

국립국어원 맞춤법 교정 말뭉치

(버전 1.0)

- **자료명:** 국립국어원 맞춤법 교정 말뭉치
- **공개일**
 - (버전 1.0) 2022. 4. 1.
- **자료 유형:** 텍스트
- **관련 사업:** 2021년 맞춤법 교정 말뭉치 연구 분석(2021)
- **자료 설명**
 - ※ 자세한 내용은 국립국어원 누리집 > 자료 > 연구조사 자료 > '2021년 맞춤법 교정 말뭉치 연구 분석' 사업 결과보고서 참조
- **내용**
 - 메신저 대화 자료 및 누리 소통망 등에서 수집한 웹 언어 자료를 대상으로 한국어 처리 도구가 분석할 수 있는 수준으로 오타자 등을 교정한 말뭉치임.
 - 세부 교정 지침은 2021년 맞춤법 교정 말뭉치 연구 분석 사업 결과 보고서를 참고할 것. (국립국어원 누리집 > 자료 > 연구조사 자료 > '2021년 맞춤법 교정 말뭉치 연구 분석' 사업 보고서)
- **분량**
 - 약 250만 어절(메신저 대화 136만 어절, 웹 자료 114만 어절)
- **파일 형식:** JSON(UTF-8 인코딩)
- **파일 수 및 크기:** 파일 2개, 총 195MB
- **인용:**
 - (국문) 국립국어원(2022). 국립국어원 맞춤법 교정 말뭉치 2021(버전 1.0). URL: <https://kli.korean.go.kr/corpus>
 - (영문) National Institute of Korean Language (2022). NIKL Spelling Correction Corpus 2021 (v.1.0). URL: <https://kli.korean.go.kr/corpus>

· 파일 명명 규칙

자리	1	2	3	4	5	6	7	8	9	10	11	12	13	14
속성	매체	구성 방법	주석 단계	구축 연도	일련번호(8자리)									
정의 값	M: 메신저 E: 웹	X: 추출	EC: 맞춤법 교정	21: 2021년	00000001 ~ 99999999 (여덟 자리 일련번호)									
※ 예시: MXEC2102112091.json 2021 년에 구축한 메신저 자료 가공 맞춤법 교정 말뭉치 파일 EXSEC102112091.json 2021 년에 구축한 웹 자료 가공 맞춤법 교정 말뭉치 파일														

· 예시

```
{
  "id": "MXEC2102112091",
  "metadata": {
    "title": "국립국어원 메신저 말뭉치 추출 MXEC2102112091",
    "creator": "국립국어원",
    "distributor": "국립국어원",
    "year": "2021",
    "category": [
      "메신저 대화 > 2인 대화",
      "메신저 대화 > 다자 대화"
    ],
    "annotation_level": "맞춤법 교정",
    "sampling": "부분 추출 - 임의 추출"
  },
  "document": [
    {
      "id": "MDRW1900000940.1",
      "metadata": {
        "title": "메신저 대화",
        "author": "개인 대화 참여자",
        "publisher": "카카오톡",
        "date": "20191219",
        "topic": "미용과 건강 (질병과 치료, 운동, 다이어트, 미용)",
        "speaker": [
          {
            "id": "1",
            "age": "30대",
            "occupation": "가정 주부",
            "sex": "여성",
            "birthplace": "경남",
            "principal_residence": "경남",
            "current_residence": "경남",
            "device": "스마트폰",
            "keyboard": "모아키"
          },
          {
            "id": "2",
```

```

        "age": "30대",
        "occupation": "전문가 및 관련 종사자",
        "sex": "남성",
        "birthplace": "경북",
        "principal_residence": "경북",
        "current_residence": "경남",
        "device": "스마트폰",
        "keyboard": "천지인"
    }
},
"setting": {
    "relation": "지역 : 현 거주지 지인"
}
},
"utterance": [
    {
        "id": "MDRW1900000940.1.1.1",
        "original_form": "오빠야",
        "form": "오빠야",
        "corrected_form": "오빠야",
        "speaker_id": "1"
    },
    {
        "id": "MDRW1900000940.1.1.2",
        "original_form": "요즘먹는영양제 뭐있음?",
        "form": "요즘먹는영양제 뭐있음?",
        "corrected_form": "요즘 먹는 영양제 뭐 있음?",
        "speaker_id": "1"
    },
    {
        "id": "MDRW1900000940.1.1.3",
        "original_form": "난 아는 약사가 추천해준 거 먹는데",
        "form": "난 아는 약사가 추천해준 거 먹는데",
        "corrected_form": "난 아는 약사가 추천해준 거 먹는데",
        "speaker_id": "2"
    },
    {
        "id": "MDRW1900000940.1.1.4",
        "original_form": "뭐먹는디",
        "form": "뭐먹는디",
        "corrected_form": "뭐 먹는데?",
        "speaker_id": "1"
    },
    {
        "id": "MDRW1900000940.1.1.5",
        "original_form": "너무 비싸서 다시 외산으로 갈까싶다..",
        "form": "너무 비싸서 다시 외산으로 갈까싶다..",
        "corrected_form": "너무 비싸서 다시 외산으로 갈까 싶다...",
        "speaker_id": "2"
    },
    {
        "id": "MDRW1900000940.1.1.6",
        "original_form": "ㅋㅋㅋㅋㅋㅋ뭐를얼마에먹고있는데 ㅋㅋㅋㅋㅋ",
        "form": "ㅋㅋㅋㅋㅋㅋ뭐를얼마에먹고있는데 ㅋㅋㅋㅋㅋ",
        "corrected_form": "ㅋㅋㅋㅋㅋㅋ 뭐를 얼마에 먹고 있는데? ㅋㅋㅋㅋㅋ",
    }
]

