriftet** an den gestrichelten Linien
3. **Selektives Labeln** – nur die extremsten Werte werden beschriftet

Regressionsgleichung erstellen

Die Regressionsgleichung bauen wir aus den extrahierten Koeffizienten zusammen:

```
# Koeffizienten formatieren
a_fmt <- scales::number(intercept, accuracy = 0.01, decimal.mark = ",")
b_fmt <- scales::number(slope, accuracy = 0.01, decimal.mark = ",")

# Vorzeichen für b berücksichtigen
vorzeichen <- if_else(slope >= 0, " + ", " - ")
b_abs <- scales::number(abs(slope), accuracy = 0.01, decimal.mark = ",")

# Regressionsgleichung zusammenbauen
formel_label <- glue::glue("y = {a_fmt}{vorzeichen}{b_abs}x")
formel_label
```

```
y = -20,23 + 2,43x
```

Selektives Labeln vorbereiten

Bei vielen Datenpunkten kann es sinnvoll sein, nur die extremsten Werte zu beschriften. Hier labeln wir alle Punkte, die auf mindestens einer Achse zu den fünf höchsten oder fünf niedrigsten gehören:

```
dat <- dat %>%
  mutate(
    # Ränge berechnen (1 = niedrigster Wert)
    rang_x = rank(alo_quote),
    rang_y = rank(alo_veraenderung),
    # Label für Extremwerte auf beiden Achsen
    label_selektiv = if_else(
      rang_x <= 5 | rang_x > n() - 5 | rang_y <= 5 | rang_y > n() - 5,
      kreis,
      NA_character_
    )
  )

# Prüfen, welche Kreise gelabelt werden
dat %>%
  filter(!is.na(label_selektiv)) %>%
  select(kreis, alo_quote, rang_x, alo_veraenderung, rang_y)
```

```
# A tibble: 17 × 5
   kreis                alo_quote rang_x alo_veraenderung rang_y
   <chr>                    <dbl>  <dbl>            <dbl>  <dbl>
 1 Bielefeld                 4.02      5           -17.1        4
 2 Borken                    3.16      1           -15.1        6
 3 Coesfeld                  3.64      4            -0.964     33
 4 Dortmund                 12.9      51             5.93      44
 5 Duisburg                 10.2      49             6.40      46
 6 Essen                    13.0      53             5.67      42
 7 Gelsenkirchen            12.3      50            -1.56      29
 8 Herford                   4.04      6           -17.9        2
 9 Herne                    13.0      52            24.9       53
10 Hochsauerlandkreis        5.99     17             7.82      49
11 Höxter                    3.56      3           -28.0        1
12 Köln                      8.89     47             8.52      51
13 Leverkusen                4.59      8           -17.6        3
14 Lippe                     8.53     41             8.19      50
15 Olpe                      3.36      2            -4.91      22
16 Steinfurt                 5.94     15             9.00      52
17 Städteregion Aachen       6.37     23           -17.0        5
```

Erweiterter Plot

Nun kombinieren wir alle Elemente:

```
# Mittelwerte berechnen
mean_x <- mean(dat$alo_quote)
mean_y <- mean(dat$alo_veraenderung)

# Labels für Mittelwerte
mean_x_label <- glue::glue("Mittelwert: {scales::number(mean_x, accuracy = 0.1,
decimal.mark = ',')}")
mean_y_label <- glue::glue("Mittelwert: {scales::number(mean_y, accuracy = 0.1,
decimal.mark = ',')}")

# R² und Formel kombiniert
reg_label <- glue::glue("{formel_label}; R² = {scales::number(r_squared, accuracy =
0.001, decimal.mark = ',')}")

ggplot(dat, aes(x = alo_quote, y = alo_veraenderung)) +
  # Punkte
```

```
  geom_point(color = "#00923f", size = 3) +
  # Selektive Beschriftungen (nur Extremwerte)
  geom_text_repel(
    aes(label = label_selektiv),
    size = 2.8,
    max.overlaps = 20,
    segment.color = "grey50",
    segment.size = 0.3,
    na.rm = TRUE
  ) +
  # Mittelwertlinien
  geom_hline(yintercept = mean_y, linetype = "dashed", color = "grey40") +
  geom_vline(xintercept = mean_x, linetype = "dashed", color = "grey40") +
  # Mittelwert-Beschriftung (x-Achse, am oberen Rand)
  annotate(
    "text",
    x = mean_x,
    y = max(dat$alo_veraenderung) + 1,
    label = mean_x_label,
    size = 2.5,
    color = "grey30"
  ) +
  # Mittelwert-Beschriftung (y-Achse, am rechten Rand)
  annotate(
    "text",
    x = max(dat$alo_quote) + 0.3,
    y = mean_y,
    label = mean_y_label,
    hjust = 0,
    size = 2.5,
    color = "grey30"
  ) +
  # Regressionsgerade
  geom_abline(
    intercept = intercept,
    slope = slope,
    color = "#E31937",
    linewidth = 0.8
  ) +
  # R² und Regressionsgleichung kombiniert
  annotate(
    "text",
    x = min(dat$alo_quote) + 0.5,
    y = max(dat$alo_veraenderung) - 1,
    label = reg_label,
    hjust = 0,
    size = 3.5,
    color = "#E31937"
  ) +
  # Achsen mit scale_x/y_continuous
  scale_x_continuous(
    name = "Arbeitslosenquote 2023 in %",
    limits = c(min(dat$alo_quote) - 0.5, max(dat$alo_quote) + 3),
    expand = c(0, 0)
  ) +
  scale_y_continuous(
    name = "Veränderung der Arbeitslosenquote 2015-2023 in %",
    limits = c(min(dat$alo_veraenderung) - 2, max(dat$alo_veraenderung) + 3),
    expand = c(0, 0)
  ) +
  theme_minimal(base_size = 11)
```

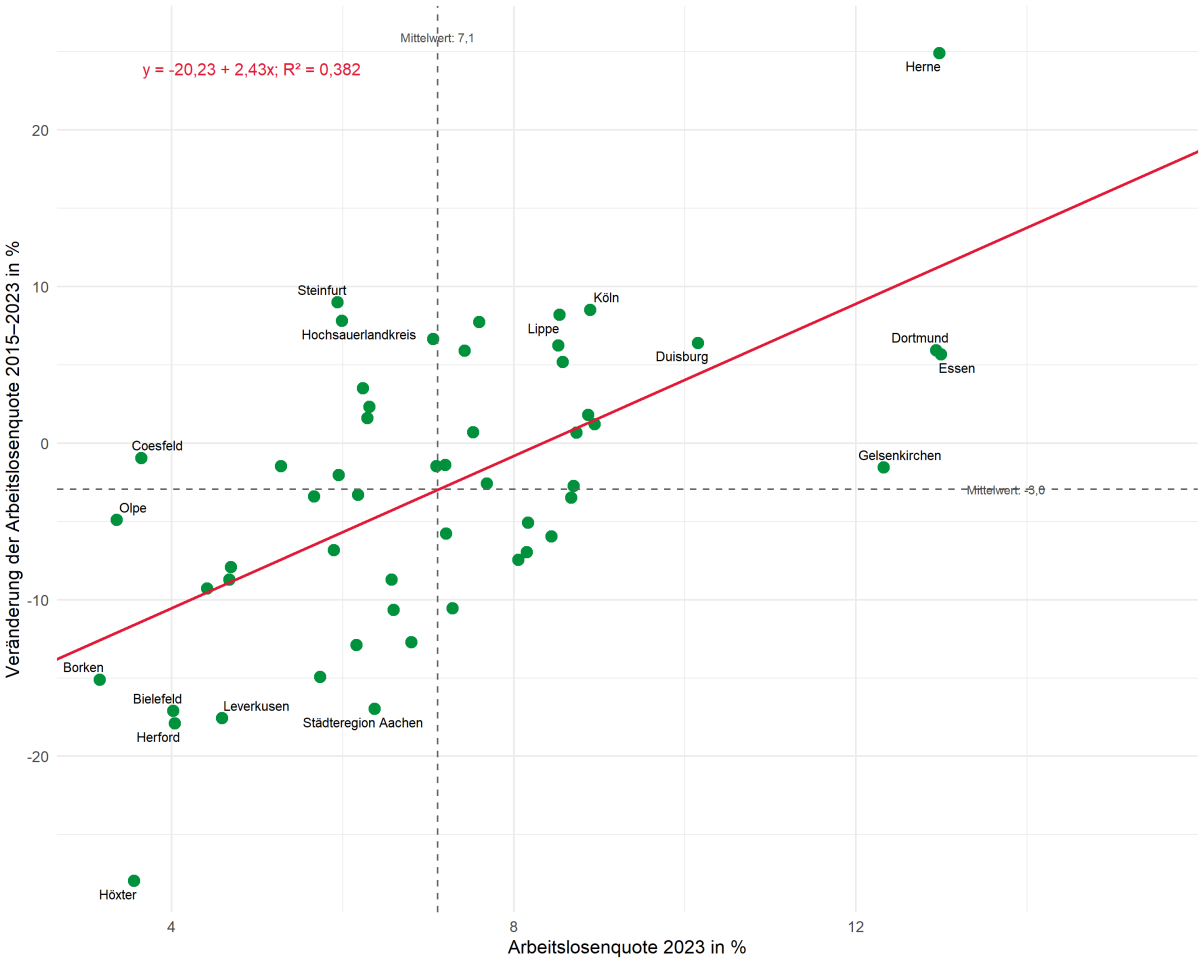

Dieser erweiterte Plot zeigt:

- **Selektives Labeln**: Nur die Extremwerte auf beiden Achsen (jeweils Top/Bottom 5) sind beschriftet – der Rest bleibt übersichtlich
- **Mittelwerte beschriftet**: Die durchschnittlichen Werte stehen direkt an den gestrichelten Linien
- **Regressionsgleichung und R²**: Beide Informationen kompakt in einer Annotation

Zusammenfassung

Der Workflow für professionell aufbereitete Regressionsplots:

1. **Modell anpassen**: `lm()` für die Regression
2. **Werte extrahieren**: `broom`-Funktionen liefern Koeffizienten, R² und Vorhersagewerte als Tibbles
3. **Plot schrittweise aufbauen**:
   - `geom_point()` für die Datenpunkte
   - `geom_text_repel()` für überlappungsfreie Beschriftungen
   - `geom_hline()` / `geom_vline()` für Mittelwertlinien
   - `geom_abline()` für die Regressionsgerade
   - `annotate()` mit `glue()` für R², Regressionsgleichung und Mittelwerte
4. **Bei Bedarf erweitern**: Selektives Labeln, Regressionsgleichung, beschriftete Mittelwerte

Bibliography