```

```

    "speaker_id": "1"
  },
  {
    "id": "MDRW1900000940.1.1.7",
    "original_form": "이름은 지금은 기억 안나는데 녹십자꺼임",
    "form": "이름은 지금은 기억 안나는데 녹십자꺼임",
    "corrected_form": "이름은 지금은 기억 안 나는데 녹십자 거임.",
    "speaker_id": "2"
  },
  {
    "id": "MDRW1900000940.1.1.8",
    "original_form": "녹십자꺼 비싸?",
    "form": "녹십자꺼 비싸?",
    "corrected_form": "녹십자 거 비싸?",
    "speaker_id": "1"
  },
  {
    "id": "MDRW1900000940.1.1.9",
    "original_form": "두달치에 6만 정도더라",
    "form": "두달치에 6만 정도더라",
    "corrected_form": "두 달 치에 6만 정도더라.",
    "speaker_id": "2"
  },
  {
    "id": "MDRW1900000940.1.1.10",
    "original_form": "그정도면 비싼건 아닌데",
    "form": "그정도면 비싼건 아닌데",
    "corrected_form": "그 정도면 비싼 건 아닌데",
    "speaker_id": "2"
  },
  {
    "id": "MDRW1900000940.1.1.11",
    "original_form": "싸지도 않지",
    "form": "싸지도 않지",
    "corrected_form": "싸지도 않지.",
    "speaker_id": "2"
  },
  {
    "id": "MDRW1900000940.1.1.12",
    "original_form": "단백질보충제?",
    "form": "단백질보충제?",
    "corrected_form": "단백질 보충제?",
    "speaker_id": "1"
  },
  {
    "id": "MDRW1900000940.1.1.13",
    "original_form": "아님 종합비타민?",
    "form": "아님 종합비타민?",
    "corrected_form": "아님 종합 비타민?",
    "speaker_id": "1"
  },
  {
    "id": "MDRW1900000940.1.1.14",
    "original_form": "종합~",
    "form": "종합~",

```

```

"corrected_form": "종합~",
"speaker_id": "2"
},
{
  "id": "MDRW1900000940.1.1.15",
  "original_form": "보충제도 사긴 해야되네",
  "form": "보충제도 사긴 해야되네",
  "corrected_form": "보충제도 사긴 해야 되네.",
  "speaker_id": "2"
},
{
  "id": "MDRW1900000940.1.1.16",
  "original_form": "왜 요새 체중이 줄었으",
  "form": "왜 요새 체중이 줄었으",
  "corrected_form": "왜 요새 체중이 줄었어",
  "speaker_id": "1"
},
{
  "id": "MDRW1900000940.1.1.17",
  "original_form": "?",
  "form": "?",
  "corrected_form": "?",
  "speaker_id": "1"
},
{
  "id": "MDRW1900000940.1.1.18",
  "original_form": "넌 저번에 가니까 이것저것 많더만",
  "form": "넌 저번에 가니까 이것저것 많더만",
  "corrected_form": "넌 저번에 가니까 이것저것 많더구먼.",
  "speaker_id": "2"
},
{
  "id": "MDRW1900000940.1.1.19",
  "original_form": "글치",
  "form": "글치",
  "corrected_form": "글치.",
  "speaker_id": "2"
},
{
  "id": "MDRW1900000940.1.1.20",
  "original_form": "난 모유수유 중이잖아",
  "form": "난 모유수유 중이잖아",
  "corrected_form": "난 모유 수유 중이잖아.",
  "speaker_id": "1"
},
{
  "id": "MDRW1900000940.1.1.21",
  "original_form": "ㄷㄷㄷ",
  "form": "ㄷㄷㄷ",
  "corrected_form": "ㄷㄷㄷ",
  "speaker_id": "1"
},
{
  "id": "MDRW1900000940.1.1.22",
  "original_form": "근육량이 줄어서",

```

```

    "form": "근육량이 줄어서",
    "corrected_form": "근육량이 줄어서.",
    "speaker_id": "2"
  },
  {
    "id": "MDRW1900000940.1.1.23",
    "original_form": "칼슘이랑 철분 종합비타민 먹음",
    "form": "칼슘이랑 철분 종합비타민 먹음",
    "corrected_form": "칼슘이랑 철분, 종합 비타민 먹음.",
    "speaker_id": "1"
  },
  {
    "id": "MDRW1900000940.1.1.24",
    "original_form": "ㅋㅋ 먹으면 좀 힘이 나나",
    "form": "ㅋㅋ 먹으면 좀 힘이 나나",
    "corrected_form": "ㅋㅋ 먹으면 좀 힘이 나나?",
    "speaker_id": "2"
  },
  {
    "id": "MDRW1900000940.1.1.25",
    "original_form": "아니 죽지않을수있다",
    "form": "아니 죽지않을수있다",
    "corrected_form": "아니, 죽지 않을 수 있다.",
    "speaker_id": "1"
  },
  {
    "id": "MDRW1900000940.1.1.26",
    "original_form": "힘은무슨 ㅋㅋㅋㅋ",
    "form": "힘은무슨 ㅋㅋㅋㅋ",
    "corrected_form": "힘은 무슨. ㅋㅋㅋㅋ",
    "speaker_id": "1"
  },
  {
    "id": "MDRW1900000940.1.1.27",
    "original_form": "ㅋㅋㅋ",
    "form": "ㅋㅋㅋ",
    "corrected_form": "ㅋㅋㅋ",
    "speaker_id": "2"
  },
  {
    "id": "MDRW1900000940.1.1.28",
    "original_form": "죽을똥 말똥 할 때 머리끄덩이 잡고 당겨주는건가",
    "form": "죽을똥 말똥 할 때 머리끄덩이 잡고 당겨주는건가",
    "corrected_form": "죽을 똥 말 똥 할 때 머리끄덩이 잡고 당겨주는 건가?",
    "speaker_id": "2"
  },
  {
    "id": "MDRW1900000940.1.1.29",
    "original_form": "그런거임",
    "form": "그런거임",
    "corrected_form": "그런 거임.",
    "speaker_id": "1"
  }
}

```

※ "original_form": 수집한 언어 자료의 원문을 그대로 유지한 형태(개인 정보 등은 비식별화)

“form”: 원문에서 연속된 여러 개의 공백(스페이스, 탭 등), 특수 메시지, 비식별화 기호 등을 제거하여 전처리한 형태

“corrected_form”: ‘form’에서 제공된 언어 표현을 바탕으로 한국어 처리 도구가 분석할 수 있는 수준으로 오탈자 등을 교정한 형태

- 자료 내용 문의: 02-2669-9638